

УДК 004.932

<https://doi.org/10.21869/2223-1560-2025-29-1-8-26>



Метод для определения наклона столба линии связи на основе изображений с БПЛА

М. И. Заикин ¹, М.А. Астапова ¹ ✉, Д.М. Волков ¹

¹ Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПБ ФИЦ РАН)
14-я линия В.О., д. 39, г. Санкт-Петербург 199178, Российская Федерация

✉ e-mail: astapova.m@iias.spb.su

Резюме

Цель исследования. Воздушные линии связи (ВЛС) являются важным элементом коммуникационной инфраструктуры, однако их техническое состояние требует регулярного контроля и осмотра. Традиционные методы осмотра, включающие визуальную проверку специалистами, не всегда позволяют эффективно собирать и фиксировать все необходимые данные. С целью улучшения качества осмотра ВЛС был разработан метод для определения наклона столба линии связи на основе изображений с беспилотного летательного аппарата (БПЛА).

Методы. Для решения задачи использовалась комбинация математических преобразований и методов машинного обучения. Обработка данных включала использование параметров камеры, координат объекта на изображении, высоты полета и координат БПЛА. На основе этих данных разрабатывался алгоритм детекции ключевых точек опоры и расчета угла наклона столбов.

Результаты. В результате проведенных экспериментов на основе данных, полученных с БПЛА, была достигнута точность детектирования ключевых точек опоры по метрике mAP50 равна 0,71. В пределах корректно предсказанной опоры точность детекции ее вершины и основания составила 0,88 по метрике F1-score. Для определения наклона столбов ВЛС была выведена формула, которая позволила рассчитать максимальный наклон столба – 24,5°, а минимальный – 0,6°. Средний угол наклона опор для всего набора изображений составил примерно 6,1°.

Заключение. Разработанный метод позволяет автоматизировать процесс технического осмотра ВЛС, обеспечивая высокую точность определения их ключевых параметров. Применение БПЛА и машинного обучения снижают временные и финансовые затраты, а также улучшает качество сбора и анализа данных. Использование БПЛА в сочетании с методами машинного обучения позволяет значительно сократить временные и финансовые затраты, повышают качество сбора и анализа данных и снижают риск ошибок, связанных с человеческим фактором.

Ключевые слова: воздушные линии связи; глубокое обучение; беспилотная воздушная система; детекция объектов на изображении.

© Заикин М. И., Астапова М.А., Волков Д.М., 2025

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Заикин М. И., Астапова М.А., Волков Д.М. Метод для определения наклона столба линии связи на основе изображений с БПЛА // Известия Юго-Западного государственного университета. 2025; 29(1): 8-26. <https://doi.org/10.21869/2223-1560-2025-29-1-8-26>.

Поступила в редакцию 03.12.2024

Подписана в печать 30.01.2025

Опубликована 14.04.2025

Method for determining the inclination of a communication line pole based on UAV images

Mikhail I. Zaikin¹, Marina A. Astapova¹ ✉, Danila M. Volkov¹

¹ St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS)
39, 14th Line, St. Petersburg 199178, Russian Federation

✉ e-mail: astapova.m@iias.spb.su

Abstract

Purpose of research. Overhead communication lines (OCL) are an important element of the communication infrastructure, but their technical condition requires regular monitoring and inspection. Traditional inspection methods, including visual inspection by specialists, do not always allow for the efficient collection and recording of all necessary data. In order to improve the quality of OCL inspection, a method was developed for determining the tilt of a communication line pole based on images from an unmanned aerial vehicle (UAV).

Methods. A combination of mathematical transformations and machine learning methods was used to solve the problem. Data processing included the use of camera parameters, object coordinates in the image, flight altitude, and UAV coordinates. Based on these data, an algorithm was developed for detecting key support points and calculating the tilt angle of the poles.

Results. As a result of the experiments conducted based on the data obtained from the UAV, the accuracy of detecting key support points according to the mAP50 metric was 0.71. Within the correctly predicted support, the accuracy of detecting its top and base was 0.88 according to the F1-score metric. To determine the tilt of the VLS pillars, a formula was derived that made it possible to calculate the maximum tilt of the pillar is 24.5°, and the minimum is 0.6°. The average tilt angle of the pillars for the entire set of images is approximately 6.1°.

Conclusion. The developed method allows automating the technical inspection of VLS, ensuring high accuracy in determining their key parameters. The use of UAVs and machine learning reduces time and cost, and improves the quality of data collection and analysis. The use of UAVs in combination with machine learning methods can significantly reduce time and cost, improve the quality of data collection and analysis, and reduce the risk of human error.

Keywords: overhead communication lines; deep learning; unmanned aerial vehicle; image object detection.

Conflict of interest. The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Zaikin M. I., Astapova M. A., Volkov D. M. Method for determining the inclination of a communication line pole based on UAV images // *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta* = *Proceedings of the Southwest State University*. 2025; 29(1): 8-26 (In Russ.). <https://doi.org/10.21869/2223-1560-2025-29-1-8-26>.

Received 03.12.2024

Accepted 30.01.2025

Published 14.04.2025

Введение

ВЛС являются основой современной коммуникационной инфраструктуры, обеспечивая стабильную передачу информации и связь между различными системами. Для обеспечения их надежной работы необходимо регулярное техническое обслуживание и мониторинг состояния. Обычно для осмотра ВЛС применяются традиционные методы, предполагающие участие специалистов, которые проводят визуальные проверки на месте. Такие методы, как правило, требуют значительных затрат времени и средств, особенно при обследовании удаленных и труднодоступных участков. Кроме того, вручную выполняемые осмотры не всегда дают точные результаты, что повышает вероятность пропуска дефектов. Трудности, возникающие при получении точных данных, могут привести к недостаточному контролю за состоянием линий, что повышает риск неисправностей и аварий. В связи с этим возникает потребность в оптимизации процессов мониторинга состояния ВЛС. Современные разработки, такие как БПЛА, оснащенные камерами высокого разрешения и искусственным интеллектом для анализа данных, позволяют значительно повысить качество мониторинга объектов [1, 2]. Данные технологии обеспечивают не только ускорение процессов проверки элементов объектов и снижение затрат на проведение работ, но и повышение точно-

сти и безопасности при проведении осмотров.

БПЛА становятся все более востребованными для задач мониторинга территорий [3, 4] и построения карт [5], включая анализ состояния опор воздушных линий связи, благодаря своей мобильности, точности и способности оперативно формировать данные о труднодоступных участках [6]. БПЛА показали свою эффективность при проведении инспекций линий электропередач [7]. Различные типы БПЛА, включая устройства с фиксированными крыльями для общего осмотра, а также шестироторные и многороторные аппараты, используемые для детальных осмотров, функционально дополняют друг друга, повышая общую эффективность и скорость выполнения задач, особенно в сложных ландшафтных условиях [8]. Данные передаются в реальном времени, позволяя специалистам оперативно принимать решения и выявлять потенциальные угрозы до возникновения проблем. Использование тепловизоров и инфракрасных камер на БПЛА позволяет обнаруживать скрытые дефекты и участки с перегревом, которые могут указывать на наличие внутренних повреждений или начальные стадии разрушения материала. Эффективным способом анализа видеоряда, полученных с БПЛА являются методы компьютерного зрения, основанного на глубоком обучении [9]. БПЛА используется для получения видеоряда, содержащего опоры ВЛС.

Для оценки состояния опоры необходимо классифицировать детектируемые объекты опор на изображениях или определения угла наклона опоры. Однако оба метода имеют определенные ограничения. Так, чтобы добиться высокой точности в классификации требуется большое количество данных для обучения модели. В связи с этим, метод определения угла наклона на основе изображения опоры представляется наиболее предпочтительным вариантом.

Использование нейронных сетей для обработки изображений с БПЛА имеет преимущества: они адаптируются к изменениям, шуму и эффективно обрабатывают большие объемы данных, репрезентативной выборки и качественной разметкой. Кроме того, яркость, насыщенность и резкость изображения зависят от таких факторов, как время суток, состояние камеры, тип камеры, время года и других параметров. Нейронные сети позволяют обобщать информацию об анализируемых объектах, что позволяет эффективно обрабатывать их содержимое.

Существует множество методов для определения наклона столбов ВЛС, включая использование БПЛА, датчиков, NB-IoT, LiDAR и машинного обучения. Так, в статье [10] рассматривается метод онлайн-мониторинга наклона опоры ВЛС на основе патрульного БПЛА и камеры. Для сбора данных облака точек изображения опоры ВЛС применяется пирамидальное управление градацией. Эти данные предварительно обрабаты-

ваются для устранения ошибок, а данные облака точек гомогенизируются для получения многомасштабных характеристик. На этой основе разрабатывается многомасштабный классификатор для автоматической классификации данных облака точек. Результаты испытаний показывают, что предложенный метод позволяет эффективно контролировать угол наклона опоры ВЛС при различных ветровых условиях, при этом максимальное отклонение между измеренным и фактическим углом наклона составляет около $0,3^\circ$.

В исследовании [11] предлагается метод, который обрабатывает данные об опоре из 2D-изображения и 3D-облака точек для автоматического измерения угла наклона опоры. На первом этапе извлекается маска скелета опоры с помощью усовершенствованного алгоритма Mask R-CNN. Затем облако точек опоры извлекается с помощью PointNet, который обрабатывает фрустум, созданный из маски скелета опоры и карты глубины. На последнем этапе угол наклона вычисляется путем подгонки центральной оси облака точек опоры. Экспериментальные результаты показывают, что AP75 улучшенной Mask R-CNN составляет 58,15%, точность PointNet – 92,4%, средняя ошибка наклона полюса – $0,66^\circ$, а дисперсия – $0,12^\circ$.

Авторами [12] представлена разработка алгоритма РТТЕ для оценки наклона опор ЛЭП на основе облаков точек, полученных с помощью LiDAR с БПЛА. Метод использует сеть SCF-Net для се-

математического сегментирования энергетических объектов в сцене после сбора данных о ЛЭП с помощью БПЛА, а затем применяется кластеризация K-means для получения отдельных башен. Затем извлеченные отдельные опоры используются для предложения алгоритма оценки наклона опор, основанного на подгонке плоскости облака точек cross-stretcher и normal estimation. Эксперименты, проведенные на реальных данных электропередач, показали, что индекс IOU для классификации столбов электропередач с использованием сети SCF-Net достигает 97,75.

Целью работы [13] является разработка алгоритма расчета угла наклона опор ВЛС. Был создан алгоритм, который позволяет идентифицировать объекты на изображении с использованием нейронной сети YOLOv3 и определять края опор путем построения прямых линий вдоль них. Для идентификации наклона опор в полученных ограничивающих прямоугольниках применены методы машинного зрения (алгоритм Canny, Hough Line, GrabCut). Точность классификации металлических и бетонных столбов составила 91,11% и 91,08% соответственно, с относительно небольшим количеством ошибочных классификаций. Алгоритм был протестирован на 99 изображениях, полученных с БПЛА. Средняя относительная погрешность алгоритма составила 11,5%.

В статье [14] авторы исследуют метод мониторинга состояния наклона опоры передачи на основе технологии NB-

IoT. Для измерения угла наклона опоры выбран 6-осевой датчик положения GY-521, использующий микросхему датчика ускорения MPU6050 для цифрового вывода данных 6-осевой матрицы вращения в алгоритм слияния. Также для сбора данных о состоянии опоры ЛЭП используются датчик ветра и датчик натяжения. Сеть NB-IoT используется для передачи обработанных данных, очищенных от шума, на базовую станцию, откуда они передаются на верхний компьютер. Далее данные анализируются с помощью LSTM-сети для получения результатов мониторинга состояния наклона опоры ВЛС. Экспериментальные результаты показывают, что максимальная среднеквадратичная ошибка предлагаемого метода мониторинга составляет всего 0,02701, что значительно меньше, чем у метода сравнения Real-Time Kinematic Positioning (RTK).

В работе [15] предложен метод оценки наклона опор ВЛС на основе плотных облаков точек, полученных с помощью LiDAR, установленного на БПЛА. Для сегментации данных облака точек корпуса опоры использовались многомерные геометрические структурные особенности облака точек 3D-лазера опоры. Затем были извлечены плоскости и высоты опоры, которые объединили с гистограммой высот. Внешние контуры опоры были получены с помощью алгоритмов Alpha Shapes и Pipeline. Данные были собраны с использованием БПЛА, оснащенного датчиком VUX-1 LiDAR. Экспериментальный набор данных вклю-

чал 157 вышек передачи, классифицированных на шесть категорий. Результаты моделирования и измерений показали, что точность расчета параметров наклона корпуса опоры ЛЭП составляет более $0,5^\circ$.

В статье [16] авторы предложили систему мониторинга для автоматического измерения угла наклона опор ВЛС по изображениям, полученным с БПЛА. Метод состоит из трех основных этапов: захват изображений опор с помощью БПЛА, сегментация столбов на изображениях с использованием нейронной сети глубокого обучения и расчет угла наклона каждого столба с применением методов компьютерного зрения. Для обнаружения и измерения углов наклона опор была выбрана нейронная сеть SegNet. Модель была переобучена для решения задачи сегментации коммунальных столбов с использованием ограниченного набора классов (например, столбы, небо, дороги, растительность) для повышения точности. После сегментации столбы были проанализированы с помощью методов компьютерного зрения, включая преобразование Хафа, для расчета углов наклона. Метод был протестирован на 64 изображениях, содержащих 84 опоры линий электропередач, снятых в различных погодных условиях. Точность сегментации опор составила 93,74%, а средняя ошибка угла наклона $0,59^\circ$.

В исследовании [17] предложен метод мониторинга наклона столба с помощью БПЛА, основанный на спутниковой

навигации BeiDou. Для распознавания столбов были использованы Cascading Fusion Attention (CFA) и улучшенная версия DarkNet53 на основе YOLOv3, при этом значение F достигло 85,1%. Для определения наклона столба применялись алгоритм Canny и метод обнаружения прямых линий LSD, которые использовались для выделения центральной линии и вычисления угла наклона. Итоговая точность метода составила 87,4%.

Таким образом, основные существующие методы для задач определения наклона столба линии связи – БПЛА с камерой, 2D+3D облака точек, LiDAR-Based, глубокое обучение+изображения, NB-IoT и т.п. Каждый метод имеет компромиссы между точностью, стоимостью и сложностью. Для высокой точности идеальными являются методы на основе LiDAR или интеграция 2D-3D облака точек, в то время как глубокое обучение и обработка изображений предлагают масштабируемые и экономически эффективные альтернативы. Современные методы в основном используют сегментацию или обнаружение краев, использование новейших нейросетевых моделей обнаружения объектов – подход, который может потенциально повысить точность.

Целью исследования является предложение нового эффективного метода для определения наклона опор ВЛС с использованием БПЛА, который выполняет инспекцию опор и собирает видеоданные о состоянии элементов опор ВЛС. Для

обеспечения стабильности и точности предсказания координат опор ВЛС применён метод оптического потока, который позволяет вычислять межкадровое расстояние, пройденное БПЛА между кадрами [18].

Предлагаемый метод актуален для решения растущей потребности в автоматизированном и экономически выгодном мониторинге углов наклона объектов инфраструктуры. Его новизна заключается в использовании YOLOv8-Pose для детекции опор для задачи оценки наклона столба, который пока недостаточно исследован в данной области. Однако YOLOv8 хорошо показал свою эффективность в таких задачах, как обнаружение посторонних предметов на линии электропередачи на основе аэрофотоснимков [19], обнаружения опор линий электропередач на основе оптических спутниковых изображений [20].

Материалы и методы

Предлагаемый метод основан на использовании БПЛА и современных методов компьютерного зрения для контроля наклона ВЛС. Процесс представлен в виде последовательности этапов (рис.1).

Этапы контроля наклона столба ВЛС:

- Пролет БПЛА над опорами ВЛС на заданном маршруте. На борту БПЛА находится GPS-датчик и камера, которые отвечают за формирование необходимых для анализа состояния опор данных. Сбор видеоданных о визуальном состоянии опор.

- Обработка каждого кадра видеоряда моделью YOLOv8-pose. Модель детектирует опоры ВЛС на изображении, а также ключевые точки: основание и вершину опоры.

- Вычисления географических координат для каждой опоры ВЛС по координатам объекта на изображении.

- Повторный пролет БПЛА по определенным на предыдущем шаге координатам опор.

- Детекция опор ВЛС на полученном видеоряде.

- Данные из нейронной сети используются для расчета угла наклона опоры ВЛС. Для каждой опоры определяется, насколько опасно она наклонена.



Рис. 1. Блок-схема метода для определения наклона столба линии связи

Fig. 1. Block diagram of the method for determining the inclination of a communication line pole

Таким образом, метод состоит из 3 шагов: вычисление координат и привязка к карте; детекция опор ВЛС с использованием YOLO-v8-Pose; определение угла наклона опоры ВЛС по выведенной формуле (1).

YOLO-v8-Pose

YOLO-Pose [21] представляет собой подход для детекции ключевых точек на 2D изображении, интегрированный в архитектуру YOLO для детектирования объектов. В отличие от традиционных подходов, использующих тепловые карты и постобработку, YOLO-Pose позволяет обходиться без них. Основная задача подхода напрямую оптимизировать метрику Object Keypoint Similarity (OKS) в процессе обучения, что повышает его устойчивость и эффективность в решении задач оценки ключевых точек. YOLO-Pose использует архитектуру YOLO, что позволяет одновременно детектировать и определять позы нескольких людей за один цикл работы модели. Это упрощает процесс, устраняя необходимость в многократных вычислениях и группировке ключевых точек.

В YOLO-Pose математическая модель основывается на принципах якорей для определения поз и оптимизации функции потерь через OKS. Для каждого обнаруженного объекта на изображении создается якорь, который хранит полную 2D-позу и ограничивающую рамку. Координаты рамки трансформируются относительно центра якоря, а ключевые

точки предсказываются относительно этого центра.

YOLO-Pose использует Complete IoU (CIoU) для оптимизации ограничивающих рамок. Функция потерь CIoU формулируется следующим образом:

$$\mathcal{L}_{CIoU}(x, y, w, h) = 1 - CIoU(\text{predicted box}, \text{ground truth box})$$

Здесь (x, y, w, h) представляют координаты центра и размеры рамки. $CIoU$ учитывает геометрическую близость и размер, что помогает модели лучше справляться с различиями в масштабах.

В отличие от традиционной L1-функции потерь, YOLO-Pose оптимизирует OKS, что улучшает регрессию ключевых точек. Формула OKS рассматривается аналогично IoU, где каждая ключевая точка взвешивается в зависимости от её значимости:

$$\mathcal{L}_{OKS} = 1 - \sum_i \exp\left(-\frac{d_i^2}{2s_i^2}\right) \cdot I(v_i > 0).$$

Здесь d_i – расстояние между предсказанным и истинным положением ключевой точки i ; s_i – фактор масштабирования, а $I(v_i > 0)$ – индикатор видимости точки. Такой подход позволяет учитывать как масштаб объекта, так и значимость каждой ключевой точки, что повышает точность определения положения объектов. Полная функция потерь в YOLO-Pose сочетает ошибки предсказания ограничивающих рамок и ключевых точек, применяя весовые коэффициенты для обеспечения сбалансированного вклада каждого компонента.

Метод оптического потока

Потребность в оценке межкадрового движения БПЛА возникает из-за отсутствия обновленных координат для каждого кадра. Для определения межкадрового расстояния используется метод оптического потока, который позволяет анализировать перемещение объекта между последовательными кадрами.

Для вычисления плотного оптического потока используется Farneback Algorithm [22]. Этот алгоритм позволяет оценивать движение каждого пикселя в последовательности изображений, аппроксимируя локальные изменения интенсивности с помощью квадратичного полинома. Это дает возможность учитывать сложные движения и получать детализированные векторные поля для перемещений между кадрами.

Алгоритм предполагает, что интенсивность пикселя $I(x, y)$ в окрестности точки (x, y) может быть аппроксимирована квадратичной функцией:

$$I(x) \approx x^T A x + b^T x + c,$$

где x – вектор положения пикселя; A – симметричная матрица; b – вектор; c – скаляр. Это позволяет локально аппроксимировать изменение интенсивности с учетом всех направлений.

В случае сдвига изображения на Δx , интенсивность в новой позиции представляется следующим образом:

$$I(x + \Delta x) \approx (x + \Delta x)^T A (x + \Delta x) + b^T (x + \Delta x) + c.$$

Сравнение интенсивности между двумя кадрами позволяет оценить величину и направление сдвига Δx , что соответствует вектору потока.

Для учета движения на различных масштабах алгоритм использует гауссову пирамиду. На каждом уровне пирамиды изображение уменьшается, что позволяет обнаруживать как мелкие, так и крупные движения. Грубая оценка поля потока выполняется на самом низком уровне и затем постепенно уточняется по мере перехода к более высоким уровням разрешения.

В алгоритме используется итеративный процесс для уточнения значений вектора потока, минимизируя разницу между интенсивностями в последовательных кадрах. Каждое уточнение основывается на использовании производных, что позволяет учитывать небольшие смещения. Чтобы минимизировать влияние шума применяются сглаживающие фильтры, что способствует стабилизации значений оптического потока и улучшению точности оценки.

Этот алгоритм позволяет получить плотное поле оптического потока, что делает его эффективным для задач анализа движения объектов, стабилизации видеопотока и отслеживания перемещений. Применение квадратичной аппроксимации и многоуровневого подхода позволяет достичь высокой точности и учитывать сложные движения.

Определение координат и привязка к карте

Для определения координат опор ВЛС используются несколько параметров: локализация основания опоры на изображении в пикселях (x, y) , ширина и высота изображения в пикселях (W_{image}, H_{image}) , ширина и высота сенсора камеры в мм (W_{sensor}, H_{sensor}) , фокусное расстояние камеры в мм (F) .

Система рассчитывает фокусное расстояние камеры в пикселях f_x и f_y для осей x и y , используя физические параметры камеры:

$$f_x = F \cdot \frac{W_{image}}{W_{sensor}},$$

$$f_y = F \cdot \frac{H_{image}}{H_{sensor}}.$$

Каждый кадр видео обрабатывается моделью YOLOv8-Pose, которая определяет координаты основания и вершины опоры ВЛС, а также граничную рамку (x_1, x_2, x_3, x_4) . Для определения координат используется только основание опоры ВЛС. Для каждого обнаруженного объекта его координаты на изображении (x, y) преобразуются в реальные координаты относительно координат камеры. Смещения (dx, dy) от центра изображения рассчитываются как:

$$dx = -\frac{(c_x - x)}{f_x}, \quad dy = -\frac{(c_y - y)}{f_y},$$

где (c_x) и (c_y) – координаты центра изображения. С учётом высоты БПЛА (h) , координаты в мировой системе от-

носительно камеры (X_{world}, Y_{world}) можно вычислить через глубину (расстояние до объекта):

$$X_{world} = dx \cdot h,$$

$$Y_{world} = dy \cdot h.$$

Здесь предполагается, что в связанной системе координат начальные значения крена, тангажа и рысканья БПЛА равны нулю и остаются неизменными в течение полета. Для получения координат в широте и долготе используется радиус Земли $R=6378137$ м. Смещения Δlat и Δlon объекта рассчитываются:

$$\Delta lat = \frac{Y_{world}}{R},$$

$$\Delta lon = \frac{X_{world}}{R \cdot \cos(lat_{drone})}.$$

Итоговые географические координаты объекта будут равны:

$$lat_{object} = lat_{drone} + \Delta lat,$$

$$lon_{object} = lon_{drone} + \Delta lon.$$

Межкадровое движение БПЛА определяется анализом оптического потока, который показывает среднее смещение по осям x и y , avg_flow_y и avg_flow_x :

$$\Delta lat_{drone} = \frac{avg_flow_y \cdot s_y}{R} \cdot \frac{180}{\pi},$$

$$\Delta lon_{drone} = \frac{avg_flow_x \cdot s_x}{R \cdot \cos(lat_{drone})} \cdot \frac{180}{\pi},$$

где s_x и s_y – размеры одного пикселя на сенсоре камеры по осям x и y . Эти величины используются для определения нового положения БПЛА.

Определение угла наклона опоры

Пусть известны высота полета БПЛА, фокусное расстояние камеры, высота столба и смещение верхушки столба на изображении. Необходимо определить угол наклона опоры ВЛС θ , зная следующие параметры: высота полета БПЛА над основанием столба – H_d ; высота столба – H_p ; фокусное расстояние камеры – f ; смещение верхушки столба на изображении относительно основания – s . БПЛА находится прямо над основанием опоры на высоте H_d .

Опора наклонена под углом θ относительно вертикали. Верхушка опоры смещается от основания на расстояние D :

$$D = H_p \sin(\theta).$$

Вертикальная высота верхушки опоры относительно основания:

$$Z_{top} = H_p \cos(\theta).$$

Расстояние от камеры до верхушки столба вдоль оси Z :

$$Z_{camera} = H_d - Z_{top} = H_d - H_p \cos(\theta).$$

Горизонтальное смещение верхушки столба относительно основания в плоскости XY :

$$X_{top} = D = H_p \sin(\theta).$$

Согласно принципам перспективной проекции, смещение объекта на изображении связано с его реальными координатами:

$$s = f \cdot \frac{X_{top}}{Z_{camera}} = f \cdot \frac{H_p \sin(\theta)}{H_d - H_p \cos(\theta)}.$$

Из равносильных преобразований можно заметить, что

$$sH_p \cos(\theta) + fH_p \sin(\theta) = sH_d.$$

Решая уравнение, получаем выражение для определения угла наклона столба ВЛС:

$$\theta = \arctan\left(\frac{f}{s}\right) \pm \arccos\left(\frac{sH_d}{H_p \sqrt{s^2 + f^2}}\right). \quad (1)$$

Таким образом, общий алгоритм для определения наклона опор ВЛС для набора изображений:

1. Автоматическая обработка каждого изображения из набора данных;
2. Применение нейронной сети для получения координат и расчёта смещения s .
3. Перевод смещения в реальное расстояние – использование формулы реального смещения (в метрах) объекта в пространстве, учитывая параметры камеры.
4. Расчёт угла наклона – подстановка данных в формулу угла θ и перевод результатов из радиан в градусы.

Результаты и их обсуждение

Для обучения модели использовался набор данных из 686 исходных изображений. Для повышения обобщающей способности модели изображения были аугментированы, с увеличением размера набора данных до 1494 изображений. Аугментация позволяет значительно увеличить объем обучающей выборки, а также позволить модели более эффективно научиться обобщению на данных. Среди использованных методов аугментации были применены:

- Изменение оттенка изображения (от -17° до $+17^\circ$);

- Изменение насыщенности изображения (От -31% до +31%);
- Изменение яркости изображения (От -15% до +15%);
- Изменение экспозиции изображения (От -5% до +5%);
- Размытие изображения (до 0,8px);
- Добавление шума (0,22%).

Для каждой опоры на изображении была выделена ограничивающая рамка, а также две ключевые точки (рис. 2).



Рис. 2. Пример предсказания модели YOLOv8-Pose

Fig. 2. Example of YOLOv8-Pose model prediction

Состав итогового набора данных приведен в табл. 1.

Таблица 1. Размеры датасетов

Table 1. Dataset sizes

Размер тренировочного набора данных	1308 изображений
Размер валидационного набора данных	124 изображений
Размер тестового набора данных	62 изображений

Графики обучения представлены на рис. 3. Модели демонстрируют ее способность адаптироваться к данным и применять полученные знания в различных ситуациях. Графики разделены на две группы: метрики потерь на тренировочной выборке (верхняя строка) и на валидационной выборке (нижняя строка).

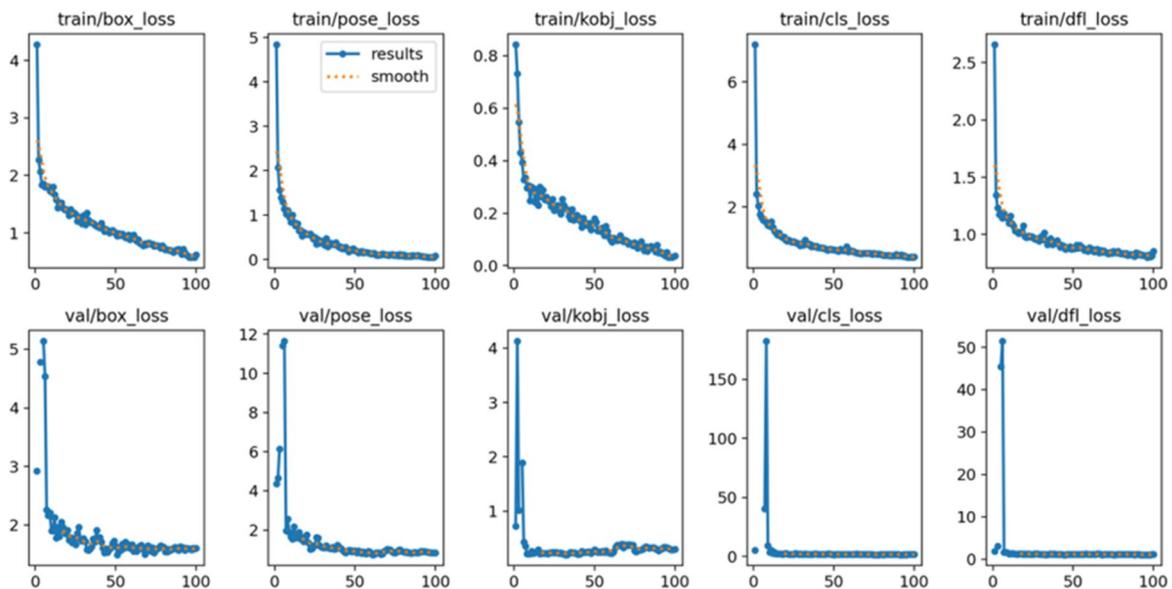


Рис. 3. Графики обучения модели

Fig. 3. Model training schedules

По результатам обучения, точность по метрике mean Average Precision (mAP) 0,71 для детекции опор, что свидетельствует о необходимости дополнительного обучения модели на более обширном наборе данных. На данный момент этот недостаток компенсируется применением метода кластеризации и его усредняющей функции.

Vox_loss и характеризует качество предсказания координат ограничивающих рамок. Потери на тренировочной выборке демонстрируют плавное снижение, что свидетельствует об успешном обучении модели в отношении локализации объектов. На валидационной выборке также наблюдается уменьшение значений потерь. $Pose_loss$ описывает качество предсказания позы (в частности, вершины и основания). На тренировочной выборке потери постепенно уменьшаются, что указывает на улучшение точности. На валидационной выборке в начале обучения видны скачки, которые позже стабилизируются, что может быть связано с процессом адаптации модели. $Kobj_loss$ оценивает качество предсказания вероятности наличия объекта в ограничивающей рамке. Потери на тренировочной выборке снижаются плавно, демонстрируя устойчивую сходимость. На валидационной выборке наблюдается резкий спад значений в начальных эпохах обучения, после чего потери стабилизируются. Cls_loss – потери, связанные с классификацией объектов внутри рамок. На тренировочной выборке график де-

монстрирует стабильное снижение значений, в то время как на валидационной выборке наблюдается резкое снижение в начальной фазе обучения, что может быть вызвано переобучением или изменением параметров модели. Dfl_loss отражает потери, связанные с точностью предсказания вероятностного распределения локализаций. На тренировочной выборке наблюдается плавное снижение значений потерь, а на валидационной выборке, как и в предыдущих метриках, отмечается резкий спад в начале обучения. После обучения была создана матрица ошибок (рис. 4).

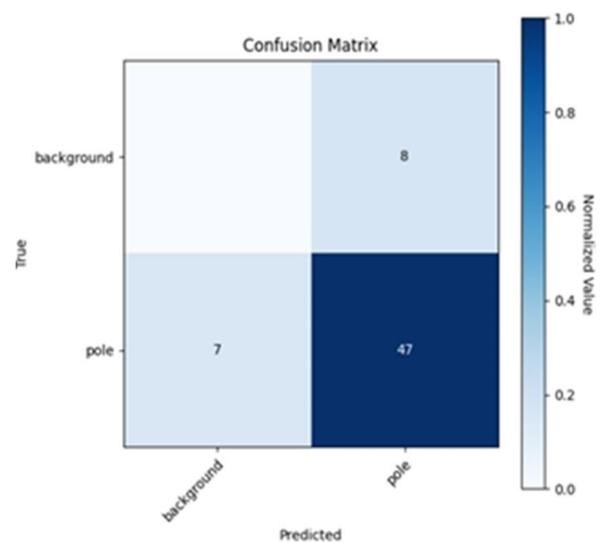


Рис. 4. Матрица ошибок

Fig. 4. Error matrix

Построение матрицы осуществлялось следующим образом: для опор, которые модель детектирует корректно $IoU \geq 0,75$, определяется как истинно положительное предсказание для класса *Pole*. Если модель ошибочно принимает фон за опору, это классифицируется как ложноположительное предсказание для *Pole* и

False Negative (ложноотрицательное) для *background*. Аналогично, если модель не распознаёт существующую опору, это считается ложно отрицательным для *Pole* и ложно положительным для *Background*. Для точности детекции вершины опоры и основания использовалась метрика F1-score. Были выбраны опоры ВЛС, предсказанные моделью корректно. Для ключевых точек рассчитывались показатели *Precision* и *Recall*, как и для задачи классификации. Если точка предсказывалась корректно, то добавлялся +1 к *TruePositive* и *TrueNegative*. В случае ошибки модели при определении точек основания и вершины, то *FalsePositiv* и *FalsePositive*.

Таким образом, точность детекции ключевых точек равна по метрике mAP 0,71. Это значение формируется за счет того, что нейронная сеть может некорректно предсказывать опоры ВЛС и, как следствие, неправильно детектировать точки. В пределах корректно предсказанной опоры точность детекции ее вершины и основания составляет 0,88 по метрике F1-score.

Расчет угла наклона столба ВЛС

Основной задачей является вычисление угла наклона столба, который можно определить с помощью геометрических формул, используя угол зрения камеры и ее положение относительно столба.

Входные данные для определения угла наклона столба: высота опоры, фокусное расстояние камеры высота поле-

та БПЛА. Формула (1) позволяет рассчитать угол наклона θ через параметры камеры, высоту БПЛА, высоту опоры и смещение s . Из изображений после применения нейронной сети получены данные о расположении ключевых точек, из которых была рассчитана величина s – смещение верхушки опоры на изображении относительно основания в пикселях.

Для определения угла наклона было взято 320 изображений. С использованием выведенной формулы для определения наклона столба ВЛС были рассчитаны их углы. В табл. 2 приведены рассчитанные результаты для 5 случайных изображений из набора данных.

Таблица 2. Результаты определения угла наклона

Table 2. The results of the tilt angle determination

θ (градусы) / θ degrees)	s (пиксели) / s (pixels)	H (м) / H (m)
5,81	78,32	35,0
4,21	32,67	30,0
2,99	2,41	32,5
3,51	11,22	34,0
1,8	56,7	3,5

Максимальный наклон столба составил $24,5^\circ$, а минимальный – $0,6^\circ$. Средний угол наклона опор для всего набора изображений составляет примерно $6,1^\circ$.

Выводы

Анализ современных подходов к мониторингу состояния воздушных линий связи выявил актуальность проблемы

обеспечения точности и автоматизации процесса. В работе предложен метод для определения наклона опор ВЛС, отличающийся применением YOLOv8-Pose для детекции ключевых точек и алгоритма оптического потока для повышения точности оценки межкадрового перемещения БПЛА. Метод обеспечивает автоматическое определение координат опор и их угла наклона на основе аэрофото-

снимков. Для расчетов была выведена формула, связывающая параметры камеры, высоту полета и смещение вершины опоры. Экспериментальные результаты продемонстрировали высокую эффективность метода. Точность детекции ключевых точек опор достигла 0,88 по метрике F1-score. Средний угол наклона опор для всего набора изображений составил примерно 6,1°.

Список литературы

1. 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): 35.
2. Паньков Д.Н., Бугорский И.А. Применение искусственного интеллекта для обнаружения дефектов воздушных линий электропередач // Перспективы развития технологий обработки и оборудования в машиностроении. 2023; 282–285.
3. Fang Z., Savkin A.V. Strategies for Optimized UAV Surveillance in Various Tasks and Scenarios: A Review // Drones. 2024; 8(5): 193.
4. Epifani L, Caruso A. A Survey on Deep Learning in UAV Imagery for Precision Agriculture and Wild Flora Monitoring: Datasets, Models and Challenges // Smart Agricultural Technology. 2024; 100625.
5. Overview of Large Scale Map Production with UAV-Based Photogrammetric Technique: A Case Study in Izmir-Cesme Territory of Turkey / Y. Yılmaz, M. Gürtürk, B. Süleymanoğlu, A. Soycan, M. Soycan // Journal of Geography and Cartography. 2023; 6(2): 2164.
6. A UAV Intelligent System for Greek Power Lines Monitoring / A. Tsellou, G. Livanos, D. Ramnalis, V. Polychronos, G. Plokamakis, M. Zervakis, K. Moirogiorgou // Sensors. 2023; 23(20): 8441.
7. Bellou E., Pisica I., Banitsas K. Aerial Inspection of High-Voltage Power Lines Using YOLOv8 Real-Time Object Detector // Energies. 2024; 17(11): 2535.
8. UAV Photogrammetry for Mapping and 3D Modeling: Current Status and Future Perspectives / F. Remondino, L. Barazzetti, F. Nex, M. Scaioni, D. Sarazzi // Proceedings of the International Conference on Unmanned Aerial Vehicle in Geomatics (UAV-g). 2011; 25–31.

9. Bhowmick S., Nagarajaiah S., Veeraraghavan A. Vision and Deep Learning-Based Algorithms to Detect and Quantify Cracks on Concrete Surfaces from UAV Videos // *Sensors*. 2020; 20(21): 6299.
10. Automatic Measurement of Inclination Angle of Utility Poles Using 2D Image and 3D Point Cloud / L. Chen, J. Chang, J. Xu, Z. Yang // *Applied Sciences*. 2023; 13(3): 1688.
11. Automatic Assessment and Prediction of the Resilience of Utility Poles Using Unmanned Aerial Vehicles and Computer Vision Techniques / M.M. Alam, Z. Zhu, B. Eren Tokgoz, J. Zhang, S. Hwang // *International Journal of Disaster Risk Science*. 2020; 11: 119–132.
12. PTTE: Power Tower Tilt Estimation Algorithm Based on LiDAR Point Cloud / F. Chen, Y. Li, F. Shuang, M. Huang // *2023 International Conference on Advanced Robotics and Mechatronics (ICARM)*. IEEE. 2023; 309–315.
13. Алгоритм определения наклона опор ЛЭП методами глубокого обучения по видеоданным / О.В. Лимановская, Е.А. Титов, Д.И. Волкова, А.В. Лемех // *Вестник Ивановского государственного энергетического университета*. 2020; (2): 72–80.
14. NB-IoT Based Method for Monitoring the Tilt Status of Transmission Towers. *Journal of Physics* / Y. Zheng, Y. Wu, J. Gao, S. Cui // *Conference Series*. IOP Publishing. 2021; 2108(1): 012033.
15. A Transmission Tower Tilt State Assessment Approach Based on Dense Point Cloud from UAV-Based LiDAR / Z. Lu, H. Gong, Q. Jin, Q. Hu, S. Wang // *Remote Sensing*. 2022; 14(2): 408.
16. Automatic Utility Pole Inclination Angle Measurement Using Unmanned Aerial Vehicle and Deep Learning / Z. Zhu, J. Zhang, M.M. Alam, B.E. Tokgoz, S. Hwang // *Proceedings of the Institute of Industrial and Systems Engineers Annual Conference*. 2019.
17. Sun L., et al. Power Tower Tilt Monitoring Method Based on Beidou and Improved YOLOv3. *AIoTC*. 2022; 58–66.
18. Yue K. Multi-Sensor Data Fusion for Autonomous Flight of Unmanned Aerial Vehicles in Complex Flight Environments // *Drone Systems and Applications*. 2024; 12: 1–12.
19. Power Transmission Lines Foreign Object Intrusion Detection Method for Drone Aerial Images Based on Improved YOLOv8 Network / H. Sun, Q. Shen, H. Ke, Z. Duan, X. Tang // *Drones*. 2024; 8(8): 346.
20. An Improved YOLOv8 Network for Detecting Electric Pylons Based on Optical Satellite Image / X. Chi, Y. Sun, Y. Zhao, D. Lu, Y. Gao, Y. Zhang // *Sensors*. 2024; 24(12): 4012.
21. YOLO-Pose: Enhancing YOLO for Multi-Person Pose Estimation Using Object Keypoint Similarity Loss / D. Maji, S. Nagori, M. Mathew, D. Poddar // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022; 2637–2646.

22. Farnebäck G. Two-Frame Motion Estimation Based on Polynomial Expansion // Image Analysis: 13th Scandinavian Conference, SCIA 2003, Halmstad, Sweden, June 29–July 2, 2003 Proceedings 13. Springer Berlin Heidelberg. 2003; 363–370.

References

1. Astapova M.A., Uzdaev M.Yu. Detection of defects in faulty elements of power lines using YOLO neural networks. *Modelirovanie, optimizatsiya i informatsionnye tekhnologii = Modeling, Optimization and Information Technologies*. 2021; 9(4): 35. (In Russ.).

2. Pankov D.N., Bugorskiy I.A. Application of artificial intelligence for defect detection in overhead power lines. *Perspektivy razvitiya tekhnologij obrabotki i oborudovaniya v mashinostroyeni* = *Perspectives of development of technologies for processing and equipment in mechanical engineering*. 2023; 282–285. (In Russ.).

3. Fang Z., Savkin A.V. Strategies for Optimized UAV Surveillance in Various Tasks and Scenarios: A Review. *Drones*. 2024; 8(5): 193.

4. Epifani L., Caruso A. A Survey on Deep Learning in UAV Imagery for Precision Agriculture and Wild Flora Monitoring: Datasets, Models and Challenges. *Smart Agricultural Technology*. 2024; 100625.

5. Yılmaz Y., Gürtürk M., Süleymanoğlu B., Soycan A., Soycan M. Overview of Large Scale Map Production with UAV-Based Photogrammetric Technique: A Case Study in Izmir-Cesme Territory of Turkey. *Journal of Geography and Cartography*. 2023; 6(2): 2164.

6. Tsellou A., Livanos G., Ramnalis D., Polychronos V., Plokamakis G., Zervakis M., Moirogiorgou K. A UAV Intelligent System for Greek Power Lines Monitoring. *Sensors*. 2023; 23(20): 8441.

7. Bellou E., Pisica I., Banitsas K. Aerial Inspection of High-Voltage Power Lines Using YOLOv8 Real-Time Object Detector. *Energies*. 2024; 17(11): 2535.

8. Remondino F., Barazzetti L., Nex F., Scaioni M., Sarazzi D. UAV Photogrammetry for Mapping and 3D Modeling: Current Status and Future Perspectives. *Proceedings of the International Conference on Unmanned Aerial Vehicle in Geomatics (UAV-g)*. 2011; 25–31.

9. Bhowmick S., Nagarajaiah S., Veeraraghavan A. Vision and Deep Learning-Based Algorithms to Detect and Quantify Cracks on Concrete Surfaces from UAV Videos. *Sensors*. 2020; 20(21): 6299.

10. Chen L., Chang J., Xu J., Yang Z. Automatic Measurement of Inclination Angle of Utility Poles Using 2D Image and 3D Point Cloud. *Applied Sciences*. 2023; 13(3): 1688.

11. Alam M.M., Zhu Z., Eren Tokgoz B., Zhang J., Hwang S. Automatic Assessment and Prediction of the Resilience of Utility Poles Using Unmanned Aerial Vehicles and Computer Vision Techniques. *International Journal of Disaster Risk Science*. 2020; 11: 119–132.
12. Chen F., Li Y., Shuang F., Huang M. PTTE: Power Tower Tilt Estimation Algorithm Based on LiDAR Point Cloud. *2023 International Conference on Advanced Robotics and Mechatronics (ICARM)*. IEEE. 2023; 309–315.
13. Limanovskaya O.V., Titov E.A., Volkova D.I., Lemeh A.V. Algorithm for determining the inclination of power line supports using deep learning methods on video data. *Vestnik Ivanovskogo gosudarstvennogo energeticheskogo universiteta = Bulletin of Ivanovo State Power University*. 2020; (2): 72–80. (In Russ.).
14. Zheng Y., Wu Y., Gao J., Cui S. NB-IoT Based Method for Monitoring the Tilt Status of Transmission Towers. *Journal of Physics: Conference Series. IOP Publishing*. 2021; 2108(1): 012033.
15. Lu Z., Gong H., Jin Q., Hu Q., Wang S. A Transmission Tower Tilt State Assessment Approach Based on Dense Point Cloud from UAV-Based LiDAR. *Remote Sensing*. 2022; 14(2): 408.
16. Zhu Z., Zhang J., Alam M.M., Tokgoz B.E., Hwang S. Automatic Utility Pole Inclination Angle Measurement Using Unmanned Aerial Vehicle and Deep Learning. *Proceedings of the Institute of Industrial and Systems Engineers Annual Conference*. 2019.
17. Sun L., Ma C., Hu H., Ni T., Zhang M., Zhang Z. Power Tower Tilt Monitoring Method Based on Beidou and Improved YOLOv3. *AIoT*. 2022; 58–66.
18. Yue K. Multi-Sensor Data Fusion for Autonomous Flight of Unmanned Aerial Vehicles in Complex Flight Environments. *Drone Systems and Applications*. 2024; 12: 1–12.
19. Sun H., Shen Q., Ke H., Duan Z., Tang X. Power Transmission Lines Foreign Object Intrusion Detection Method for Drone Aerial Images Based on Improved YOLOv8 Network. *Drones*. 2024; 8(8): 346.
20. Chi X., Sun Y., Zhao Y., Lu D., Gao Y., Zhang Y. An Improved YOLOv8 Network for Detecting Electric Pylons Based on Optical Satellite Image. *Sensors*. 2024; 24(12): 4012.
21. Maji D., Nagori S., Mathew M., Poddar D. YOLO-Pose: Enhancing YOLO for Multi-Person Pose Estimation Using Object Keypoint Similarity Loss. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022; 2637–2646.
22. Farneback G. Two-Frame Motion Estimation Based on Polynomial Expansion. In: *Image Analysis: 13th Scandinavian Conference, SCIA 2003, Halmstad, Sweden, June 29–July 2, 2003 Proceedings 13*. Springer Berlin Heidelberg. 2003; 363–370.

Информация об авторах / Information about the Authors

Заикин Михаил Игоревич, ведущий программист лаборатории автономных робототехнических систем, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН), г. Санкт-Петербург, Российская Федерация, e-mail: zmaik@live.com, ORCID: <http://orcid.org/0009-0001-8149-5804>.

Астапова Марина Алексеевна, младший научный сотрудник лаборатории технологий больших данных социоконвергентных систем, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН), г. Санкт-Петербург, Российская Федерация, e-mail: astapova.m@iias.spb.su, ORCID: <http://orcid.org/0000-0002-9121-894X>

Волков Данила Михайлович, младший научный сотрудник лаборатории автономных робототехнических систем, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН), г. Санкт-Петербург, Российская Федерация, e-mail: volkov.d@iias.spb.su, ORCID: <http://orcid.org/0009-0003-5030-677X>

Mikhail I. Zaikin, Lead Programmer of the Autonomous Robotic Systems Laboratory, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS), St. Petersburg, Russian Federation, e-mail: zmaik@live.com, ORCID: <http://orcid.org/0009-0001-8149-5804>

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 (SPC RAS), St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences, St. Petersburg, Russian Federation, e-mail: astapova.m@iias.spb.su, ORCID: <http://orcid.org/0000-0002-9121-894X>

Danila M. Volkov, Junior Researcher, Laboratory of Autonomous Robotic Systems, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS), St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences, St. Petersburg, Russian Federation, e-mail: volkov.d@iias.spb.su, ORCID: <http://orcid.org/0009-0003-5030-677X>