

УДК 621.3.051; 004.032.26

DOI: [10.26102/2310-6018/2021.35.4.035](https://doi.org/10.26102/2310-6018/2021.35.4.035)

Детектирование дефектов неисправных элементов линий электропередач при помощи нейронных сетей семейства YOLO

М.А. Астапова✉, М.Ю. Уздяев

*Санкт-Петербургский Федеральный исследовательский центр
Российской академии наук,
Санкт-Петербургский институт информатики и автоматизации Российской
академии наук,
Санкт-Петербург, Российская Федерация
marinaastapova55@gmail.com✉*

Резюме. В настоящее время визуальная диагностика состояния элементов линий электропередач (ЛЭП) является сложной и трудоемкой процедурой. В целях повышения эффективности и снижения трудозатрат этой процедуры наиболее перспективным является применение беспилотных летательных аппаратов, оборудованных системами компьютерного зрения, выполняющих автоматическую детекцию поврежденных элементов ЛЭП. Для повышения качества детекции поврежденных участков ЛЭП системами компьютерного зрения наиболее перспективно применение современных глубоких нейросетевых архитектур. Однако, вопрос применения таких архитектур в обозначенной задаче недостаточно освещен в современных исследованиях. Особо остро стоит вопрос сравнения различных нейронных сетей и выявления значимых различий в их результатах. Данная статья посвящена сравнительному анализу современных нейросетевых детекторов YOLOv3 и YOLOv4, а также их сокращенных версий (YOLOv3-tiny и YOLOv4-tiny) в задаче детекции дефектов ЛЭП. Приводятся результаты обучения этих детекторов на наборе данных CPLID, а также статистическое сравнение результатов YOLOv3 и YOLOv4 посредством процедуры кросс-валидации. Детекторами были показаны высокие результаты точности детекции ($mAP@0,50=0,97\pm0,03$; $mAP@0,75=0,78\pm0,04$), а также статистически значимые различия в этих результатах. Сравнительный анализ результатов показал, что применение более простой нейронной сети YOLOv3 является более перспективным в задаче детекции дефектов ЛЭП.

Ключевые слова: беспилотный летательный аппарат, обследование высоковольтных линий электропередач, обнаружение неисправностей, определение дефектов, нейронные сети, YOLOv3, YOLOv4.

Благодарности: работа выполнена при финансовой поддержке РФФИ в рамках научного проекта № 20-08-01056 А.

Для цитирования: Астапова М.А., Уздяев М.Ю. Детектирование дефектов неисправных элементов линий электропередач при помощи нейронных сетей семейства YOLO. *Моделирование, оптимизация и информационные технологии*. 2021;9(4). Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=1115> DOI: 10.26102/2310-6018/2021.35.4.035

Detection of defects in faulty elements of power lines using neural networks of YOLO

М.А. Astapova✉, M.Y. Uzdiaev

*St. Petersburg Federal Research Center of the Russian Academy of Sciences,
St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences,*

*Laboratory of Autonomous Robotic Systems, St. Petersburg, Russian Federation
marinaastapova55@gmail.com*

Abstract: Currently, visual state diagnostics of power transmission lines (PTL) elements is a complex and time-consuming procedure. In order to increase the efficiency and reduce the labor costs of this undertaking, the most promising measure is the use of unmanned aerial vehicles equipped with computer vision systems that automatically detect damaged elements of power lines. For the purposes of improving the detection quality of power lines damaged areas by computer vision systems, the application of modern deep neural network architectures would be most effective. However, the problem of utilizing such architectures in the aforementioned task is not sufficiently covered in modern research. The issue of comparing various neural networks and identifying substantial differences in their results is especially acute. This article is devoted to a comparative analysis of modern neural network detectors YOLOv3 and YOLOv4 as well as their reduced versions (YOLOv3-tiny and YOLOv4-tiny) in terms of detecting power transmission line defects. The results of training these detectors on the CPLID dataset are presented along with statistical comparison of the YOLOv3 and YOLOv4 results by means of the cross-validation procedure. The detectors displayed high rates of detection accuracy ($mAP @ 0.50 = 0.97 \pm 0.03$; $mAP @ 0.75 = 0.78 \pm 0.04$) and statistically significant distinctions in these results. A comparative analysis of the findings has revealed that the employment of a simpler neural network YOLOv3 has more potential when applied to detection of power transmission line defects.

Keywords: unmanned aerial vehicle, inspection of high-voltage power lines, fault detection, defect detection, neural networks, YOLOv3, YOLOv4.

Acknowledgments: This research was carried out with the financial support from the Russian Foundation for Basic Research within the framework of scientific project No. 20-08-01056 A.

For citation: Astapova M.A., Uzdiaev M.Y. Detection of defects in faulty elements of power lines using neural networks of YOLO. *Modeling, Optimization and Information Technology*. 2021;9(4). Available from: <https://moitvvt.ru/ru/journal/pdf?id=1115> DOI: 10.26102/2310-6018/2021.35.4.035(In Russ).

Введение

Сегодня многие электроэнергетические компании регулярно проводят визуальный осмотр своих электрических сетей, чтобы спланировать необходимый ремонт или замену поврежденных или отказавших элементов. Проверка линий электропередач (ЛЭП) обычно выполняется с использованием традиционных методов, таких как пеший патруль, вертолетные обследования и сервисные роботы. Однако, такая организация работы по контролю ЛЭП является низкоэффективной с точки зрения временных, денежных, трудозатрат, а также в связи с возможными рисками для здоровья рабочих, непосредственно выполняющих проверку элементов ЛЭП. Это объясняет необходимость разработки современных автоматизированных систем мониторинга состояния элементов ЛЭП.

В последние годы происходит бурное развитие в области технологий аккумуляторных батарей и топливных элементов [1], датчиков и компонентов [2], а также компьютерного зрения. Это существенно расширяет возможности мониторинга состояния элементов ЛЭП с помощью беспилотных летательных аппаратов (БПЛА) [3].

С развитием технологий управления БПЛА и технологий компьютерного зрения задача мониторинга состояния элементов ЛЭП сводится к разработке специализированных методов анализа аэрофотоснимков, которые должны выявлять на аэрофотоснимках области, содержащие поврежденный элемент ЛЭП, что в итоге сводится к задаче детекции интересующего нас класса дефектных объектов. В этой области наиболее перспективными являются методы извлечения и анализа отличительных признаков объектов (feature-based methods), в особенности, методы,

основанные на технологиях машинного обучения. В свою очередь, наиболее перспективными методами машинного обучения для решения задач компьютерного зрения являются методы глубокого обучения [4], основанные на применении сложных нейросетевых архитектур. Наиболее распространенными решениями задачи детекции визуальных объектов являются методы, основанные на применении сверточных нейронных сетей (СНС), к которым относятся R-CNN [5], Fast R-CNN [6], Faster R-CNN [7], YOLO [8], R-FCN [9], SSD [10]. Все эти методы как раз направлены на решение задачи детекции визуальных объектов на изображении, а, следовательно, имеют перспективу для применения в задаче обнаружения дефектов ЛЭП на аэрофотоснимках.

В данной статье рассматриваются аспекты применения глубоких сверточных нейросетевых моделей в задаче детекции дефектов изоляторов ЛЭП, отображенных на аэрофотоснимках, полученных при помощи БПЛА. В частности, предметом рассмотрения являются нейросетевые детекторы YOLOv3 и YOLOv4.

Анализ известных подходов

Рассмотрим подробнее современные исследования и методы детектирования дефектов на ЛЭП. Дефекты на ЛЭП, которые можно обнаружить с помощью нейронных сетей: отсутствие тарелки изолятора, сколы изолятора, обледенение изолятора, падение опоры, коррозия опоры, гнезда птиц на опоре, повреждение/обрыв проводок провода, посторонний предмет на проводе, деформация, отсутствие деталей арматуры и растительность на трассе ЛЭП.

В предыдущей работе [11] представлен обзор современных методов мониторинга состояния элементов конструкции линий электропередач (ЛЭП) посредством обработки изображений в инфракрасном, ультрафиолетовом и видимом спектрах. Методы, предназначенные для обработки изображений в видимом спектре, основываются на алгоритмах глубокого и машинного обучения. Наибольшую эффективность для выявления дефектов в видимом спектре показали GVN, HOG+SVM, SSD, Grab cut, cascading CNN, LBP-HF+SVM, DMNN, VGG-19, LBP+ULBP, YOLO v3, DELM+LRF, SVM, Faster R-CNN, CNN, стереозрение+PLAMEC.

В статье [12] авторы представили методологию выявления дефекта и типа изоляторов с помощью сверточных нейронных сетей (CNN). Авторами предложена классификационная модель для автоматического распознавания соответствия изоляторов. Многозадачное обучение (MTL) использовалось для повышения производительности обнаружения дефектов путем прогнозирования класса изолятора. Предлагаемая методика позволяет достичь точности 92 % для классификации материалов и 85 % для обнаружения дефектов, с F1-оценкой 0,75.

В статье [13] предложен метод глубокого обучения, основанный на You Only Look Once (YOLO). Модифицированная сеть YOLOv3-density объединила YOLOv3 с Dense-Blocks для оптимизации сети извлечения признаков. Для повышения точности и надежности обнаружения изоляторов разного размера была предложена структура FPN в качестве дополнения к сети YOLOv3-density. Авторы сделали вывод о том, что сеть YOLOv3 может быть использована БПЛА в целях проверки изоляторов. Сеть YOLOv3-dense имеет преимущества в обнаружении закрытых объектов и может быть использована для проверки других компонентов в высоковольтных линиях электропередачи (например, виброизолирующие опоры, птичьи гнезда и т. д.). Средняя точность YOLOv3-density, YOLOv3 и YOLOv2 составила 94,47 %, 90,31 % и 83,43 % соответственно. Экспериментальные результаты и анализ подтверждают, что предложенная сеть с плотной плотностью YOLOv3-dense достигает хороших характеристик при обнаружении изоляторов разного размера на фоне фоновых помех.

В статье [14] предлагается решение для объединения локализации изолятора и обнаружения дефектов с использованием каскадных CNN. Предлагаемая каскадная модель включает две сети. Первая сеть ILN обнаруживает все потенциально дефектные изоляторы на изображениях. Затем на основе кадрированных изображений определяются недостающие крышки из второго сетевого DDN. Наилучшая производительность достигается с предварительно обученными моделями VGG-16 и ResNet-101. Были получены результаты обнаружения дефектов изолятора. Зеленая рамка обозначает нормальный изолятор, а красная рамка обозначает дефектные изоляторы или дефекты. Точность обнаружения дефектов и отзыв предлагаемого метода составляет 0,91 и 0,96 с использованием стандартного набора данных изолятора.

В статье [15] авторы использовали Faster R-CNN для определения местоположения изоляторов и обнаружения распространенных дефектов изолятора, таких как отсутствующий колпачок и удар молнии. Сверточный слой используется для извлечения признаков из изображения фиксированного размера для получения карт признаков. Затем RPN применяется для обработки карт объектов, которые генерируют предложения по регионам. Объединение ROI используется для синтеза карт характеристик. Метки и ограничивающие прямоугольники получаются с помощью softmax и регрессии для реализации обнаружения дефектов изолятора. Результаты точности обнаружения: изолятор 96,04 %, отсутствует крышка 89,36 %, удар молнии 82,18 %, время обнаружения 0,517 с и средняя точность mAP 89,19 %.

Статья [4] направлена на решение двух ключевых задач ближней навигации – локализации башни и одновременной оценки местоположения беспилотного летательного аппарата. В статье обнаружение башен можно разделить на три типа: истинно положительные (TP) (башня обнаружена правильно), ложноположительные (FP) (фон ошибочно принимается за башню) и ложноотрицательные (FN) (башня не обнаруживается). Зеленые ограничительные рамки представляют основную истину. (а) синий ограничивающий прямоугольник представляет TP, (б) красный ограничивающий прямоугольник представляет FP, (в) отсутствие обнаружения ограничивающего прямоугольника (пропущенное обнаружение) представляет FN. Для локализации башни ЛЭП авторы использовали набор данных и настроили быструю нейронную сеть (сверточную нейронную сеть области башни (R-CNN)) для обнаружения. Обнаружение башни интегрировано в структуру SLAM, чтобы обеспечить точное положение в трехмерном пространстве.

Таким образом, не все исследования направлены на выявления дефектов изоляторов на видимых изображениях. Главная проблема – малое количество наборов данных. В открытом доступе на данный момент существует пять датасетов (Таблица 1).

Таблица 1 – Датасеты для детектирования дефектов ЛЭП
Table 1 – Datasets for detecting power transmission line defects

Тип элемента ЛЭП	Ссылка
Изолятор (изображения с дефектом (без крышки))	[16]
Башня (различные типы башен и фонов)	[17]
Набор данных (инфракрасный и видимый свет), провода	[18]
Набор данных для обнаружения повреждений изолятора	[19]
Набор данных для обнаружения объектов линий электропередач	[20]

Несмотря на результаты исследований, которые приводятся в обзоре, внедрение глубокого обучения для анализа изображений при обследовании ЛЭП все еще находится на начальном этапе развития. Современные исследования в основном рассматривают диагностику неисправностей как задачу обнаружения объекта (например, обнаружение изолятора или башни) или задачу классификации (например, коррозия башни). В исследованиях, которые направлены именно на обнаружение дефектов, используются методы, основанные на предложении регионов [12, 14, 15]. Они являются достаточно медленными и сложными для оптимизации, поскольку каждый отдельный компонент обучается отдельно. Для решения этой проблемы необходимо выбрать метод глубокого обучения, который обладает и высокой скоростью, и точностью обнаружения объектов.

В данной работе предложен и реализован метод для быстрой, точной и безопасной автоматической проверки линий электропередачи, а именно детектирования дефектов ЛЭП на базе нейронных сетей. В соответствии с результатами проведенного анализа связанных методов и подходов в рамках настоящего исследования предложен метод решения данной задачи. Для этого далее рассмотрим архитектуру YOLO (You Only Look Once), которая соответствует требованиям.

Архитектуры семейства YOLO

Рассмотрим подробнее нейросетевые архитектуры детекторов, использующихся в данной работе. Детекторы YOLOv3 и YOLOv4 являются современными нейросетевыми детекторами визуальных объектов. Они выполняют детекцию, т. е., генерируют координаты локализационной рамки, куда помещается объект, а также выполняют классификацию локализованного в рамке объекта, на основании одноэтапной обработки изображения. В отличие от других методов, таких как Feature Pyramid Network [21] или Mask R-CNN [5], выполняющих детекцию в два этапа (генерирование областей, где потенциально содержатся объекты и непосредственно детекция), детекция на основании одноэтапной обработки позволяет существенно сократить время обработки изображений.

Кратко рассмотрим архитектурные особенности, лежащие в основе всех нейросетевых детекторов семейства YOLO. На Рисунке 1 изображена схема, отражающая общие особенности архитектуры YOLO.



Рисунок 1 – Архитектура YOLO
Figure 1 – Architecture YOLO

Сначала выполняется обработка изображения сверточным экстрактором признаков. Обычно в качестве него выступает глубокая сверточная нейронная сеть, предварительно обученная общей задаче классификации на репрезентативной выборке изображений ImageNet [22], содержащей большое количество классов. Сформированные экстрактором карты признаков обрабатываются далее непосредственно детектором. Детектор на своем выходе формирует предполагаемые координаты рамок, а также информацию об объекте, находящемся в каждой рамке. При этом, для реализации одноэтапной детекции исходное изображение предварительно разделяется на так называемые опорные элементы (anchors), которые формируют сетку из M строк и N столбцов. Для каждого опорного элемента выполняются следующие задачи: проверка наличия объекта в указанном опорном элементе, классификация объекта, прогнозирование координат локализационной рамки. Таким образом, архитектура YOLO формирует предварительные детекционные рамки, которые в дальнейшем подвергаются постобработке, в ходе которой отбрасываются рамки, не удовлетворяющие комплексу критериев. Различные вариации архитектуры YOLO различаются реализацией блоков экстрактора и / или детектора.

YOLOv3

Детектор YOLOv3 [23] является развитием архитектур YOLOv2 [24] и YOLOv1 [25]. При этом, YOLOv3 существенно превосходит YOLOv2 и YOLOv1 по точности в общей задаче детекции визуальных объектов. В отличие от двухэтапных алгоритмов, сеть YOLOv3 извлекает признаки на основе методов регрессии без создания большого количества окон-кандидатов и напрямую использует одну нейронную сеть для прогнозирования и классификации входного изображения, что помогает сократить время обнаружения объекта. По этой причине одноэтапные алгоритмы работают быстрее, чем двухэтапные. Общая архитектура YOLOv3 показана на Рисунке 2.

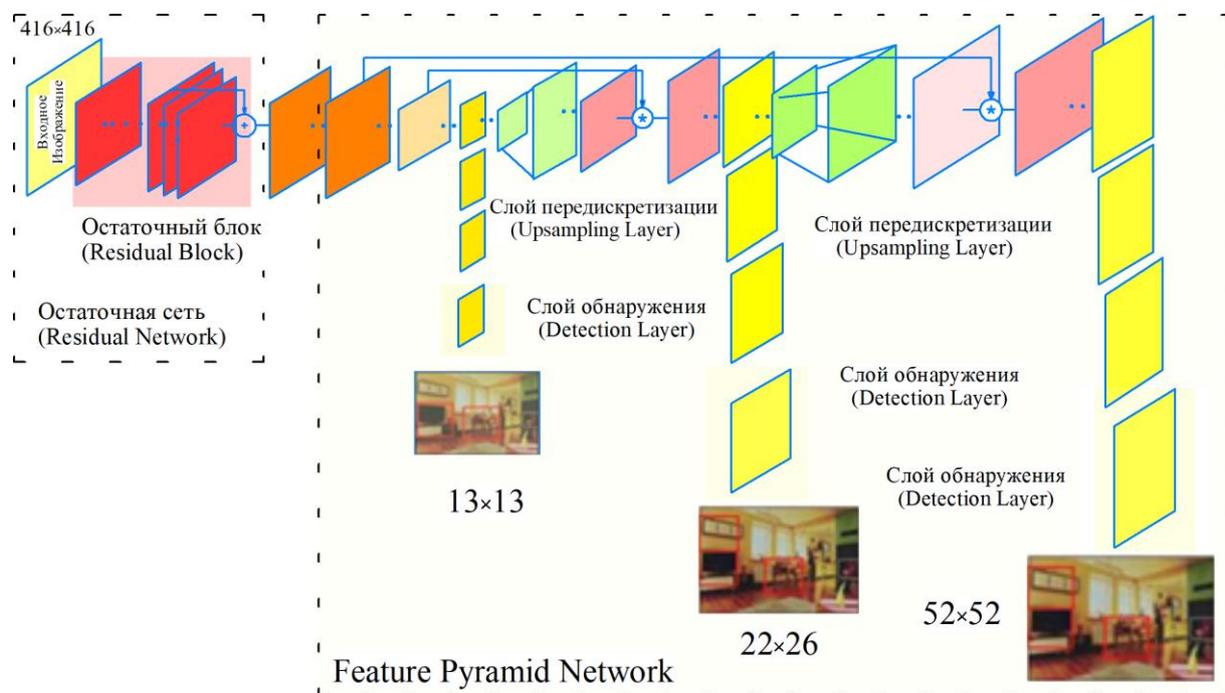


Рисунок 2 – Архитектура YOLOv3
 Figure 2 – YOLOv3 Architecture

Ключевыми отличиями YOLOv3 являются, во-первых, применение нейронных сетей семейства ResNet [26], а во-вторых, параллельное формирование детекционных рамок для трех различных масштабов сеток опорных элементов: (13, 13), (26, 26), (52, 52). Обработка различных масштабов сетки опорных элементов позволяет с более высокой точностью детектировать объекты различных размеров, а также перекрывающихся объектов. Этот прием является аналогичным, использованному в детекторе SSD [10]. Использование этих приемов позволяет увеличить точность детекции относительно архитектур YOLOv1 и YOLOv2 на наборах PASCAL VOC [27] и Microsoft COCO [28].

Для решения задачи детекции дефектов ЛЭП были использованы полная версия YOLOv3, а также сокращенная версия архитектуры YOLOv3-tiny, у которой в экстракторе признаков меньше слоев. Архитектура YOLO v3-tiny приведена на Рисунке 3.

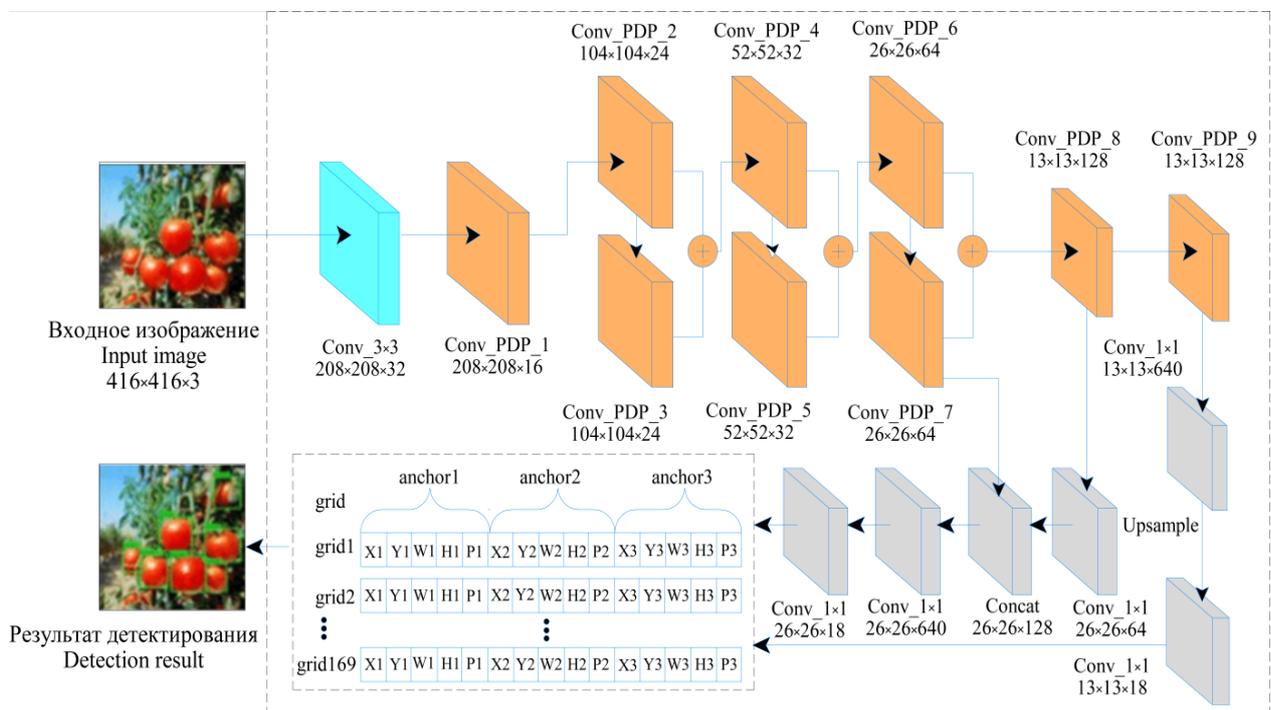


Рисунок 3 – Сеть обнаружения объектов YOLOv3-tiny
Figure 3 – Object detection network YOLOv3-tiny

Магистральная сеть YOLOv3-tiny представляет собой 7-слойную стандартную сверточную структуру. Входной слой представляет собой изображение 416x416, а затем после 10 сверток и 6 операций субдискретизации выходные карты признаков имеют размер 13x13. Далее рассмотрим архитектуру YOLOv4.

Архитектура YOLOv4

YOLOv4 является развитием архитектуры YOLOv3. Архитектура YOLOv4 представлена на Рисунке 4.

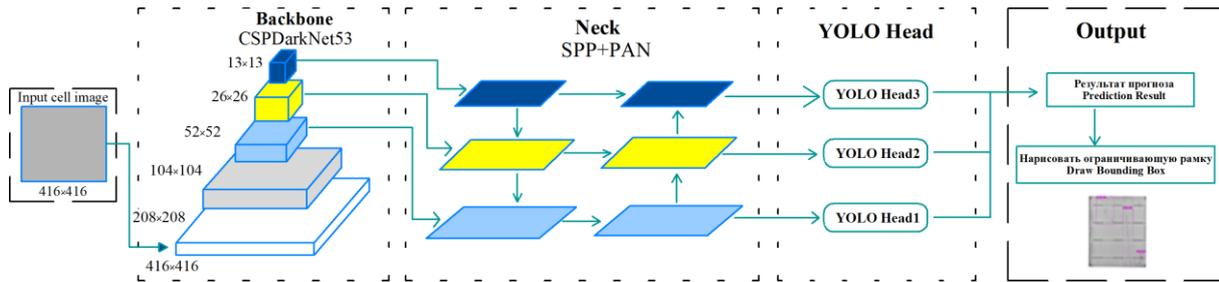


Рисунок 4 – Архитектура YOLOv4
Figure 4 – YOLOv4 architecture

Отличительной особенностью YOLOv4 по сравнению с YOLOv3 является применение дополнительных нейросетевых блоков обработки пространственных признаков, именуемых в оригинальной работе как «Neck». Данные блоки реализуют принцип обработки пирамиды признаков [29] с последующей агрегацией результатов обработки пирамиды признаков посредством нейронной сети PANet [30]. Кроме того, в качестве экстрактора признаков в этой нейронной сети используется сверточная архитектура, в основе которой лежит так называемая нейронная сеть с перекрестной частичной поэтапной обработкой информации (Cross Stage Partial Network – CSP), которая является модификацией архитектуры DenseNet [31]. Внесенные модификации позволили улучшить mAP (среднюю точность) на 10 % на наборе данных Microsoft COCO [29], а также скорость обработки изображений на 12 % [32]. Кроме того, нейронную сеть стало проще обучать на одном графическом процессоре.

Помимо YOLOv4, в данной работе также применялась ее сокращенная версия YOLOv4-tiny, архитектура которой приведена на Рисунке 5.

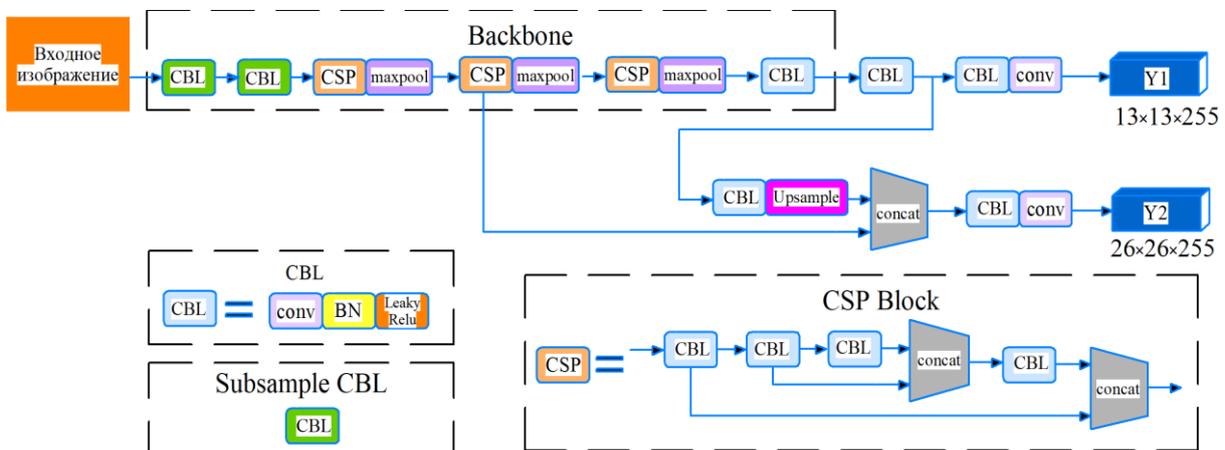


Рисунок 5 – Архитектура YOLOv4-tiny
Figure 5 – YOLOv4-tiny architecture

YOLOv4-tiny использует сеть CSPDarknet53-tiny в качестве базовой сети. CSPDarknet53-tiny состоит из трех уровней Conv и трех модулей CSPBlock.

Описание датасета

Для проведения эксперимента нужен был набор данных с достаточным количеством изображений для детектирования анализа и оценки дефектов ЛЭП. Открытые датасеты представлены в Таблице 1. Однако для решения поставленной задачи подходит только один общедоступный набор данных для обнаружения

повреждений изоляторов ЛЭП, который называется «CPLID» [14,16] и состоит из 600 изображений, снятых БПЛА. Этот набор данных разделен на две части:

1. Normal_Insulators содержит нормальные изоляторы захвата БПЛА. Количество изображений нормального изолятора – 600.
2. Defective_Insulators содержит изоляторы с дефектом. Количество образов дефектных изоляторов - 248. Для решения задачи детектирования дефектов ЛЭП была взята именно эта выборка.

Обнаружение изоляторов является одной из наиболее важных проблем при обследовании высоковольтных линий электропередачи с использованием БПЛА. Набор данных CPLID – это датасет изоляторов ЛЭП Китая, снятый в 2016 году. В данной выборке представлен один класс повреждений ЛЭП, а именно, отсутствующий изолятор. Поскольку аэрофотоснимки повреждений изолятора редки для получения как можно большего количества таких изображений на основе набора данных образцы смоделированных повреждений изолятора были созданы синтетически. Помимо этого, набор данных содержит в себе всего один класс дефектов ЛЭП, а также малый объем выборки размеченных изображений. Пример изображений из CPLID, содержащих поврежденные изоляторы, приведен на Рисунке 6.



Рисунок 6 – Изображения из датасета CPLID
 Figure 6 – Images from the CPLID dataset

Далее проведен эксперимент по детектированию дефектов изолятора на выбранном наборе данных, где сравниваются алгоритмы YOLOv3 и YOLOv4.

Методика исследования

Для проверки различий в способностях нейронных сетей YOLOv3 и YOLOv4 эти нейронные сети были обучены задаче детекции посредством процедуры кросс-валидации с $P \times K$ контролем ($P \times K$ -fold cross-validation), где P – количество раз, которые

выполняется разбиение в пределах кросс-валидации, а K – это количество, на которое разбивается выборка в пределах одной кросс-валидации. Рекомендуемыми параметрами для проверки различий результативности алгоритмов машинного обучения являются $p=5$ и $k=2$ [33]. Полученные в ходе кросс-валидации 5×2 значения метрик для каждого алгоритма составляют выборки, анализ которых при помощи парного t -теста Стьюдента позволяет судить о статистически значимых различиях в результатах алгоритмов детекции. Кроме того, для каждой выборки строятся доверительные интервалы, позволяющие судить о разбросе значений, полученных в ходе процедуры кросс-валидации 5×2 .

В качестве оцениваемых метрик были выбраны следующие наиболее распространенные метрики качества детекторов визуальных объектов на изображениях:

$$precision = \frac{TP}{TP + FP}$$

$$recall = \frac{TP}{TP + FN}$$

где TP – количество истинно положительно детектированных экземпляров, FP – количество ложно положительно детектированных экземпляров, FN – количество ложно отрицательно детектированных экземпляров.

Средневзвешенная точность (mean average precision – mAP), вычисляемая как усредненное среднее значение точности (average precision – AP) для различных классов для различных значений метрики recall:

$$mAP = \frac{1}{K} \sum_{i=1}^k AP_k$$

Обычно данная метрика вычисляется для определенного параметра отношения площади пересечения к площади объединения сгенерированной детекционной рамки и эталонной рамки (Intersection over Union – IoU), который контролирует первоначальные требования к точности координат рамок. Наиболее распространенными значениями IoU являются IoU=0,5 (mAP@0.5) и IoU=0.75 (mAP@0.75). Обучение выполнялось при помощи алгоритма пакетного стохастического градиентного спуска. Размер пакета данных, подаваемых в нейронную сеть, составил 16 изображений (640×640 пикселей каждое). Обучение каждой нейронной сети выполнялось в течение 100 эпох.

Результаты и обсуждение

На Рисунке 7 проиллюстрированы результаты детекции поврежденных изоляторов нейронными сетями YOLOv3 и YOLOv4.



(1)



(2)



Рисунок 7 – Результаты детекции YOLOv3 (1), YOLOv3-tiny (2), YOLOv4 (3) YOLOv4-tiny (4)
Figure 7 – YOLOv3 (1), YOLOv3-tiny (2), YOLOv4 (3) YOLOv4-tiny (4) detection results

Результаты экспериментов приведены в Таблице 2.

Таблица 2 – Результаты экспериментального исследования нейронных сетей семейства YOLO
Table 2 – Results of an experimental study of neural networks of the YOLO

	Precision	Recall	mAP@.50	mAP@.75
YOLOv3	0,96±0,03	0,95±0,02	0,97±0,02	0,78±0,03
YOLOv3-tiny	0,97±0,02	0,96±0,03	0,97±0,03	0,78±0,04
YOLOv4	0,74±0,05	0,68±0,04	0,74±0,03	0,71±0,04
YOLOv4-tiny	0,61±0,04	0,79±0,03	0,86±0,04	0,74±0,03

Для интерпретации полученных результатов необходимо выполнить парное сравнение каждого с каждым. В пределах пары YOLOv3 и YOLOv3-tiny парный тест Стьюдента с уровнем значимости $p < 0,05$ не показал статистически значимых различий ни в одной из рассмотренных метрик. Однако, применение YOLOv3 оказывается оправданным с точки зрения скорости обработки данных моделью, размера модели и скорости сходимости алгоритма обучения. Несмотря на лучшие результаты в общей задаче детекции, показанные нейронной сетью YOLOv4 относительно YOLOv3, сравнение алгоритма YOLOv3-tiny с YOLOv4 и YOLOv4-tiny показало статистически значимые различия между ними на уровне значимости $p < 0,001$. Превосходство этой нейронной сети можно объяснить меньшей архитектурной сложностью, что в случае простых (с точки зрения количества экземпляров, количества представленных классов, сложностью самих визуальных объектов) наборов данных обычно дает лучшие результаты. Также особо стоит выделить сравнение YOLOv4 и YOLOv4-tiny. В отличие от YOLOv3 и YOLOv3-tiny, у которых не наблюдается значимых различий в метриках качества, парный тест Стьюдента показал статистически значимые различия у YOLOv4 и YOLOv4-tiny для всех метрик. Это также можно объяснить более сложной архитектурой YOLOv4, которая изначально разрабатывалась для решения задачи детекции большого количества классов визуальных объектов и обучалась на выборках, в которых в каждом классе присутствует большое количество экземпляров.

Таким образом, можно сделать вывод о том, что применение YOLOv3 является более эффективным в задаче детекции дефектов на изоляторах как в случае минимальных требований IoU, составляющих 0,5, так и в случае более высоких требований к IoU, составляющих 0,75.

Заключение

В приведенной работе в контексте задачи детектирования поврежденных участков ЛЭП рассматривалось сравнение двух современных нейросетевых архитектур YOLOv3 и YOLOv4, а также их более простых вариантов (YOLOv3-tiny и YOLOv4-tiny). Моделирование этих нейронных сетей посредством процедуры 5x2 кросс-валидации на наборе данных CPLID показало высокие значения метрик качества детекции для нейронных сетей YOLOv3, YOLOv3-tiny и YOLOv4-tiny. При этом более простые нейронные сети YOLOv3 превзошла по рассмотренным показателям YOLOv4. Сравнительное статистическое исследование результатов метрик, полученных в ходе процедуры 5x2 кросс-валидации, выявило: значения метрик у YOLOv3 и YOLOv3-tiny не показали статистически значимых различий. При этом применение YOLOv3 является более перспективным ввиду меньшего размера этой нейронной сети и более высокой скорости обработки информации. Все другие пары сравниваемых вариантов моделей YOLOv3 и YOLOv4 показали статистически значимые различия согласно рассматриваемым метрикам.

Несмотря на высокие результаты метрик качества детекции, показанные обоими алгоритмами, а также статистически значимые различия результатов рассмотренных нейронных сетей, необходимо дальнейшее исследование моделей, методов и алгоритмов детекции дефектов ЛЭП. Особенно остро встает вопрос о сборе и разметке новых выборок данных, содержащих большое количество различных классов дефектов ЛЭП, а также широкую вариативность экземпляров этих классов. Кроме того, планируется выполнить сравнительное исследование с другими методами детекции: SSD [10], FPN [21], Mask R-CNN [5], MTCNN [34], Viola-Jones [35].

СПИСОК ИСТОЧНИКОВ

1. Savvaris A., Xie Y., Malandrakis K., Lopez M., Tsourdos A. Development of a fuel cell hybrid-powered unmanned aerial vehicle. *2016 24th mediterranean conference on control and automation (MED)*. 2016:1242–1247.
2. Zhang Tao, et al. Current trends in the development of intelligent unmanned autonomous systems. *Frontiers of information technology & electronic engineering*. 2017;18(1):68-85.
3. Sadykova D., Pernebayeva D., Bagheri M., James A. IN-YOLO: Real-time detection of outdoor high voltage insulators using UAV imaging. *IEEE Transactions on Power Delivery*. 2019;35(3):1599–1601.
4. Bian J., Hui X., Zhao X., Tan M. A monocular vision-based perception approach for unmanned aerial vehicle close proximity transmission tower inspection. *International Journal of Advanced Robotic Systems*. 2019;16(1):1729881418820227.
5. He K., Gkioxari G., Dollár P., Girshick R. Mask R-CNN. *Proceedings of the IEEE international conference on computer vision*. 2017:2961–2969.
6. Girshick R. Fast R-CNN. *Proceedings of the IEEE international conference on computer vision*. 2015:1440–1448.
7. Ren S., He K., Girshick R., Sun J. Faster r-cnn: Towards real-time object detection with region proposal networks. *IEEE transactions on pattern analysis and machine intelligence*. 2016;39(6):1137–1149.

8. Redmon J., Divvala S., Girshick R., Farhadi A. You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016:779–788.
9. Pál D., Póczos B., Szepesvári C. Estimation of Rényi Entropy and Mutual Information Based on Generalized Nearest-Neighbor Graphs. *Advances in neural information processing systems*. 2010:1849–1857.
10. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.-Y., Berg A.C. SSD: Single shot multibox detector. *European conference on computer vision*. Springer, Cham. 2016:21–37.
11. Астапова М.А., Лебедев И.В. Обзор подходов к детектированию дефектов элементов ЛЭП на изображениях в инфракрасном, ультрафиолетовом и видимом спектрах. *Моделирование, оптимизация и информационные технологии*. 2020;8(4):38–39.
12. Prates R.M., Cruz R., Marotta A.P., Ramos R.P., Simas Filho E.F., Cardoso J.S. Insulator visual non-conformity detection in overhead power distribution lines using deep learning. *Computers & Electrical Engineering*. 2019;78:343–355.
13. Liu C., Wu Y., Liu J., Sun Z. Improved YOLOv3 Network for Insulator Detection in Aerial Images with Diverse Background Interference. *Electronics*. 2021;10(7):771.
14. Tao X., Zhang D., Wang Z., Liu X., Zhang H., Xu D. Detection of Power Line Insulator Defects Using Aerial Images Analyzed With Convolutional Neural Networks. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. 2020;50(4):1486–98.
15. Liao G.P., Yang G.J., Tong W.T., Gao W., Lv F.L., Gao D. Study on power line insulator defect detection via improved faster region-based convolutional neural network. *2019 IEEE 7th International Conference on Computer Science and Network Technology (ICCSNT)*. 2019:262–266.
16. Insulator Data Set – Chinese Power Line Insulator Dataset (CPLID). Доступно по: <https://github.com/InsulatorData/InsulatorDataSet> (дата обращения: 16.12.2021).
17. Transmission Tower DataSet in VOC data format. Доступно по: <https://drive.google.com/drive/folders/1UyP0fBNUqFeoW5nmPVGzyFG5IQZcqlc5> (дата обращения: 16.12.2021).
18. Ömer Emre Yetgin, Ömer Nezhir GEREK. Powerline Image Dataset (Infrared-IR and Visible Light-VL). 2019. Доступно по: <https://data.mendeley.com/datasets/n6wrv4ry6v/8> (дата обращения: 16.12.2021).
19. Dataset for insulator fault detection. Доступно по: https://figshare.com/articles/dataset/66KVimage_zip/14992944 (дата обращения: 16.12.2021).
20. STN PLAD: A Dataset for Multi-Size Power Line Assets Detection in High-Resolution UAV Images. Доступно по: <https://github.com/andreluizbvs/PLAD> (дата обращения: 16.12.2021).
21. Lin T.Y., Dollár P., Girshick R., He K., Hariharan B., Belongie S. Feature pyramid networks for object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017:2117–2125.
22. Russakovsky O., et al. Imagenet large scale visual recognition challenge. *International journal of computer vision*. 2015;115(3):211–252.
23. Redmon J., Farhadi A. Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*. 2018.
24. Redmon, J., Farhadi, A. *Yolo9000: better, faster, stronger arXiv preprint*. 2017.
25. Redmon J., et al. You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016:779–788.
26. He K., Zhang X., Ren S., Sun, J. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016:770–778.

27. Everingham M., Van Gool L., Williams C. K., Winn J., Zisserman A. The pascal visual object classes (voc) challenge. *International journal of computer vision*. 2010;88(2):303–338.
28. Lin T.Y., et al. Microsoft coco: Common objects in context. *European conference on computer vision*. Springer, Cham. 2014:740–755.
29. Adelson E.H., Anderson C.H., Bergen J.R., Burt P.J., Ogden J.M. *Pyramid methods in image processing*. RCA engineer. 1984;29(6):33–41.
30. Liu S., Qi L., Qin H., Shi J., Jia J. Path aggregation network for instance segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018:8759–8768.
31. Huang G., Liu Z., Van Der Maaten L., Weinberger K.Q. Densely connected convolutional networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017:4700–4708.
32. Bochkovskiy A., Wang C.Y., Liao, H.Y.M. Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*. 2020.
33. Dietterich T.G. Approximate statistical tests for comparing supervised classification learning algorithms. *Neural computation*. 1998;10(7):1895–1923.
34. Zhang K., Zhang Z., Li Z., Qiao Y. Joint face detection and alignment using multitask cascaded convolutional networks. *IEEE Signal Processing Letters*. 2016;23(10):1499–1503.
35. Viola P., Jones M. Rapid object detection using a boosted cascade of simple features. *Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition*. CVPR 2001. 2001;1:I–I.

REFERENCES

1. Savvaris A., Xie Y., Malandrakis K., Lopez M., Tsourdos A. Development of a fuel cell hybrid-powered unmanned aerial vehicle. *2016 24th mediterranean conference on control and automation (MED)*. 2016:1242–1247.
2. Zhang Tao, et al. Current trends in the development of intelligent unmanned autonomous systems. *Frontiers of information technology & electronic engineering*. 2017;18(1):68-85.
3. Sadykova D., Pernebayeva D., Bagheri M., James A. IN-YOLO: Real-time detection of outdoor high voltage insulators using UAV imaging. *IEEE Transactions on Power Delivery*. 2019;35(3):1599–1601.
4. Bian J., Hui X., Zhao X., Tan M. A monocular vision-based perception approach for unmanned aerial vehicle close proximity transmission tower inspection. *International Journal of Advanced Robotic Systems*. 2019;16(1):1729881418820227.
5. He K., Gkioxari G., Dollár P., Girshick R. Mask R-CNN. *Proceedings of the IEEE international conference on computer vision*. 2017:2961–2969.
6. Girshick R. Fast R-CNN. *Proceedings of the IEEE international conference on computer vision*. 2015:1440–1448.
7. Ren S., He K., Girshick R., Sun J. Faster r-cnn: Towards real-time object detection with region proposal networks. *IEEE transactions on pattern analysis and machine intelligence*. 2016;39(6):1137–1149.
8. Redmon J., Divvala S., Girshick R., Farhadi A. You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016:779–788.
9. Pál D., Póczos B., Szepesvári C. Estimation of Rényi Entropy and Mutual Information Based on Generalized Nearest-Neighbor Graphs. *Advances in neural information processing systems*. 2010:1849–1857.

10. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.-Y., Berg A.C. SSD: Single shot multibox detector. *European conference on computer vision*. Springer, Cham. 2016:21–37.
11. Astapova M.A., Lebedev I.V. Obzor podkhodov k detektirovaniyu defektov elementov LEP na izobrazheniyakh v infrakrasnom, ultrafioletovom i vidimom spektrakh. *Modelirovaniye, optimizatsiya i informatsionnyye tekhnologii = Modeling, optimization and information technology*. 2020;8(4):38-39. (In Russ.)
12. Prates R.M., Cruz R., Marotta A.P., Ramos R.P., Simas Filho E.F., Cardoso J.S. Insulator visual non-conformity detection in overhead power distribution lines using deep learning. *Computers & Electrical Engineering*. 2019;78:343–355.
13. Liu C., Wu Y., Liu J., Sun Z. Improved YOLOv3 Network for Insulator Detection in Aerial Images with Diverse Background Interference. *Electronics*. 2021;10(7):771.
14. Tao X., Zhang D., Wang Z., Liu X., Zhang H., Xu D. Detection of Power Line Insulator Defects Using Aerial Images Analyzed With Convolutional Neural Networks. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. 2020;50(4):1486–98.
15. Liao G.P., Yang G.J., Tong W.T., Gao W., Lv F.L., Gao D. Study on power line insulator defect detection via improved faster region-based convolutional neural network. *2019 IEEE 7th International Conference on Computer Science and Network Technology (ICCSNT)*. 2019:262–266.
16. Insulator Data Set – Chinese Power Line Insulator Dataset (CPLID). Available at: <https://github.com/InsulatorData/InsulatorDataSet> (accessed 16.12.2021).
17. Transmission Tower DataSet in VOC data format. Available at: <https://drive.google.com/drive/folders/1UyP0fBNUqFeoW5nmPVGzyFG5IQZcqlc5> (accessed 16.12.2021).
18. Ömer Emre Yetgin, Ömer Nezir GEREK. Powerline Image Dataset (Infrared-IR and Visible Light-VL). 2019. Available at: <https://data.mendeley.com/datasets/n6wrv4ry6v/8> (accessed 16.12.2021).
19. Dataset for insulator fault detection. Available at: https://figshare.com/articles/dataset/66KVimage_zip/14992944 (accessed 16.12.2021).
20. STN PLAD: A Dataset for Multi-Size Power Line Assets Detection in High-Resolution UAV Images. Available at: <https://github.com/andreluizbvs/PLAD> (accessed 16.12.2021).
21. Lin T.Y., Dollár P., Girshick R., He K., Hariharan B., Belongie S. Feature pyramid networks for object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017:2117–2125.
22. Russakovsky O., et al. Imagenet large scale visual recognition challenge. *International journal of computer vision*. 2015;115(3):211–252.
23. Redmon J., Farhadi A. Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*. 2018.
24. Redmon, J., Farhadi, A. *Yolo9000: better, faster, stronger arXiv preprint*. 2017.
25. Redmon J., et al. You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016:779–788.
26. He K., Zhang X., Ren S., Sun, J. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016:770–778.
27. Everingham M., Van Gool L., Williams C. K., Winn J., Zisserman A. The pascal visual object classes (voc) challenge. *International journal of computer vision*. 2010;88(2):303–338.
28. Lin T.Y., et al. Microsoft coco: Common objects in context. *European conference on computer vision*. Springer, Cham. 2014:740–755.
29. Adelson E.H., Anderson C.H., Bergen J.R., Burt P.J., Ogden J.M. *Pyramid methods in image processing*. *RCA engineer*. 1984;29(6):33–41.

30. Liu S., Qi L., Qin H., Shi J., Jia J. Path aggregation network for instance segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018:8759–8768.
31. Huang G., Liu Z., Van Der Maaten L., Weinberger K.Q. Densely connected convolutional networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017:4700–4708.
32. Bochkovskiy A., Wang C.Y., Liao, H.Y.M. Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*. 2020.
33. Dietterich T.G. Approximate statistical tests for comparing supervised classification learning algorithms. *Neural computation*. 1998;10(7):1895–1923.
34. Zhang K., Zhang Z., Li Z., Qiao Y. Joint face detection and alignment using multitask cascaded convolutional networks. *IEEE Signal Processing Letters*. 2016;23(10):1499–1503.
35. Viola P., Jones M. Rapid object detection using a boosted cascade of simple features. *Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition. CVPR 2001*. 2001;1:I–I.

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Астапова Марина Алексеевна, младший научный сотрудник лаборатории технологий больших данных социоконвергентных систем, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук, Санкт-Петербург, Российская Федерация,
e-mail: marinaastapova55@gmail.com
ORCID: [0000-0002-9121-894X](https://orcid.org/0000-0002-9121-894X)

Marina A. Astapova, junior researcher of Laboratory of Big Data Technologies in Socio-Cyberphysical Systems, St. Petersburg Federal Research Center of the Russian Academy of Sciences, St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences, St. Petersburg, Russian Federation

Уздяев Михаил Юрьевич, младший научный сотрудник лаборатории технологий больших данных социоконвергентных систем, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук, Санкт-Петербург, Российская Федерация,
e-mail: m.y.uzdiaev@gmail.com
ORCID: [0000-0002-7032-0291](https://orcid.org/0000-0002-7032-0291)

Mikhail Y. Uzdiaev, junior researcher of Laboratory of Big Data Technologies in Socio-Cyberphysical Systems, St. Petersburg Federal Research Center of the Russian Academy of Sciences, St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences, St. Petersburg, Russian Federation

Статья поступила в редакцию 17.12.2021; одобрена после рецензирования 24.12.2021; принята к публикации 26.12.2021.

The article was submitted 17.12.2021; approved after reviewing 24.12.2021; accepted for publication 26.12.2021.