ТЕХНОЛОГИИ МАШИННОГО ИНТЕЛЛЕКТА ДЛЯ МОНИТОРИНГА СИЛОВЫХ ТРАНСФОРМАТОРОВ

АВТОРЫ:

А.В. ГОФМАН,
К.Т.Н.,
«НТЦ РОССЕТИ ФСК ЕЭС»

А.С. ВЕДЕРНИКОВ,
К.Т.Н.,
ФГБОУ «САМГТУ»

В.М. ДАШКОВ,
К.Т.Н.,
ФГБОУ «САМГТУ»

Мониторинг состояния силового трансформатор является важнейшей, но достаточно сложной задачей, так как при различных режимах работы происходит накапливание воздействий на его обмотки и магнитопровод. Своевременное выявление нарушений функционирования трансформатора позволит предотвратить их дальнейшее развитие. Современные методы машинного обучения позволят оперативно выполнять визуальный контроль состояния силовых трансформаторов.

Ключевые слова: мониторинг; силовой трансформатор; машинное обучение; компьютерное зрение; сверточные сети.

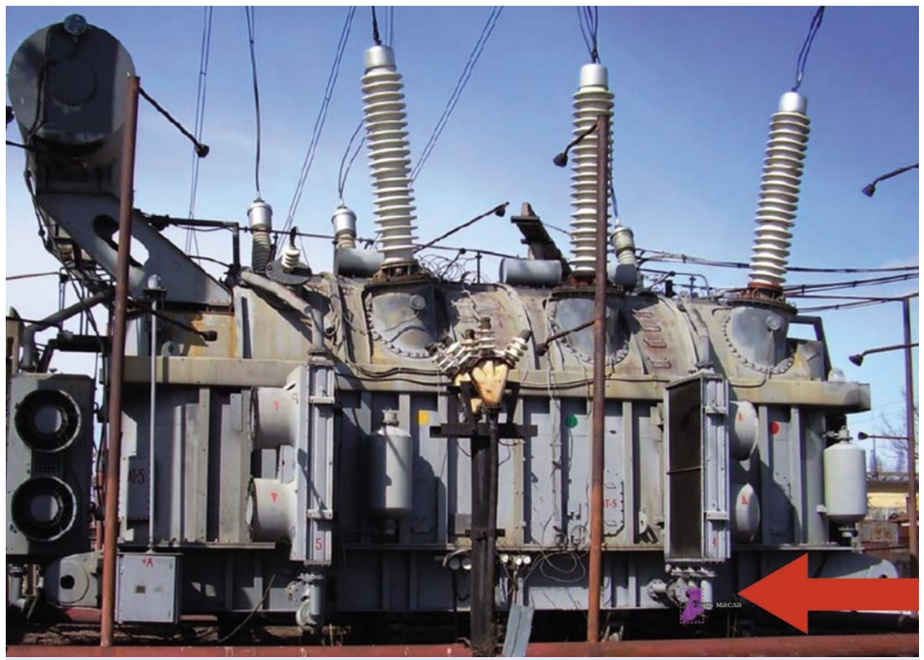

Маска и рамка потеков масла на оборудовании трансформатора после обучения сети

Несмотря на небольшую долю аварийности силовых трансформаторов в общем объеме технологических нарушений в электросетевом комплексе, любое нарушение, связанное с работой силового трансформатора, приводит к значительным экономическим потерям [1]. Повреждение силового трансформатора не только вызывает убытки, связанные с необходимостью его замены, а также, возможно, реконструкции части подстанции, но и создает на время проведения ремонтных работ сложные режимы в сети, при которых питание потребителей отличается от нормальной схемы.

Для решения этой задачи активно применяются и развиваются различные методы диагностики и мониторинга трансформаторов. При этом зачастую методы диагностики позволяют спрогнозировать и предотвратить аварийные последствия развития внутренних нарушений оборудования. Мониторинг состояния силового трансформатора, несмотря на постоянные измерения его параметров и периодический осмотр обслуживающим персоналом, является достаточно сложной задачей, так как в различных режимах его работы происходит накапливание воздействий на его обмотки и магнитопровод. Кумулятивный эффект от этих воздействий приводит к нарушениям изоляции, смещению магнитопровода, окислению масла и другим повреждениям силового трансформатора. Своевременное выявление этих нарушений и вывод из работы оборудования на этапе возникновения нарушения позволят предотвратить их дальнейшее развитие и повреждение оборудования вплоть до его полного уничтожения. Постоянный визуальный поверхностный контроль позволит предотвратить или снизить последствия неконтролируемого развития нарушения, в число наиболее опасных из которых входят [2, 3]:

- течи масла через уплотнения или швы;
- повышенная загрязненность поверхности трансформатора;
- пожары из-за повреждения маслонаполненных вводов.

Проблему необходимости постоянного мониторинга состояния оборудования усугубляют его старение и дороговизна замены или модернизации основного трансформаторного оборудования.

Значительно снизить вероятность развития повреждений трансформатора возможно путем постоянного визуального контроля над его состоянием. Визуальный контроль трансформатора должен обеспечивать:

- постоянный контроль в любое время дня и ночи в любых климатических условиях;
- достоверность определения возникающих отклонений от нормального состояния оборудования;
- оповещение оперативного персонала об обнаруженных отклонениях.

Бурное развитие технологий машинного интеллекта в последние годы дает новые инструменты для решения широкого круга различных задач. При этом машинное обучение (machine learning) выделилось в особое направление, которое в настоящее время фактически превратилось в отдельную науку, стоящую на пересечении математики, статистики и других направлений, связанных с прикладным применением машинного интеллекта. Актуальный состав алгоритмов машинного обучения представлен на рис. 1, и он постоянно расширяется.

На практике наиболее часто методы и модели машинного обучения применяются для задач временных рядов, самый частый пример такого применения — прогнозирование финансовых показателей, и компьютерного зрения, примерами которого являются

Рис. 1

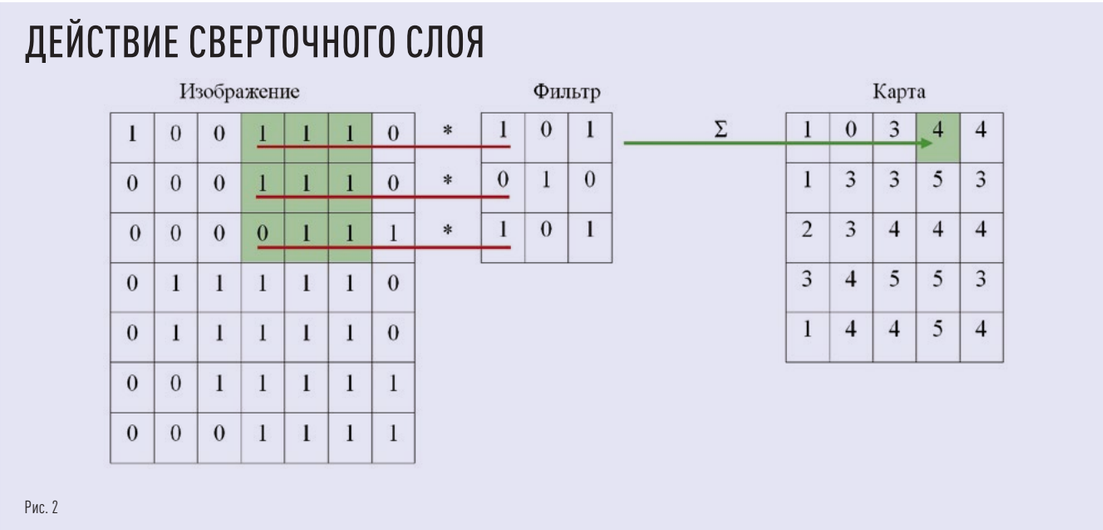

Рис. 2

системы распознавания, беспилотные автомобили, анализ медицинских снимков и т.д. При этом непрерывный рост интереса и числа исследований в этом направлении свидетельствует об их технических и экономических преимуществах перед традиционными методами.

Успехи в применении машинного обучения в различных отраслях экономики дают повод рассмотреть их применение в электроэнергетике. Обзор научных работ в этой области свидетельствует об активном интересе к созданию математических моделей — цифровых двойников (digital twin), позволяющих давать оценку состояния элементов электрической сети. Этот метод предполагает подход к рассмотрению реального оборудования как сложной математической модели, принимающей на вход набор влияющих факторов в виде некоторой выборки измеримых параметров (цифровые признаки) и/или описательных характеристик (категориальные признаки) и формирующей на выходе отклик в виде некоторых параметров состояния. Эта модель создается методом «обучения» на реальных данных с целью «научить» ее повторять отклик реального оборудования для определенных входных параметров. Применение цифровых двойников позволяет успешно решать следующие задачи [4]:

– прогнозирование краткосрочного состояния оборудования, позволяющего принимать решения, упреждающие серьезные повреждения или аварийные ситуации;

– прогнозирование среднесрочного или долгосрочного изменения параметров оборудования для оптимизации ремонтных компаний.

Успех применения цифровых моделей линейно зависит от набора, качества и объема статистической информации, использованной при их создании, — обучающей выборки. С учетом зачастую недостаточного объема имеющихся в наличии в компаниях электроэнергетики баз данных статистической информации эта проблема нередко является главной из тех, что приходится решать специалисту по разработке моделей машинного обучения [5]. А при невозможности учета некоторых факторов, которые могут существенно повлиять на работоспособность силовых трансформаторов, таких как скрытые дефекты при изготовлении, нарушения при ремонте и т. д., делаем вывод о том, что цифровые двойники не могут гарантировать точную информацию об их состоянии.

Другим вариантом осуществлять непрерывный автоматический мониторинг состояния оборудования электрической сети является компьютерная система, способная в круглосуточном режиме обнаруживать и распознавать отклонения от нормального состояния оборудования и оповещать о них оперативный персонал [6]. Такая система должна соответствовать следующим требованиям:

– выделять объект интереса в видеопотоке — критичные изменения визуального состояния оборудования, вызванные повреждением;

– отслеживать изменения этого объекта;

– работать непрерывно в любое время дня и ночи и при любых погодных условиях.

Эти требования являются обычными для всех систем компьютерного видеонаблюдения [7], но задача визуального контроля состояния силового трансформатора имеет следующие упрощения: отсутствуют проблемы изменения основного объекта в кадре во времени, кроме природных факторов (день/ночь, снег, туман, дождь), но присутствуют характерные для видеонаблюдения проблемы:

– наличие в кадре нескольких объектов, которые могут перекрывать друг друга (потеки масла в нескольких местах, возникновение загорания потеков масла);

– похожесть объектов друг на друга в разных местах трансформатора;

– высокая вычислительная нагрузка для работы с видеопотоком.

Гигантский скачок в развитии методов компьютерного зрения (Computer vision) произошел с началом применения сверточных нейронных сетей (Convolutional Neural Networks, CNN) [8]. Сверточные сети применяют так называемый сверточный (convolutional) слой для объединения характерных групп пикселей. Для этого используют окно, обычно размера 3×3, 5×5 или 7×7, называемое фильтром, которое последовательно сдвигается по горизонтали и вертикали изображения, формируя карту его признаков (рис. 2). Фильтр может иметь различную комбинацию единиц и нулей, которые умножаются на соответствующие значения пикселей изображения, и их сумма представляет собой результат применения фильтра к фрагменту изображения. Изображение может сканироваться одновременно несколькими различными фильтрами, давая таким образом на выходе несколько карт, называемых каналами.

Возможности сверточных сетей позволяют применять их в автоматическом режиме для постоянного слежения за изменениями состояния оборудования по картинкам видеоряда, получаемого от видеокамеры. При этом сверточная сеть решает проблему распознавания одним из следующих методов [7]:

– классификация изображений;

– поиск и локализация объектов.

В 2012 г. Алексей Крижевский представил сеть AlexNet на международном соревновании ImageNet по классификации содержимого картинок, которая стала прорывом в применении сверточных сетей и открыла новую главу в применении сетей для распознавания объектов на изображениях [8]. Эта сеть представляет собой набор сверточных (Conv) и полносвязанных (Fc) слоев и один выходной нейрон (рис. 3). Картинка в такой сети поступает на вход (input) в формате матрицы, далее в сверточных слоях кодируется в матрицы уменьшенного размера, характеризующие признаки каждого фрагмента изображения заданного размера. Эти матрицы поступают в решающий полносвязный слой, формирующий значение выхода (output), соответствующее определенному классу объекта на картинке. Для выполнения такой классификации требуется «обучить» сеть, т. е. настроить ее веса таким образом, что бы она максимально точно выполняла классификацию изображения.

Современные варианты развития архитектуры этой сети с различными характеристиками сверточных и выходного слоев в отношении задачи визуального мониторинга состояния трансформатора характеризуются:

– быстрым временем создания нейронной сети и низкими требованиями к аппаратному обеспечению;

– средней достигаемой точностью распознавания изменений на изображении;

– возможностью определения различных изменений;

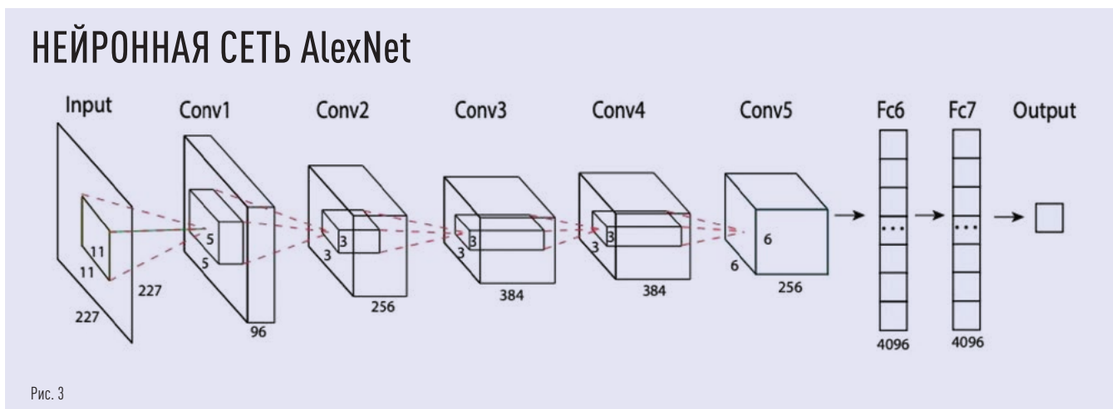

Рис. 3

ПРИМЕНЕНИЕ АУГМЕНТАЦИИ К ОБУЧАЮЩЕЙ ВЫБОРКЕ

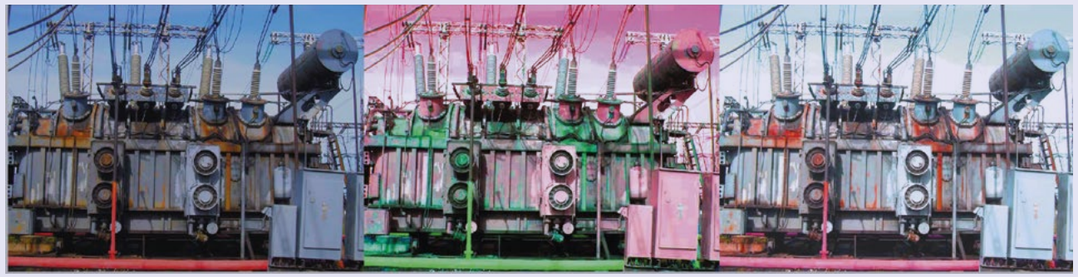

Рис. 4

– сложностью обработки видеопотока из-за невысокой скорости обработки одного изображения и необходимости их последовательной обработки.

В ходе исследований выполнено обучение сверточных сетей с помощью методики Transfer learning [8], предполагающей применение предобученных сетей типа VGG-19 with batch normalization, ResNet-34, ResNet-50, ResNet-101, DenseNet-121, DenseNet-169, Inception-v3 библиотеки PyTorch [9] и их ансамблей, на которых «замораживались» внутренние сверточные слои, модель при обучении настраивалась на решение задачи выявления и классификации причин отклонения визуального состояния стороны ВН трансформатора АТДЦТН-200000/330/110 подбором параметров входного сверточного слоя и выходного классификатора.

При проведении этих исследований команда ученых столкнулась с проблемой недостаточного объема первичной информации — картинок оборудования при различном уровне освещенности и различных погодных условиях. Данная проблема частично решилась применением аугментации (data augmentation) — механизма искусственной трансформации изображений для расширения объема обучающего набора данных с изменением яркости, контраста, насыщения, искажения, обрезки, сдвига, поворота, окраски, шума, тона изображения (рис. 4).

Такой прием позволил на малом количестве базы фотографий обучить сверточную сеть с удовлетворительной точностью классификации следующих повреждений:

– течь масла по сварным швам расширительного бака;

– течь масла по уплотнениям адаптера нейтрали и клеммным коробкам;

– течь масла по уплотнению фланцевого соединения адсорбционного фильтра;

– течь масла на клеммной коробке трансформаторов тока ВН;

– течь масла на маслонасосе;

– течь масла по уплотнению смотрового люка.

Наилучший результат точности определения повреждений (Precision) 82,3% был достигнут применением предобученной архитектуры типа DenseNet-161 и выходного классификатора, построенного с применением слоев ReLU, Tanh и Sigmoid (рис. 5). Сеть типа DenseNet (Densely Connected Convolutional Network) была предложена в 2017 г. Она отличается наличием компактно соединенного блока (Dense Block), который соединяет каждый слой с каждым другим слоем. Соединения служат для объединения (конкатенации, channel-wise concatenation) признаков в единую матрицу, формируя карту свойств изображения от каждого предыдущего слоя. Таким образом, достигается более высокая по сравнению с другими аритектурами сверточных сетей вычислительная эффективность. Как следствие, особенностью DenseNet является ее хорошая обучаемость на малых наборах данных [10].

Полученные результаты позволяют дать положительную оценку возможности применения разработанных моделей для постоянного контроля внешнего состояния трансформатора, выявления и классификации повреждений. При этом основное свойство классификатора, которое позволяет ему уверенно классифицировать один объект, становится проблемой при нескольких одновременных событиях, например потеке масла и последующем пожаре. Эта задача успешно решается применением алгоритмов поиска и локализации объектов.

АРХИТЕКТУРА РАЗРАБОТАННОЙ СЕТИ DENSENET-161

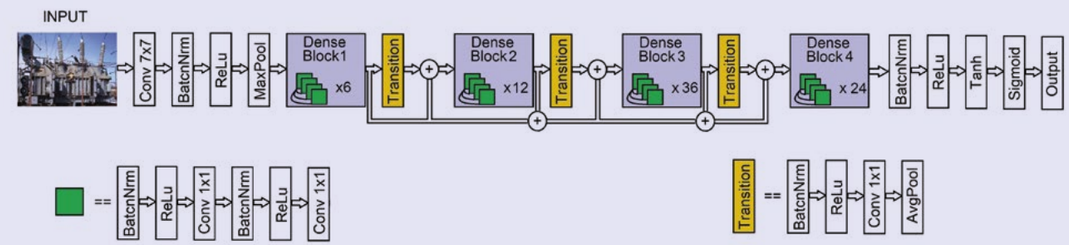

Рис. 5

В 2017 г. команда разработчиков компании Facebook AI Research представила сеть Mask R-CNN для решения задачи поиска и локализации объектов [10]. Эта сеть является последней и наиболее успешной разработкой для решения задачи поиска и локализации объектов на изображении. Сеть с архитектурой Mask R-CNN позволяет выделять на изображениях контуры (маски) разных объектов, даже если таких объектов несколько и они имеют различный размер или частично перекрываются (рис. 6). Работу сети Mask R-CNN можно разделить на два этапа [11]:

1) генерируются предположения о том, где на изображении могут находиться объекты;

2) на основании сделанных предположений предсказывается класс объекта, уточнется его рамка и создается его маска.

Оба этапа реализуются в единой структуре сети.

На первом этапе сверточная сеть, обычно ResNet50 или ResNet101, выполняет операции свертки (Conv) для извлечения признаков изображения. При этом первые слои извлекают признаки низшего порядка (углы и грани) и последние слои детектируют

СТРУКТУРА РАБОТЫ СЕТИ MASK R-CNN

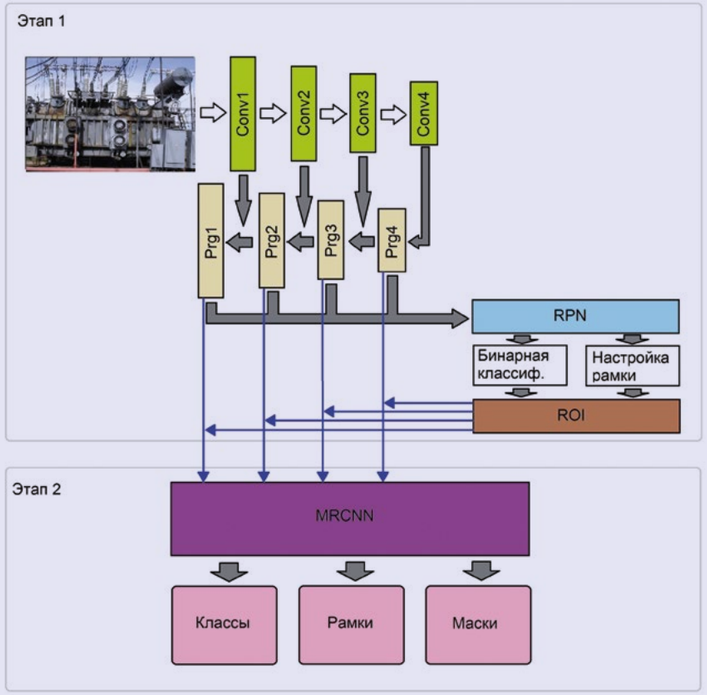

Рис. 6

целые объекты. Для лучшего представления объектов применяется механизм FPN (Future Pyramid Network), который, используя вторую пирамиду из слоев Prg, передает информацию об объектах на первые слои для формирования карт признаков, содержащих информацию об объектах всех уровней. Эти карты передаются в модуль RPN (Region Proposal Network), который использует механизм скользящего окна для формирования предположений о нахождении на изображении областей, содержащих объекты. Скольжение выполняется по фрагментам изображения различного размера и формы, называемым Anchor. Одно изображение может содержать до 200 тыс. таких фрагментов. Это сканирование выполняется очень быстро, приблизительно за 10 мс, благодаря применению параллельных расчетов на графическом процессоре и сканированию не всей картинки, а карты признаков, полученных в FPN.

Модуль RPN имеет два выхода для каждого Anchor:

1) класс Anchor`a, передний план или фон;
2) дельты изменения координат центра рамки объекта, ее высоты и ширины для лучшей центровки относительно объекта и захвата объекта целиком.

В модуле RPN отбираются только те Anchor, которые с наибольшей долей вероятности содержат объект целиком на основании рейтинга заполнения переднего плана. Полученные фрагменты поступают в модуль ROI (Regions of Interest), который формирует:

– класс объекта;

– уточнение размеров рамки объекта.

На втором этапе сеть MRCNN, используя на входе информацию объектов, спрогнозированных на первом этапе, назначает им соответствующие области карты объектов и создает рамки и маски. Маска — это область объекта на изображении, повторяющая его контур. Действие MRCNN аналогично действию RPN с тем различием, что вместо Anchor применяется метод ROIAlign [12] для определения соответствующих областей карты признаков функций, и отдельная ветвь используется для создания масок объектов из пикселей изображения. В результате этих операций сеть формирует класс объекта, его рамку и маску.

Для обучения сети Mask R-CNN использовался упомянутый ренее прием Transfer Learning, который предполагает применение предобученной на датасете COCO [13] модели вместо обучения модели с нуля (рис. 7). Для разметки исходных изображений использовалось программное обеспечение VGG Image Annotator [14].

Процесс обучения сети благодаря Transfer Learning и применению параллельных вычислений на графическом процессоре достаточно быстрый. На тестовом наборе сеть научилась локализовать потеки масла с вероятностью 0,78 за 14 итераций, что составило в сумме менее 30 минут машинного времени на графическом процессоре Nvidia GTX-1050. После обучения сеть может работать в режиме реального времени совместно с видеокамерой на подстанции электрических сетей (рис. 8). Доступность этой технологии достигается применением специальных модулей для имплементации искусственных нейронных сетей в реальное применение. Примером такого модуля может служить модуль Nvidia Jetson Nano.

Ввиду отсутствия достаточного объема размеченных изображений трансформатора, содержащих в том числе различное время суток с соответствующим положением теней от элементов трансформатора, в ряде случаев была выполнена избыточная локализация теней и их классификация как потеков масла. Эта проблема будет решена применением расширенного объема обучающего набора, содержащего как весь спектр возможных повреждений (потеки масла, возгорание), так и всех возможных помех (снег, тени и т. д.) [15–31].

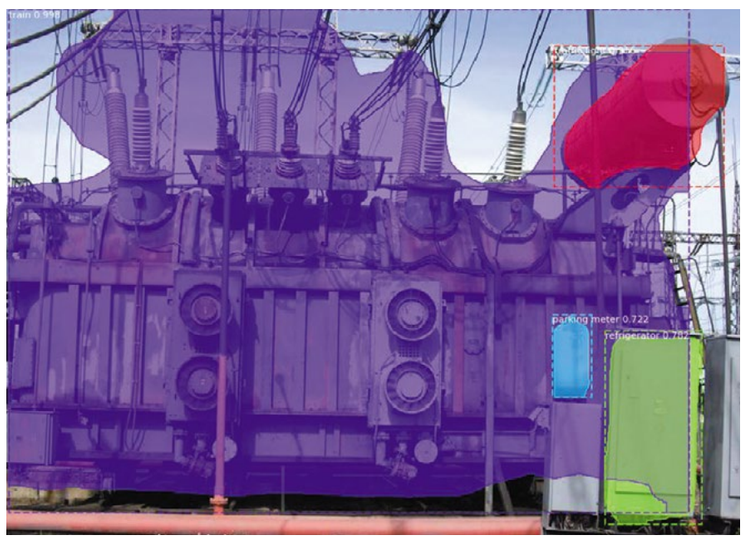

Рис. 7.
Локализация объектов на изображении трансформатора до обучения сети

ВЫВОДЫ

Предложена искусственная нейронная сеть, демонстрирующая современный уровень развития методов и моделей машинного обучения, позволяющая создавать модели компьютерного зрения, способные выполнять постоянный контроль визуального состояния силовых трансформаторов в круглосуточном режиме, оказывая неоценимую поддержку оперативно-технологическому управлению в повышении надежности электроснабжения. Результаты обучения сети обнаружению потеков масла позволяют судить об успешности применения предлагаемой технологии для обнаружения мест возможных возгораний. Компьютерное зрение способно достоверно, с минимальными затратами на аппаратное обеспечение решать задачи раннего обнаружения повреждения оборудования и оповещать о возникшем пожаре на силовом оборудовании.

Показано, что возможно применение компьютерного зрения в качестве элемента мониторинга цифровой системы управления силовым оборудованием для повышения надежности электроснабжения.

Сделан вывод о необходимости создавать и постоянно расширять общую базу фото- и видеоматериалов различных состояний оборудования различных марок и типов, что позволит «доучивать» системы компьютерного зрения для максимальной достоверности распознавания отклонений от нормального состояния силового оборудования.

ЛИТЕРАТУРА

1. Защита трансформаторов: предупредить дешевле, чем вылечить/Газета «Энергетика и промышленность России». Май 2012. № 09 (197). URL: https://www.eprussia.ru/epr/197/13984.htm
2. Анализ повреждений силовых трансформаторов за 1989–1991 годы: Сост. фирмой по наладке, совершенствованию технологии и эксплуатации электростанций и сетей ОРГРЭС. М.: СПО ОРГРЭС, 1993.
3. Севостьянов П.Р. Анализ повреждаемости трансформаторов мощностью 16 и 25 МВА класса напряжения 11 О кВ//Электро. 2004. № 5. С. 25–27.
4. Digital Twin Framework and Its Application to Power Grid Online Analysis. Mike Zhou, Member, IEEE, Jianfeng Yan, Member, CSEE, and Donghao Feng CSEE/Journal of power and energy systems. September 2019. Vol. 5. N 3.
5. Digital Twin: Enabling Technologies, Challenges and Open Research. Aidan Fuller, Zhong Fan, Charles Day and Chris Barlow. URL: https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9103025
6. Силовые трансформаторы. Современные принципы построения систем непрерывного контроля. URL: http://www.news.elteh.ru/arh/2014/90/06.php
7. Введение в компьютерное зрение. Курс лекций Антона Конушина в МГУ, Факультет вычислительной математики и кибернетики. URL: https://www.lektorium.tv/course/22847
8. Вижу, значит существую: обзор Deep Learning в Computer Vision. URL: https://habr.com/ru/company/mipt/blog/450732/
9. Torchvision.models. URL: https://pytorch.org/docs/stable/torchvision/models.html
10. Densely Connected Convolutional Networks. Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger. URL: https://arxiv.org/pdf/1608.06993.pdf
11. Simple Understanding of Mask RCNN. Xiang Zhang. URL: https://medium.com/@alittlepain833/simple-understanding-of-mask-rcnn-134b5b330e95
12. Mask R-CNN Kaiming He, Georgia Gkioxari, Piotr Dollár, Ross Girshick. arXiv:1703.06870v3 [cs.CV] 24 Jan 2018.
13. Mask R-CNN — Train on Shapes Dataset. URL: https://github.com/matterport/Mask_RCNN/blob/master/samples/shapes/train_shapes.ipynb
14. VGG Image Annotator. URL: http://www.robots.ox.ac.uk/~vgg/software/via/
15. Latest Jetson Products. https://developer.nvidia.com/buy-jetson?product=jetson_nano&location=RU
16. An Analysis of Deep Neural Network Models for Practical Applications Alfredo Canziani, Adam Paszke, Eugenio Culurciello/arXiv:1605.07678v4 [cs.CV] 14 Apr 2017.
17. CSRNet-keras. URL: https://github.com/Neerajj9/CSRNet-keras
18. Mask R-CNN for Object Detection and Segmentation. URL: https://github.com/matterport/Mask_RCNN
19. PCC Net: Perspective Crowd Counting via Spatial Convolutional Network. URL: https://github.com/gjy3035/PCC-Net
20. VGG16 — сверточная сеть для выделения признаков изображений. URL: https://neurohive.io/ru/vidy-nejrosetej/vgg16-model/
21. Walter Phillips III, Mubarak Shah, and Niels da Vitoria Lobo, Flame Recognition in Video, Pattern Recognition Letters. January 2002. Vol. 23 (1–3). PP. 319–327.
22. Zhenyuan Wang, Yilu Liu, Griffin P. J. Диагностика трансформаторов с помощью нейронных сетей и экспертных систем//IEEE Industry Applications Magazine. 2000. Vol. 6. N 2. P. 50–55.
23. Алексеев Б.А. Контроль состояния (диагностика) крупных силовых трансформаторов. М.: Изд-во НЦ ЭНАС, 2002.
24. Давиденко И.В. Информационные технологии в организации диагностики силового электрооборудования//Электрика. 2004. № 7. С. 2125.
25. Ильина Е. Перспективы развития диагностики электрооборудования методов ультрафиолетового контроля. URL: http://www.corocam-uv.ru/menu_3_13.html
26. Гун И.Г., Салганик В.М., Евдокимов С.А., Сарлыбаев А.А. Основные неисправности и методы диагностирования силовых трансформаторов в условиях эксплуатации. URL: https://cyberleninka.ru/article/n/osnovnye-neispravnosti-i-metody-diagnostirovaniya-silovyh-transformatorov-v-usloviyah-ekspluatatsii
27. К вопросу о прогнозировании состояния силового трансформатора/В.Н. Ларионов, Т. Лхамсурэнгийн, Г.В. Попов, И.А. Холостова//Повышение эффективности работы ТЭС и энергосистем: Труды ИГЭУ/ИГЭУ. Иваново, 1997. С. 208–210.
28. Львов Ю.Н., Львов М.Ю. Диагностика трансформаторного оборудования//Энергетик. 2000. № 1.1. С. 26–27.
29. О повреждениях силовых трансформаторов напряжением 110–500 кВ в эксплуатации/Б.В. Ванин, Ю.И. Львов, М.Ю. Львов и др.//Электрические станции. 2001. № 9. С. 53–58.
30. СТО 56947007–29.200.10.011–2008. Системы мониторинга силовых трансформаторов и автотрансформаторов. Общие технические требования.
31. Хренников А.Ю. Высоковольтное оборудование в электротехнических системах: диагностика, дефекты, повреждаемость, мониторинг: учеб. пособие/А.Ю. Хренников. М.: ИНФРА-М, 2019.