

<https://doi.org/10.21122/1029-7448-2025-68-4-324-342>

УДК 621.3

Система автоматизированной обработки результатов тепловизионной диагностики электрооборудования

А. Д. Косенко¹⁾, В. А. Величко¹⁾, А. А. Косенко¹⁾

¹⁾Оренбургский государственный университет (Оренбург, Российская Федерация)

Реферат. Развитие электроэнергетики сопровождается улучшением средств диагностики состояния оборудования в энергетических системах. Часть оборудования электрических сетей значительно изношена и требует повышенного внимания для определения остаточного ресурса. Синтез интеллектуальных технологий и общепринятых методов диагностики является следующей ступенью на пути к будущему электроэнергетики. Цель работы – разработка принципов функционирования системы автоматизированной обработки результатов тепловизионной диагностики электрооборудования. В работе исследуются критерии оценки дефектов электрооборудования на основе температуры нагрева. Алгоритм для автоматизации обработки результатов тепловизионной диагностики электрооборудования разрабатывается на базе искусственных нейронных сетей. Программная реализация детектирования элементов электроустановок на инфракрасных снимках выполняется с использованием архитектуры YOLOv5. Тестирование и оценка обученной нейронной сети производятся с использованием данных тепловизионной диагностики работающего электрооборудования. Обученная в рамках исследования модель нейронной сети по результатам детектирования термограмм из тестовой выборки демонстрирует уверенное обнаружение деталей электроустановок. По результатам анализа нормативной документации был формализован подход к определению степени развития дефектов. Помимо использования термограмм сетевого оборудования фиксируются также токовая нагрузка и температура окружающего воздуха для выбора подходящей формулы пересчета превышения температуры или избыточной температуры узла электроустановки или контактного соединения. Разработанный алгоритм по автоматизации обработки результатов тепловизионной диагностики электроустановок на базе нейросети YOLOv5 отражает основные процессы, необходимые для функционирования системы. Сформирован и размечен пользовательский набор данных, включающий термограммы реально существующих электроустановок, на основании которого была обучена модель нейросети. Использование тестовой выборки позволило рассчитать значения метрик для оценки качества обучения модели YOLOv5. Разработанная система апробирована на термограммах электрооборудования. Ее использование позволяет в автоматизированном режиме выявить не только развившиеся дефекты, но и начальную стадию возникновения неисправностей.

Ключевые слова: тепловизионная диагностика электрооборудования, термограмма электроустановки, инфракрасный контроль, инфракрасная диагностика, превышение температуры, избыточная температура, контактное соединение, детектирование объектов, сверточные нейронные сети, нейросеть YOLO

Для цитирования: Косенко, А. Д. Система автоматизированной обработки результатов тепловизионной диагностики электрооборудования / А. Д. Косенко, В. А. Величко, А. А. Косенко // *Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ*. 2025. Т. 68, № 4. С. 324–342. <https://doi.org/10.21122/1029-7448-2025-68-4-324-342>

Адрес для переписки

Косенко Анастасия Дмитриевна
Оренбургский государственный университет
просп. Победы, 13,
460018, г. Оренбург, Российская Федерация
Тел.: +7 353 237-28-91
fiara@inbox.ru

Address for correspondence

Kosenko Anastasia D.
Orenburg State University
13, Pobedy Ave.,
460018, Orenburg, Russian Federation
Tel.: +7 353 237-28-91
fiara@inbox.ru

The System for Automated Processing of the Results of Thermal Imaging Diagnostics of Electrical Equipment

A. D. Kosenko¹⁾, V. A. Velichko¹⁾, A. A. Kosenko¹⁾

¹⁾Orenburg State University (Orenburg, Russian Federation)

Abstract. The development of the electric power industry is accompanied by the improvement of diagnostic tools for the state of equipment in energy systems. Some of the electrical network equipment is significantly worn out and requires increased attention in order to determine the residual resource. The synthesis of intelligent technologies and generally accepted diagnostic methods is the next step towards the future of the electric power industry. The aim of the project is to develop the principles for the functioning of an automated processing system for results of thermal imaging diagnostics of electrical equipment. The paper examines the criteria for evaluating defects in electrical equipment based on the heating temperature. An algorithm for automating the processing of the results of thermal imaging diagnostics of electrical equipment is also being developed on the basis of artificial neural networks. The software implementation of the detection of electrical installation elements in infrared images is performed using the YOLOv5 architecture. Testing and evaluation of the trained neural network are performed using thermal imaging diagnostics data of working electrical equipment. The neural network model trained as part of the study demonstrates confident detection of electrical installation parts based on the results of detecting thermograms from a test sample. Based on the results of the analysis of regulatory documentation, an approach to determining the degree of defect development has been clearly laid out. In addition to using thermal images of electrical grid equipment, the current load and ambient temperature are also recorded to select a suitable formula for calculating temperature excess or excessive temperature of an electrical installation unit or contact connection. The developed algorithm for automating the processing of the results of thermal imaging diagnostics of electrical installations based on the YOLOv5 neural network reflects the main processes necessary for the functioning of the system. A custom dataset was generated and marked up, including thermograms of real-life electrical installations, on the basis of which a neural network model was trained. Using a test sample, we were able to calculate the values of metrics to evaluate the quality of YOLOv5 model learning. The developed system has been tested on thermograms of electrical equipment. Its use makes it possible to identify not only the developed defects, but also the initial stage of the occurrence of defects in an automated mode.

Keywords: thermal imaging diagnostics of electrical equipment, thermal image of an electrical installation, infrared monitoring, infrared diagnostics, temperature excess, excessive temperature, contact connections, object detection, convolutional neural networks, YOLO neural networks

For citation: Kosenko A. D., Velichko V. A., Kosenko A. A. (2025) The System for Automated Processing of the Results of Thermal Imaging Diagnostics of Electrical Equipment. *Energetika. Proc. CIS Higher Educ. Inst. and Power Eng. Assoc.* 68 (4), 324–342. <https://doi.org/10.21122/1029-7448-2025-68-4-324-342> (in Russian)

Введение

Интеллектуальные технологии и средства мониторинга и диагностики состояния оборудования в энергетических системах – одна из составляющих ряда приоритетных мер, способствующих развитию электроэнергетики в соответствии с Энергетической стратегией Российской Федерации на период до 2035 г. [1].

Одним из путей реализации вышеуказанных мероприятий является разработка автоматизированных программных комплексов, способных свести

к минимуму влияние «человеческого фактора» на результаты диагностики электроустановок и сделать обработку данных более оперативной.

Проблема износа силовых электроустановок энергетической системы проявляется все чаще с увеличением срока их эксплуатации. В результате ограниченного финансирования работ по реконструкции существенная доля оборудования электрических сетей на сегодняшний день выработала свой срок службы и находится на пределе возможностей. Так, например, по данным компании «Таврида Электрик», «средний возраст оборудования подстанций 35 кВ составляет 35 лет, а возраст около 20 % оборудования приближается к отметке 45–50 лет» [2].

Электроустановки высокого напряжения на протяжении всего срока службы подвержены влиянию различных факторов: сильных электромагнитных полей, механических воздействий, неблагоприятных погодных условий. Для снижения рисков повреждения электрооборудования в процессе эксплуатации регулярно производится его диагностика. Цель технической диагностики заключается в оценке состояния технической системы в условиях ограниченной информации и, как следствие, повышении надежности остаточного ресурса оборудования [3, 4].

По признаку воздействия различают методы разрушающего и неразрушающего контроля. По результатам анализа научно-технической литературы в области диагностики высоковольтного оборудования установлено, что наиболее часто используется группа методов неразрушающего контроля [3, 5–7]. Теме диагностики изоляции силовых трансформаторов, кабелей и других конструкций методом частичных разрядов посвящены работы [8–10]. В [11] изложена методика вибрационного обследования силовых трансформаторов. Хроматографический анализ масла в качестве одного из методов мониторинга состояния силовых трансформаторов приводят в [12]. Применение инфракрасной (ИК) термографической диагностики в целях выявления неисправностей электротехнических устройств упоминается в работах [13–15]. Практическая значимость каждого из вышеперечисленных методов контроля подтверждается наличием нормативной документации [16, 17].

В настоящее время периодическая инфракрасная диагностика оборудования энергосистемы позволяет оперативно обнаруживать дефекты. В процессе термографирования специалисты создают значительное количество инфракрасных изображений, каждое из которых можно рассматривать как массив данных. Для определения температуры объекта на термограмме необходимо учитывать различные внешние факторы и пользоваться формулами пересчета [16]. Автоматизация процесса обработки термограмм применительно к инфракрасному контролю электроустановок способна увеличить производительность труда специалистов по тепловизионной диагностике, тем самым реализовав одно из приоритетных мероприятий энергетической стратегии. В связи с этим целью работы является разработка принципов функционирования системы автоматизированной обработки результатов тепловизионной диагностики электрооборудования.

Для достижения поставленной цели определены следующие задачи:

- выбрать критерии оценки дефектов электрооборудования на основе температуры нагрева;
- разработать алгоритм для автоматизации обработки результатов тепловизионной диагностики электрооборудования на базе искусственных нейронных сетей;
- программно реализовать детектирование элементов электроустановок на инфракрасных снимках;
- провести тестирование и оценку обученной нейронной сети с использованием данных тепловизионной диагностики работающего электрооборудования.

Рассмотрим решение каждой из перечисленных выше задач.

Объекты и методика исследования

Зачастую на объектах электроэнергетики для получения ИК-изображений применяются переносные тепловизоры. Специалисты по тепловизионной диагностике производят съемку, по результатам которой создается массив термограмм, подлежащих обработке в специализированных программных комплексах с учетом требований нормативной документации [16, 17].

При обнаружении дефекта на тепловизионном снимке специалисту требуется его классифицировать. Эта задача решается путем сравнения температуры оборудования или токоведущей части с наибольшим допустимым значением температуры нагрева или ее превышения [16]. На следующем шаге по таблицам браковочных нормативов, исходя из рассчитанных значений превышения температуры или избыточной температуры, производится классификация дефекта. Как правило, электроустановки находятся не под номинальной нагрузкой, поэтому необходимо пользоваться формулами пересчета температуры [17]. Из приведенной методики видно, что при обработке большого количества изображений вручную могут потребоваться значительные затраты времени. Перспективным представляется использование автоматизированной системы для повышения скорости обработки ИК-изображений и снижения количества случайных вычислительных ошибок и человеческого фактора.

Автоматизированные системы в отличие от автоматических предполагают участие человека в производственном процессе [18]. Предлагаемая система будет способна взять на себя часть функций по обработке изображений, что в перспективе упростит труд специалистов при диагностике электроустановок.

Для формирования математической модели системы критериев определения дефектов был рассмотрен ряд нормативных документов в сфере ИК-диагностики электроустановок [15, 19]. При работе электроустановок с токами, отличными от номинальных, необходимо пользоваться формулами пересчета температуры в зависимости от нагрузки. В качестве примера рассмотрим формулы определения превышения температуры и избыточной температуры. Полученные значения сравниваются с браковочными нормативами при ИК-диагностике оборудования электрических сетей [16].

Превышение температуры – разность между измеренной температурой нагрева и значением температуры окружающего воздуха [16]. Критерий применяется при токе $(0,6-1,0)I_{\text{ном}}$

$$\frac{\Delta T_{\text{ном}}}{\Delta T_{\text{раб}}} = \left[\frac{I_{\text{ном}}}{I_{\text{раб}}} \right]^2, \quad (1)$$

где $\Delta T_{\text{ном}}$ – нормированное значение превышения температуры при номинальной нагрузке $I_{\text{ном}}$ (сравнивается с допустимой величиной по справочной таблице); $\Delta T_{\text{раб}}$ – значение превышения температуры при измерении при токе $I_{\text{раб}}$.

Нормированное значение превышения температуры 10–20 °С является начальной стадией развития дефекта для контактного соединения, 20–40 °С – развившимся дефектом, а более 40 °С – аварийным.

Избыточная температура – превышение измеренной температуры контролируемого узла одной фазы над температурой аналогичных узлов других фаз (с наименьшей температурой нагрева) или заведомо исправного узла [16]. Критерий применяется при токе $(0,3-0,6)I_{\text{ном}}$

$$\frac{\Delta T_{0,5}}{\Delta T_{\text{раб}}} = \left[\frac{0,5I_{\text{ном}}}{I_{\text{раб}}} \right]^2, \quad (2)$$

где $\Delta T_{0,5}$ – избыточная температура при токе нагрузки $0,5I_{\text{ном}}$; $\Delta T_{\text{раб}}$ – то же при токе нагрузки, отличном от $0,5I_{\text{ном}}$.

Если при токе нагрузки $0,5I_{\text{ном}}$ значения избыточной температуры контактного соединения составляют 5–10 °С, то это указывает на неисправность, которую следует держать под контролем; при 10–30 °С требуется усиленный контроль и при ≥ 30 °С аварийный дефект требует немедленного устранения.

При обработке ИК-изображения оператор сталкивается с необходимостью определения типа элемента электроустановки на изображении. Например, если производится обработка термограммы силового трансформатора, то вполне вероятно, что на снимке содержатся фрагменты изоляторов, радиаторов, контактных соединений. Как правило, для человека не составляет труда распознать, какой тип элемента электроустановки находится перед ним. Если на изображении находится множество фрагментов разных типов, для каждого из которых требуется определить значение температуры, подлежащей дальнейшему пересчету и сравнениям с нормативами, то задача усложняется, а также повышается риск возникновения ошибок.

В работе предложено использовать при обработке результатов ИК-диагностики сверточные нейронные сети (СНС) для обнаружения на инфракрасных изображениях элементов электроустановок [21–26]. В рамках исследования разработан алгоритм, позволяющий автоматизировать процесс обработки термограмм электрооборудования на основе детектирования объектов с помощью СНС (рис. 1). Алгоритм представлен в формате UML-диаграммы активностей. Применение нейросети обосновывается приоритетом внедрения интеллектуальных технологий в энергетике [1].




Рис. 1. Алгоритм для автоматизированной обработки термограмм электрооборудования: на первом этапе с использованием сверточных нейронных сетей детектируются объекты на ИК-изображении, создаются файлы *.txt и *.csv; на втором этапе создается субматрица температур, определяется температура $T_{\max.\text{пкс}}$, вычисляются $\Delta T_{\text{ном}}$ или $\Delta T_{0,5}$ в зависимости от токовой нагрузки; на третьем этапе производится выбор и проверка условия, делается вывод о наличии и степени неисправности

Fig. 1. Automation algorithm for processing thermograms of electrical equipment: at the first stage, objects are detected in the IR-image using convolutional neural networks, *.txt and *.csv files are created; at the second stage, a temperature submatrix is created, the temperature $T_{\max.\text{pxl}}$ is determined, ΔT_{rated} or $\Delta T_{0,5}$ is calculated depending on the current load; at the third stage, the condition is selected and checked, a conclusion is made about the presence and grade of the defect

На первом этапе оператор загружает на компьютер ИК-изображения в формате *.jpg. Работа алгоритма рассматривается на примере одной термограммы. Из исходного файла *.jpg экспортируется матрица температур, представляющая собой таблицу в формате *.csv. В предварительно созданный файл Mathcad, внутри которого производятся основные расчеты, записывается матрица температуры из таблицы *.csv. Параллельно с этим оператором подготавливается команда для детектирования ИК-изображения. Обученная модель СНС YOLOv5 детектирует объекты на изображениях и формирует файл *.txt. В этом текстовом файле содержится информация в виде строк чисел – каждая строка соответствует одному детектированному объекту. Работа алгоритма рассматривается на примере одного детектированного объекта. Одна строка файла *.txt содержит информацию о классе (ID), координатах центра (X, Y), ширине (W) и высоте (H) детектированного объекта. Параметры ID, X, Y, W, H записываются в файл расчета Mathcad в виде различных переменных. По параметрам из файла *.txt исходное изображение *.jpg кадрируется на несколько фрагментов, каждый из которых содержит только один детектированный объект. Полученные фрагменты сохраняются на диске, но непосредственно в расчетах не участвуют – применяются для оценки результатов детектирования.

На втором этапе производится создание субматрицы температур по данным таблицы *.csv и текстового файла *.txt. Субматрица представляет собой фрагмент исходной матрицы температур *.csv и соответствует местоположению детектированного объекта на изображении *.jpg. Создание субматриц производится в файле расчета Mathcad по формуле «один к одному» – одному детектированному объекту соответствует одна субматрица температур. Далее внутри полученной субматрицы производится поиск максимального числового значения $T_{\text{макс.пкс}}$ – температуры «наиболее нагретого пикселя». Параметр $T_{\text{макс.пкс}}$ назван температурой «наиболее нагретого пикселя» условно – подразумевается связь между наибольшим числовым значением из субматрицы температур ИК-изображения и цветом пикселя RGB-интерпретации этого ИК-изображения.

Параллельно с этим в файл расчета Mathcad заносятся данные о температуре окружающей среды, о рабочем и номинальном токах.

В процессе определения превышения температуры $\Delta T_{\text{раб}}$ при токе $I_{\text{раб}}$ используется $T_{\text{макс.пкс}}$ и температура окружающей среды.

Затем с использованием значений рабочего $I_{\text{раб}}$ и номинального $I_{\text{ном}}$ токов осуществляется определение значения превышения температуры при номинальной нагрузке $\Delta T_{\text{ном}}$ по формуле (1). При детектировании нескольких объектов одного класса для каждого из них в субматрице температур определяется $T_{\text{макс.пкс}}$, а затем имеется возможность определения избыточной температуры $\Delta T_{0,5}$ по формуле (2).

На третьем этапе производится проверка условия. В зависимости от того, под какой нагрузкой работает электрооборудование или токоведущая часть, выбирается превышение температуры $\Delta T_{\text{ном}}$ или избыточная $\Delta T_{0,5}$. Далее выбранное значение сравнивается с пороговым, например для $\Delta T_{\text{ном}} - 10\text{ }^{\circ}\text{C}$, а для $\Delta T_{0,5} - 5\text{ }^{\circ}\text{C}$. Если величина превышения температуры или избыточной температуры превышает пороговое значение,

то производится определение степени неисправности по табл. 4-2 или 4-3 РД 153-34.0-20.363–99. В противном случае – дефект не обнаружен. Алгоритм завершается выводом информации о наличии или отсутствии дефекта, а также о его степени (при наличии).

Для решения задачи обнаружения частей электроустановок выбрана архитектура сверточной нейронной сети YOLOv5 (от англ. You Only Look Once) [27]. Указанное семейство моделей компьютерного зрения позволяет решать задачу детектирования объектов на изображениях или в видеопотоке. В частности, модель YOLOv5 заключает обнаруженные образы в ограничивающие рамки и записывает их координаты в текстовые файлы [28]. Такая технология позволяет не просто визуализировать обнаруженные элементы электроустановок для оператора, но и использовать отдельные регионы термограммы для определения температуры узлов электрооборудования.

Прежде чем использовать модель нейросети YOLOv5 для детектирования элементов электроустановок, необходимо произвести ее обучение на собственном наборе данных. На начальном этапе устанавливается необходимое программное обеспечение и загружаются предобученные веса YOLO. Вместе с этим подготавливается набор изображений для обучения нейросети YOLO с соблюдением соответствующей иерархической структуры [29]. Изображения из обучающего набора подлежат разметке. Для этого используется специализированное программное обеспечение, например OpenLabeling (рис. 2).



Рис. 2. ИК-изображение силового трансформатора с нанесенными вручную граничными рамками в программе OpenLabeling; различный цвет рамок обозначает принадлежность к соответствующим классам: «красный» – «изолятор», «синий» – «контактное соединение», «зеленый» – «радиатор», «бирюзовый» – «расширительный бак»

Fig. 2. IR-image of a power transformer with manually applied bounding boxes in the OpenLabeling tool; different colors of the boxes indicate belonging to the corresponding classes: “red” – “insulator”, “blue” – “contact”, “green” – “radiator”, “turquoise” – “oil conservator”

В результате работы с программой по разметке изображений создается текстовый файл, содержащий информацию о расположении и размерах граничных рамок, а также принадлежности образов внутри этих рамок к определенному классу. Каждый сгенерированный текстовый файл имеет название, позволяющее однозначно сопоставить его с изображением из доступной для разметки выборки. Полученный по такому принципу набор данных может быть использован для обучения нейросети YOLOv5.

По завершении процесса обучения генерируется файл с весами обученной СНС, который используется в дальнейшем для детектирования объектов на изображениях. В рамках данной работы файл весов используется для детектирования узлов электроустановок на ИК-снимках.

Среди параметров, которые определяют качество обучения, обычно преобладают вероятностные параметры. Традиционная матрица ошибок может быть представлена как совокупность четырех событий [30]: правильное обнаружение / True Positive (TP); правильное необнаружение / True Negative (TN); ложная тревога / False Positive (FP), ошибка I рода; пропуск события / False Negative (FN), ошибка II рода. Обычно выделяют три основные метрики для оценки качества обучения:

accuracy – доля правильных результатов работы алгоритма распознавания

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN}; \quad (3)$$

precision – доля объектов, которые названы алгоритмом распознавания положительными и при этом являющиеся таковыми (правильное распознавание)

$$precision = \frac{TP}{TP + FP}; \quad (4)$$

recall – доля объектов, которые названы алгоритмом положительными из всех объектов положительного класса, которые этот алгоритм нашел:

$$recall = \frac{TP}{TP + FN}. \quad (5)$$

Метрику *accuracy* (3) можно использовать в задачах обнаружения объектов одного класса, однако ее редко используют в задачах распознавания объектов разных классов, особенно в тех случаях, когда количество одних объектов существенно больше, чем других (несбалансированная выборка). В этом случае используются метрики *precision* (4) и *recall* (5), которые не зависят от соотношения классов. При этом требуется найти оптимальный баланс между этими двумя метриками. Кроме того, на практике удобнее пользоваться одной метрикой, которая включает в себя две предыдущие [30].

Существует несколько способов объединения метрик *precision* (4) и *recall* (5) в единый критерий качества, например в виде критерия, названно-

го F -мера, который представляет собой среднее гармоническое от значений двух критериев [30]:

$$F_{\beta} = (1 + \beta^2) \cdot \frac{precision \cdot recall}{(\beta^2 \cdot precision) + recall}, \quad (6)$$

где β – коэффициент, определяющий вес параметра *precision* в метрике (при равных значениях веса $\beta = 1$). Чем ближе значение F -меры к 1, тем успешнее работа сети по детектированию объектов.

Результаты исследования и их обсуждение

В работе для использования модели СНС при распознавании частей электроустановок проводилось ее предварительное обучение. Так как задача распознавания частей электроустановок с помощью СНС является узкоспециализированной, для ее решения использовался пользовательский набор данных (custom dataset [31]), включающий в себя ИК-снимки оборудования электрических сетей.

При обучении использовалась методология train-validation-test split, которая предполагает разделение исходного набора данных на три подмножества: the training set – обучающий набор (далее – train), the validation set – проверочный набор (далее – val), the test set – тестовый набор (далее – test) [32].

Для анализа результатов обучения модели нейросети YOLOv5 на пользовательском наборе данных было принято решение сформировать тестовый набор данных (test) из изображений, не входящих в обучающий (train) и проверочный набор (val) на этапе обучения модели. Иными словами, были подобраны изображения, не входящие в выборку, использовавшуюся при обучении модели.

Поскольку в работе рассматривается способ обнаружения на ИК-изображениях электроустановок дефектов отдельных узлов, предпочтительнее проводить оценку модели нейросети именно на тех изображениях, которые содержат дефекты. В тестовую выборку были включены также изображения без объектов для обнаружения, а также изображения, не содержащие дефектов узлов.

В качестве устройства для распознавания объектов авторами выбран персональный компьютер, на котором была произведена установка репозитория YOLOv5 и остальной необходимой инфраструктуры. В каталоге нейросети YOLO создана папка с названием testing_place, в которую затем был загружен отобранный для тестирования набор ИК-изображений.

Необходимо отметить, что для создания набора данных были выбраны ИК-изображения размером 800×600 пикселей. При подаче на вход нейросети YOLO происходит их масштабирование до 896×896 пикселей [28]. Для обучения модели YOLOv5 подготовлены 468 изображений (samples) в качестве тренировочной выборки. Также выбран размер пакета (batch), равный 8, а количество эпох обучения (epochs) было принято равным 16 [28].

Обучение нейросети YOLO производится по команде, включающей в себя указанные выше параметры (рис. 3).

```
!python train.py --img 896 --batch 8
--epochs 16 --data
'/content/drive/MyDrive/yolov5_exper
imental/custom_dataset/dataset.yaml'
--weights
'/content/drive/MyDrive/yolov5_exper
imental/custom_dataset/yolov5x.pt' -
--nosave --cache
```

Рис. 3. Команда на обучение модели нейросети YOLOv5: “--img” – размер изображения, подаваемого на вход YOLO, каждое изображение в формате 896×896 пикселей, параметр должен быть кратен числу 32; параметр “--batch” определяет число картинок, которые обработает нейросеть до обновления модели; “--epochs” – количество эпох, то есть полных проходов алгоритма через тренировочный набор данных; “--data” указывает путь к файлу конфигурации набора данных в формате “*.yaml”; “--weights” указывает путь к файлу предобученной модели нейросети в формате “*.pt”

Fig. 3. Training command for YOLOv5 neural network model: “--img” is the size of the image to the YOLO input: each image is in the format 896×896 pixels, the parameter must be a multiple of 32; the “--batch” parameter determines the number of pictures that the neural network will process before updating the model; “--epochs” – the number of epochs or complete runs of the algorithm through the training data set; “--data” – specifies the path to the data set configuration file in the “*.yaml” format; “--weights” – specifies the path to the file of the pre-trained neural network model in the “*.pt” format

Следующий шаг – вызов командной строки в каталоге yolov5-master и ввод команды на распознавание группы изображений (рис. 4).

```
C:\Experimental\yolov5-master>python detect.py --weights runs\train\last\last.pt --save-txt --save-crop --img 416
--conf 0.1 --source c:\Experimental\yolov5-master\testing_place\
detect: weights=[runs\train\last\last.pt], source=c:\Experimental\yolov5-master\testing_place, data=data\coc
o128.yaml, imgsz=[416, 416], conf thres=0.1, iou thres=0.45, max_det=1000, device=, view_img=False, save_txt=True,
save_conf=False, save_crop=True, nosave=False, classes=None, agnostic_nms=False, augment=False, visualize=False,
update=False, project=runs\detect, name=exp, exist_ok=False, line_thickness=3, hide_labels=False, hide_conf=False,
half=False, dnn=False, vid_stride=1
YOLOv5 2023-2-4 Python-3.9.0 torch-1.13.1+cu117 CUDA:0 (NVIDIA GeForce GTX 1050 Ti, 4096MiB)

Fusing layers...
Model summary: 322 layers, 86193601 parameters, 0 gradients, 203.8 GFLOPs
image 1/15 C:\Experimental\yolov5-master\testing_place\IR_0724.jpg: 320x416 3 contacts, 89.7ms
image 2/15 C:\Experimental\yolov5-master\testing_place\IR_1450.jpg: 320x416 3 contacts, 80.0ms
image 3/15 C:\Experimental\yolov5-master\testing_place\IR_3840.jpg: 320x416 1 contact, 79.9ms
image 4/15 C:\Experimental\yolov5-master\testing_place\IR_7249.jpg: 416x320 (no detections), 70.4ms
image 5/15 C:\Experimental\yolov5-master\testing_place\IR_7251.jpg: 320x416 1 contact, 1 radiator, 70.1ms
image 6/15 C:\Experimental\yolov5-master\testing_place\IR_7252.jpg: 416x320 (no detections), 70.3ms
image 7/15 C:\Experimental\yolov5-master\testing_place\IR_7266.jpg: 416x320 1 contact, 70.3ms
image 8/15 C:\Experimental\yolov5-master\testing_place\IR_7269.jpg: 320x416 (no detections), 79.8ms
image 9/15 C:\Experimental\yolov5-master\testing_place\IR_7270.jpg: 320x416 3 contacts, 80.5ms
image 10/15 C:\Experimental\yolov5-master\testing_place\IR_7284.jpg: 416x320 2 contacts, 65.2ms
image 11/15 C:\Experimental\yolov5-master\testing_place\IR_7289.jpg: 320x416 2 contacts, 70.0ms
image 12/15 C:\Experimental\yolov5-master\testing_place\IR_7437.jpg: 320x416 3 insulators, 1 contact, 70.2ms
image 13/15 C:\Experimental\yolov5-master\testing_place\IR_7497.jpg: 320x416 4 insulators, 3 contacts, 70.3ms
image 14/15 C:\Experimental\yolov5-master\testing_place\IR_7501.jpg: 320x416 1 insulator, 2 contacts, 80.5ms
image 15/15 C:\Experimental\yolov5-master\testing_place\IR_7503.jpg: 320x416 1 insulator, 3 contacts, 73.0ms
Speed: 0.0ms pre-process, 74.7ms inference, 2.7ms NMS per image at shape (1, 3, 416, 416)
Results saved to runs\detect\exp47
12 labels saved to runs\detect\exp47\labels
```

Рис. 4. Результат выполнения команды детектирования объектов на изображениях из тестовой папки; для каждого обработанного ИК-изображения присутствует запись о наличии обнаруженных образов, включая индикаторы их принадлежности к классу

Fig. 4. The result of command execution for object detection in images from the test folder; for each processed IR-image, there is a record of the presence of detected images, including indicators of their belonging to a class

Необходимо отметить, что для удобства восприятия данных здесь и далее в качестве примера тестовой выборки используются 15 изображений.

Для расчетов основных метрик оценки качества обучения модели нейросети YOLOv5 необходимо выяснить количество событий TP, FP, FN матрицы ошибок, соответствующее каждому изображению из тестовой выборки (табл. 1).

Таблица 1

Оценка наличия событий TP, FP, FN в тестовой выборке
Evaluation of the presence of TP, FP, FN events in the test sample

Номер/No	TP	FP	FN	Имя/Name
1	3	0	0	0724
2	3	0	0	1450
3	1	0	2	3840
4	0	0	3	7249
5	1	1	2	7251
6	0	0	3	7252
7	1	0	0	7266
8	0	0	0	7269
9	3	0	0	7270
10	1	0	0	7284
11	1	1	0	7289
12	4	0	1	7437
13	6	1	0	7497
14	4	0	3	7501
15	4	0	5	7503
Сумма	32	3	19	–

Результаты расчета метрик для оценки качества обучения модели нейросети YOLOv5 приведены ниже.

Доля объектов, которые названы алгоритмом распознавания положительными и при этом являются таковыми:

$$precision = \frac{32}{32 + 3} = 0,914.$$

Доля объектов, которые названы алгоритмом положительными из всех объектов положительного класса, которые этот алгоритм обнаружил:

$$recall = \frac{32}{32 + 19} = 0,627.$$

F-мера, которая представляет собой среднее гармоническое от значений двух критериев *precision* и *recall* (принимая значение весового коэффициента $\beta = 1$):

$$F_{\beta} = (1 + 1^2) \cdot \frac{0,914 \cdot 0,627}{(1^2 \cdot 0,914) + 0,627} = 0,744.$$

Величина $F_{\beta} = 0,744$, что свидетельствует о способности модели успешно детектировать объекты.

В результате получена модель СНС, способная детектировать узлы электроустановок. Далее обученная модель YOLOv5 используется в разработанном авторами алгоритме, приведенном на рис. 1.

В рамках первого этапа СНС детектирует детали электроустановок на ИК-изображении: выделяет области, в которых находится различное оборудование. В результате создается *.txt файл с информацией о расположении и размерах граничных рамок или ярлыков (от англ. labels), определяет класс детектированного элемента (рис. 5).




Рис. 5. Детектированное нейросетью YOLOv5 инфракрасное изображение трех контактных соединений; заметно превышение температуры правого контактного соединения над другими

Fig. 5. An infrared image of three contact joints detected by the YOLOv5 neural network; the temperature of the right contact joint is noticeably higher than others

Второй этап направлен на обработку данных, полученных при детектировании и из других внешних источников. Ключевым процессом является создание сумматрицы температуры детектированного объекта.

При представлении термограммы в виде матрицы температур по параметрам из файла *.txt выделяется субматрица, содержащая температуры внутри детектированной области. В конце этапа происходит поиск максимального значения температуры $T_{\text{макс.пкс}}$ для каждого детектированного

образа на ИК-снимке. Упрощенная реализация этого процесса представлена в Mathcad-документе (рис. 6).




Рис. 6. Создание субматрицы по результатам детектирования YOLOv5: по параметрам из файла *.txt определяется максимальная температура объекта (фазы C)

Fig. 6. Creation of the submatrix based on YOLOv5 detection results: the maximum temperature of the object (phase C) is determined using parameters from the *.txt file

В рамках третьего этапа в зависимости от значений температур, полученных при пересчете по формулам (1) или (2), делается вывод о степени развития дефекта с учетом таблиц браковочных нормативов 4-2 и 4-3 из РД 153-34.0-20.363–99. На данном этапе также возможна проверка критерия превышения наибольшего допустимого значения температуры нагрева электрооборудования и токоведущих частей в соответствии с таблицей 4-1 РД 153-34.0-20.363–99 (на рис. 1 не показан).

Пересчет температуры осуществляется на примере ИК-изображения контактного соединения, которое было детектировано нейросетью YOLO (рис. 5). Для болтовых контактных соединений из меди, алюминия и их сплавов без покрытия в воздухе наибольшее допустимое значение температуры нагрева составляет 90 °C, а наибольшее допустимое значение превышения температуры 50 °C при значении эффективной температуры окружающего воздуха, принимаемой равной 40 °C [16].

В результате обработки субматрицы температур, соответствующей правому перегретому контактному соединению на рис. 5 (фазе C), была определена температура наиболее нагретого пикселя, равная 122,9 °C. Произведем сравнение величин температур: $T_{\text{пред.нагр}} = 90 \text{ °C} < T_{\text{макс.пкс}} = 122,9 \text{ °C}$. Очевидно, что температура наиболее нагретого пикселя превышает наибольшее допустимое значение температуры нагрева ($T_{\text{пред.нагр}}$ – предельная тем-

пература нагрева по таблице 4-1 РД 153-34.0-20.363–99), что однозначно свидетельствует о наличии дефекта в фазе С.

Рассмотрим фазу А (крайний левый контакт на рис. 5) с температурой наиболее нагретого пикселя, равной 46,7 °С. Температура окружающего воздуха принимается равной 23,0 °С. Пересчитаем нормированное значение превышения температуры при номинальной нагрузке. Предположим, что контакт находится под нагрузкой 80 % от номинальной:

$$\Delta T_{\text{ном ф.А}} = \Delta T_{\text{раб ф.А}} \cdot \left[\frac{I_{\text{ном}}}{I_{\text{раб}}} \right]^2 = (46,7 - 23) \cdot \left[\frac{100}{80} \right]^2 = 37 \text{ } ^\circ\text{С}. \quad (7)$$

Превышение температуры фазы А в этом случае составляет 37,0 °С, что позволяет классифицировать указанное контактное соединение как дефектное со степенью неисправности 2 в соответствии с таблицей 4-2 РД 153-34.0-20.363–99 (развившийся дефект, учащенный контроль 1 раз в месяц, устранение дефекта при первой необходимости) [16].

Новизна предложенного авторами решения заключается в снижении влияния человеческого фактора за счет автоматического детектирования оборудования сверточной нейронной сетью YOLOv5 и пересчета критериев оценки в зависимости от токовой нагрузки, что позволяет выявить не только развившиеся дефекты, но и обнаружить начальную стадию возникновения неисправностей.

ВЫВОДЫ

1. Предложенная математическая модель системы критериев оценки требует фиксирования не только данных, полученных из ИК-изображений электросетевого оборудования, но и токовой нагрузки и температуры окружающего воздуха для пересчета $\Delta T_{\text{ном}}$ или $\Delta T_{0,5}$ узла электроустановки или контактного соединения.

2. Разработанный алгоритм обработки термограмм электрооборудования на базе СНС YOLOv5 позволяет автоматизировать детектирование объектов на изображениях, найти температуру наиболее нагретой точки и определить наличие дефекта, а также степень неисправности оборудования.

3. Программная реализация разработанного алгоритма обеспечивает возможность обработки больших объемов данных и сокращает время анализа результатов ИК-диагностики. Это способствует увеличению частоты проведения актов контроля и повышению надежности работы электрооборудования.

4. Обученная на пользовательском наборе данных сверточная нейронная сеть обладает метриками: $precision = 0,914$, $recall = 0,627$ и $F_\beta = 0,744$, что свидетельствует о ее высокой эффективности в задаче детектирования объектов на термограммах оборудования электрических сетей.

ЛИТЕРАТУРА

1. Энергетическая стратегия Российской Федерации на период до 2035 года: Распоряжение Правительства Российской Федерации от 9 июня 2020 г., № 1523-п // Министерство энергетики РФ. URL: <https://minenergo.gov.ru/ministry/energy-strategy> (дата обращения: 26.09.2024).
2. Реклоузер SMART 35 – Статистические данные по сетям и центрам питания 35 кВ в России // Elec.ru – электротехнический интернет-портал. URL: <https://www.elec.ru/viewer?url=/files/2017/05/03/Reklouzer-SMART35.pdf> (дата обращения: 26.09.2024).
3. Диагностика электрооборудования электрических станций и подстанций / А. И. Хальясмаа, С. А. Дмитриев, С. Е. Кокин, Д. А. Глушков. Екатеринбург: Изд-во Урал. ун-та, 2015. 64 с.
4. Секретарев, Ю. А. Модели текущего технического состояния электрооборудования для расчета надежности систем электроснабжения монопотребителей в рамках риск-ориентированного подхода / Ю. А. Секретарев, А. А. Горшунов // Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ. 2025. Т. 68, № 1. С. 17–34. <https://doi.org/10.21122/1029-7448-2025-68-1-17-34>.
5. Хлебцов, А. П. Развитие методов и устройств диагностики силового электрооборудования трансформаторных подстанций / А. П. Хлебцов, Л. Х. Зайнутдинова, А. Н. Шилин // Электротехнические и информационные комплексы и системы. 2020. Т. 16, № 3. С. 14–27. <https://doi.org/10.17122/1999-5458-2020-16-3-14-27>.
6. Кувшинов, А. А. Диагностика технического состояния электрооборудования в системах электроснабжения: учеб. пособие / А. А. Кувшинов, В. П. Тараканов. Тольятти: ТГУ, 2016. 90 с.
7. Сви, П. М. Методы и средства диагностики оборудования высокого напряжения / П. М. Сви. М.: Энергоатомиздат, 1992. 240 с.
8. Максудов, Д. В. Методы селекции сигналов частичных разрядов в изоляции силовых трансформаторов / Д. В. Максудов, Е. М. Федосов // Вестник УГАТУ. 2009. Т. 12, № 2. С. 138–143.
9. Вдовико, В. П. Частичные разряды в диагностировании высоковольтного оборудования / В. П. Вдовико. М.: Наука, 2007. 156 с.
10. Кучинский, Г. С. Частичные разряды в высоковольтных конструкциях / Г. С. Кучинский. Л.: Энергия, Ленингр. отд-ние, 1979. 224 с.
11. Гавриленко, А. В. Методика вибрационного обследования силовых трансформаторов / А. В. Гавриленко, А. П. Долин. URL: https://megaom.ucoz.ru/_ld/0/40____.pdf.
12. Пузина, Е. Ю. Системы мониторинга силовых трансформаторов тяговых подстанций / Е. Ю. Пузина, А. Г. Туйгунова, И. А. Худоногов. Иркутск: ИрГУПС, 2020. 184 с.
13. Вавилов, В. П. Инфракрасная термография и тепловой контроль / В. П. Вавилов. М.: ИД Спектр, 2009. 544 с.
14. Власенко, С. А. Мониторинг и диагностика болтовых электрических соединений системы тягового электроснабжения: монография / С. А. Власенко, И. В. Игнатенко. Хабаровск: Изд-во ДВГУПС, 2022. 107 с.
15. Коренчиак, Д. Тепловое измерение и его применение для диагностики масляных трансформаторов распределительных сетей. / Д. Коренчиак, М. Себок, М. Гуттен // Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ. 2019. Т. 62, № 6. С. 583–594. <https://doi.org/10.21122/1029-7448-2019-62-6-583-594>.
16. РД 153-34.0-20.363–99 Основные положения методики инфракрасной диагностики электрооборудования и ВЛ. М.: СПО ОРГРЭС, 2001. 136 с.
17. РД 34.45-51.300–97 Объем и нормы испытаний электрооборудования. М.: Изд-во НЦ ЭНАС, 2004. 256 с.
18. Величко, В. А. Предложения по совершенствованию системы критериев оценки состояния электрооборудования по результатам инфракрасного контроля / В. А. Величко, А. Д. Чернова // Проблемы и перспективы развития электроэнергетики и электротехники: материалы V Всерос. науч.-практ. (с междунар. участием) конф., посвящ. празднованию 55-летия КГЭУ. Казань: КГЭУ, 2023. Т. 2. С. 219–228.

19. Лебедь, Н. И. Имитационное моделирование автоматизированных систем управления технологических процессов в электроэнергетике и АПК / Н. И. Лебедь. Волгоград: ФГБОУ ВО Волгоградский ГАУ, 2022. 88 с.
20. Standard for Infrared Inspection of Electrical Systems & Rotating Equipment. NJ: Infraspection Institute, 2016. URL: <https://www.atlanticleak.com/wp-content/uploads/2019/08/Standard-for-Infrared-Inspection-of-Electrical-systems-and-Rotating-Equipment.pdf> (date of access 26.09.2024).
21. Kim, J. S. Infrared Thermal Image-Based Sustainable Fault Detection for Electrical Facilities / J. S. Kim, K. N. Choi, S. W. Kang // *Sustainability*. 2021. Vol. 13, № 2. P. 557. <https://doi.org/10.3390/su13020557>.
22. Xu, F. Research on Power Equipment Troubleshooting Based on Improved AlexNet Neural Network / F. Xu, S. Liu, and W. Zhang // *Journal of Measurements in Engineering*. 2024. Vol. 12, No 1. P. 162–182. <https://doi.org/10.21595/jme.2023.23786>.
23. Wu, J. An Infrared Image Detection of Power Equipment Based on Super-Resolution Reconstruction and YOLOv4 / J. Wu, X. Li, Y. Zhou // *The Journal of Engineering*. 2022. Vol. 2022, No 10. P. 1006–1016. <https://doi.org/10.1049/tje2.12187>.
24. Efficient Real-Time Detection of Electrical Equipment Images Using a Lightweight Detector Model / C. Qi, Z. Chen, X. Chen [et al.] // *Frontiers in Energy Research*. 2023. Vol. 11. P. 1291382. <https://doi.org/10.3389/fenrg.2023.1291382>.
25. Electric Substation Inspection: YOLOv5 in Hotspot Detection Through Thermal Imaging / D. A. Pérez-Aguilar, J. M. Pérez-Aguilar, A. P. Pérez-Aguilar [et al.] // *Ingenius, Revista Ciencia y Tecnología*. 2024. Vol. 31. P. 43–54. <https://doi.org/10.17163/ings.n31.2024.04>.
26. 王媛彬. 基于自适应特征融合和注意力机制的变电设备红外图像识别 / 王媛彬, 吴冰超 // *电子与信息学报*. 2024. Vol. 46, No 9. P. 3749–3756 = Wang, Y., Infrared Image Recognition of Substation Equipment Based on Adaptive Feature Fusion and Attention Mechanism / Y. Wang, B. Wu // *Journal of Electronics & Information Technology*. 2024. Vol. 46, No 9. P. 3749–3756. <https://doi.org/10.11999/JEIT231047>.
27. Ahmed, K. R. Smart Pothole Detection Using Deep Learning Based on Dilated Convolution / K. R. Ahmed // *Sensors*. 2021. Vol. 21, No 24. P. 8406. <https://doi.org/10.3390/s21248406>.
28. Величко, В. А. Программная реализация алгоритма по автоматизации тепловизионной диагностики оборудования подстанций с использованием нейросети YOLOv5 / В. А. Величко, А. Д. Косенко // *Университетский комплекс как региональный центр образования, науки и культуры: материалы Всерос. науч.-метод. конф., Оренбург, 01–03 февр. 2024 г. Оренбург: Оренбургский государственный университет, 2024. С. 1209–1214.*
29. Чернова, А. Д. Разметка изображений элементов электроустановок для обучения нейросети YOLOv5 / А. Д. Чернова, В. А. Величко // *Энергетика: состояние, проблемы, перспективы: материалы XIV Всероссийской науч.-техн. конф., Оренбург. Оренбург: Оренбург. гос. ун-т, 2023. С. 217–222.*
30. Ярышев, С. Н. Технологии глубокого обучения и нейронных сетей в задачах видеоанализа / С. Н. Ярышев, В. А. Рыжова. СПб.: Ун-т ИТМО, 2022. 82 с.
31. Обучение YOLOv5 на пользовательских данных // *Ultralytics*. URL: https://docs.ultralytics.com/yolov5/tutorials/train_custom_data/ (дата обращения: 11.01.2024).
32. Gomed, E. The Significance of Train-Validation-Test Split in Machine Learning / E. Gomed // *Medium*. URL: <https://medium.com/@evertongomed/the-significance-of-train-validation-test-split-in-machine-learning-91ee9f5b98f3>. Publ. date: 28.08.2023.

Поступила 20.12.2024 Подписана в печать 26.02.2025 Опубликована онлайн 31.07.2025

REFERENCES

1. The Energy Strategy of the Russian Federation for the Period up to 2035 Approved by the Decree of the Government of the Russian Federation, June 9, 2020, No 1523-R. *Ministry of Energy of the Russian Federation*. Available at: <https://minenergo.gov.ru/ministry/energy-strategy> (accessed 26 September 2024) (in Russian).

2. SMART 35 Recloser: An Innovative Solution for Upgrading Power Centers and Improving the Reliability of 35 kV Networks. *Elec.ru – Electrotechnical Internet Portal*. Available at: <https://www.elec.ru/viewer?url=/files/2017/05/03/Reklouzer-SMART35.pdf> (accessed 26 September 2024) (in Russian).
3. Khalyasmaa A. I., Dmitriev S. A., Kokin S. E., Glushkov D. A. (2015) *Diagnostics of Electrical Equipment of Power Stations and Substations*. Ekaterinburg, Ural University Publishing House, 64 (in Russian).
4. Sekretarev Yu. A., Gorshunov A. A. (2025) Models of the Current Technical Condition of Electrical Equipment for Calculating the Reliability of Power Supply Systems for Single-Users within the Framework of a Risk-Based Approach. *Energetika. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, 68 (1), 17–34. <https://doi.org/10.21122/1029-7448-2025-68-1-17-34> (in Russian).
5. Khlebtsov A. P., Zainutdinova L. KH., Shilin A.N. (2020) Development of Methods and Devices for Diagnostics of Power Electrical Equipment of Transformer Substations; *Elektrotekhnicheskiye i informatsionnyye komplekсы i sistemy = Electrical and data processing facilities and systems*, 16 (3), 14–27. <https://doi.org/10.17122/1999-5458-2020-16-3-14-27> (in Russian).
6. Kuvshinov A. A., Tarakanov V. P. (2016) *Diagnostics of the Technical Condition of Electrical Equipment in Power Supply Systems*. Togliatti, Togliatti State University. 90 (in Russian).
7. Svi P. M. (1992) *Methods and Means of Diagnostics of High Voltage Equipment*. Moscow, Energoatomizdat Publ. 240 (in Russian).
8. Maksudov D. V., Fedosov E. M. (2009) Methods of Selection of Partial Discharge Signals in Isolation of Power Transformers. *Vestnik USATU*, 12 (2), 138–143 (in Russian).
9. Vdoviko V. P. (2007) *Partial Discharges in the Diagnosis of High-Voltage Equipment*. Moscow, Nauka Publ. 156 (in Russian).
10. Kuchinskiy G. S. (1979) *Partial Discharges in High Voltage Structures*. Leningrad, Energiya Publ., Leningrad Branch. 224 (in Russian).
11. Gavrilenko A. V., Dolin A. P. (2004) Technique of Vibration Inspection of Power Transformers. Available at: https://megaom.ucoz.ru/_ld/0/40_____.pdf (in Russian).
12. Puzina E. Yu., Tuygunova A. G., Khudonogov I. A. (2020) *Systems of Monitoring of Power Transformers of Traction Substations*. Irkutsk, Irkutsk State Transport University (IrGUPS). 184 (in Russian).
13. Vavilov V. P. (2009) *Infrared Thermography and Thermal Control*. Moscow, Spektr Publishing House. 544 (in Russian).
14. Vlasenko S. A., Ignatenko I. V. (2022) *Monitoring and Diagnostics of Bolted Electrical Connections of the Traction Power Supply System*. Khabarovsk, Far Eastern State Transport University (FESTU) Publishing House. 107 (in Russian).
15. Korenciak D., Sebok M., Gutten M. (2019) Thermal Measurement and its Application for Diagnostics of Distribution Oil Transformers. *Energetika. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, 62 (6), 583–594. <https://doi.org/10.21122/1029-7448-2019-62-6-583-594> (in Russian).
16. RD [Guidance Document] 153-34.0-20.363-99. *Method for Infrared Inspection of Electrical Equipment and Overhead Lines*. Moscow, SPO ORGRES, 2001. 136 (in Russian).
17. RD [Guidance Document] 34.45-51.300-97. *Scope and Standards for Tests of Electrical Equipment*. Moscow, IC ENAS Publishing House, 2004. 256 (in Russian).
18. Velichko V. A., Chernova A. D. (2023) Proposals for Improving the Criteria System for Assessing the Condition of Electrical Equipment Based on the Results of Infrared Control. *Problemy i perspektivy razvitiya elektroenergetiki i elektrotekhniki: materialy V Vseros. nauch.-prakt. (s mezhdunar. uchastiem) konf., posvyashch. prazdnovaniyu 55-letiya KGEU. T. 2 [Problems and Prospects of Development of the Electric Power Industry and Electrical Engineering]*: Proceedings V All-Russian Scientific and Practical Conference (with International

- Participation) Dedicated to the Celebration of the 55th Anniversary of the KGEU. Vol. 2]. Kazan, Kazan StatePower Engineering University, 219–228 (in Russian).
19. Lebed' N. I. (2022) *Simulation Modeling of Automated Control Systems for Technological Processes in the Electric Power Industry and the Agro-industrial Complex*. Volgograd, Volgograd State Agrarian University Publ. 88 (in Russian).
20. *Standard for Infrared Inspection of Electrical Systems & Rotating Equipment*. NJ, Infrasppection Institute, 2016. Available at: <https://www.atlanticleak.com/wp-content/uploads/2019/08/Standard-for-Infrared-Inspection-of-Electrical-systems-and-Rotating-Equipment.pdf> (accessed 26 September 2024).
21. Kim J. S., Choi K. N., Kang S. W. (2021) Infrared Thermal Image-Based Sustainable Fault Detection for Electrical Facilities. *Sustainability*, 13 (2), 557. <https://doi.org/10.3390/su13020557>.
22. Xu F., Liu S., Zhang W. (2024) Research on Power Equipment Troubleshooting Based on Improved AlexNet Neural Network. *Journal of Measurements in Engineering*, 12 (1), 162–182, <https://doi.org/10.21595/jme.2023.23786>.
23. Wu J., Li X., Zhou Y. (2022) An infrared image detection of power equipment based on super-resolution reconstruction and YOLOv4. *The Journal of Engineering*, 2022, 1006–1016. <https://doi.org/10.1049/tje2.12187>.
24. Qi C., Chen Z., Chen X., Bao Y., He T., Hu S., Li J., Liang Y., Tian F., Li M. (2023). Efficient Real-time Detection of Electrical Equipment Images Using a Lightweight Detector Model. *Frontiers in Energy Research*, 11, 1291382. <https://doi.org/10.3389/fenrg.2023.1291382>.
25. Pérez-Aguilar D. A., Pérez-Aguilar J. M., Pérez-Aguilar A. P., Risco-Ramos R. H., Malpica-Rodríguez M. E. (2024) Electric Substation Inspection: YOLOv5 in Hotspot Detection Through Thermal Imaging. *Ingenius. Revista Ciencia y Tecnología*, 31, 43–54. <https://doi.org/10.17163/ings.n31.2024.04>.
26. Wang Y., Wu B. (2024) Infrared Image Recognition of Substation Equipment Based on Adaptive Feature Fusion and Attention Mechanism. *Journal of Electronics & Information Technology*, 46 (9), 3749–3756 (in Chinese). <https://doi.org/10.11999/JEIT231047>.
27. Ahmed K. R. (2021). Smart Pothole Detection Using Deep Learning Based on Dilated Convolution. *Sensors*, 21 (24), 8406. <https://doi.org/10.3390/s21248406>.
28. Velichko V. A., Kosenko A. D. (2024) Software Implementation of an Algorithm for Automating Thermal Imaging Diagnostics of Substation Equipment Using the YOLOv5 Neural Network. *Universitetskii kompleks kak regional'nyi tsentr obrazovaniya, nauki i kul'tury: materialy Vseros. nauch.-metod. konf., Orenburg, 01–03 fevr. 2024 g.* [University Complex as a Regional Center of Education, Science and Culture. Proceedings of the All-Russian Scientific and Methodological Conference, Orenburg, 01–03 February 2024.]. Orenburg, Orenburg State University, 1209–1214 (in Russian).
29. Chernova A. D., Velichko V. A. (2023) Markup of Images of Electrical Installation Elements for Training the YOLOv5 Neural Network. *Energetika: sostoyanie, problemy, perspektivy: materialy XIV Vserossiiskoi nauch.-tekhn. konf., Orenburg* [Power Engineering: State, Problems, Prospects: Proceedings of the XIV All-Russian Scientific and Technical Conference]. Orenburg, Orenburg State University, 217–222 (in Russian).
30. Yaryshev S. N., Ryzhova V. A. (2022) *Deep Learning and Neural Network Technologies in Video Analysis Tasks*. St. Petersburg, ITMO University. 82 (in Russian).
31. Train YOLOv5 on Custom Data. *Ultralytics*. Available at: https://docs.ultralytics.com/yolov5/tutorials/train_custom_data/ (accessed 11 January 2024) (in Russian).
33. Gomede E. (28 August 2023) The Significance of Train-Validation-Test Split in Machine Learning. *Medium*. Available at: <https://medium.com/@evertongomede/the-significance-of-train-validation-test-split-in-machine-learning-91ee9f5b98f3>.