

Управление в технических системах Control in technical systems

Научная статья
УДК 004.032.26
DOI: 10.14529/ctcr260202

АДАПТИВНЫЙ ГИБРИДНЫЙ АЛГОРИТМ ЛОКАЛИЗАЦИИ КЛЮЧЕВЫХ ТОЧЕК ДЛЯ НАВИГАЦИИ ЛЕТАТЕЛЬНОГО АППАРАТА С ОЦЕНКОЙ КАЧЕСТВА ИЗОБРАЖЕНИЯ

А.А. Замышляева, zamyshliaevaaa@susu.ru, <https://orcid.org/0000-0002-4530-4820>

А.А. Кузнецов, kuznetsovaa@susu.ru

Южно-Уральский государственный университет, Челябинск, Россия

Аннотация. В условиях повышения требований к точности и надежности навигации летательных аппаратов (ЛА) при наличии в видеопотоке шумов различной природы актуальной является задача разработки алгоритмов, сочетающих высокую работоспособность нейросетевых методов в сложных условиях видеосъемки с высокой точностью классических подходов в благоприятных условиях. **Цель исследования:** разработать и валидировать адаптивный гибридный алгоритм. Данный алгоритм должен комбинировать помехоустойчивую нейросетевую детекцию (на базе LND-Net) с субпиксельным уточнением классическими методами (алгоритм Canny) на основе анализа локального качества изображения, повышая надежность навигации в сложных условиях. **Материалы и методы.** Предложен гибридный подход, в котором первичные координаты ключевых точек (углов маркеров) определяются нейронной сетью (LND-Net). Для оценки качества изображения в окрестности каждой точки (область 10×10 пикселей) применяется критерий бимодальности гистограммы яркости. При наличии выраженной бимодальности активируется классический контур: применяются адаптивные пороги по методу Otsu и детектор границ Canny для уточнения координат. В зашумленной среде (унимодальное распределение) координаты от нейросети используются без изменений. Для инвариантной к масштабу оценки точности локализации введена метрика SIOKS. Валидация проводилась на наборах данных, включающих эталонные изображения и кадры с синтетическими помехами (гауссов шум, размытие, туман), а также в условиях частичного перекрытия маркера. **Результаты.** Проведен анализ влияния качества изображения на локализационные ошибки (с использованием метрики SIOKS). Показано, что предложенный гибридный алгоритм сохраняет точность, близкую к классическим методам в идеальных условиях (средняя SIOKS $\sim 0,010-0,013$), и сохраняет работоспособность в зашумленных средах, где классические методы отказываются, полагаясь на помехоустойчивый нейросетевой компонент. **Заключение.** Разработанный адаптивный алгоритм успешно разрешает фундаментальный компромисс между субпиксельной точностью классических методов компьютерного зрения и высокой помехоустойчивостью нейронных сетей. Предложенный критерий бимодальности гистограммы доказал свою эффективность в качестве быстрого и надежного триггера для переключения режимов обработки в реальном времени. Обоснована методика валидации, связывающая пиксельную точность с анализом локального качества изображения, что имеет критическое значение для корректной работы бортовых систем видеонаблюдения и навигации летательных аппаратов.

Ключевые слова: оценка точности, нейронные сети, компьютерное зрение, летательный аппарат, навигация, графические маркеры, ключевые точки, бортовые системы видеонаблюдения

Для цитирования: Замышляева А.А., Кузнецов А.А. Адаптивный гибридный алгоритм локализации ключевых точек для навигации летательного аппарата с оценкой качества изображения // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». 2026. Т. 26, № 2. С. 16–29. DOI: 10.14529/ctcr260202

ASSESSMENT OF THE ACCURACY OF LOCALIZATION OF KEY POINTS OF REFERENCE MARKERS BY A NEURAL NETWORK ALGORITHM WHEN ANALYZING VIDEO FROM ON-BOARD CAMERAS OF AN AIRCRAFT

A.A. Zamyshlyayeva, zamyshliaevaaa@susu.ru, <https://orcid.org/0000-0002-4530-4820>

A.A. Kuznetsov, kuznetsovaa@susu.ru

South Ural State University, Chelyabinsk, Russia

Abstract. In the context of increasing requirements for the accuracy and reliability of aircraft navigation in the presence of various types of noise in the video stream, the problem of developing algorithms that combine the high performance of neural network methods in complex video shooting conditions with the high accuracy of classical approaches in favorable conditions is highly relevant. **Aim.** To develop and validate an adapted hybrid algorithm. This algorithm should combine noise-robust neural network detection (based on LND-Net) with subpixel refinement of classical methods (the Canny algorithm) based on local image quality analysis, increasing detection reliability in challenging conditions. **Materials and methods.** A hybrid approach is proposed in which the primary coordinates of keypoints (marker corners) are determined by a neural network (LND-Net). A bimodality criterion for the brightness histogram is used to assess image quality in the vicinity of each point (a 10×10 pixel region). In the presence of pronounced bimodality, a classical contour is activated: adaptive thresholds based on the Otsu method and a Canny edge detector are used to refine the coordinates. In a noisy environment (unimodal distribution), the coordinates from the neural network are used unchanged. The SIOKS metric is introduced for scale-invariant localization accuracy assessment. Validation was conducted on datasets including reference images and frames with synthetic noise (Gaussian noise, blur, and fog), as well as under conditions of partial marker occlusion. **Results.** An analysis of the impact of image quality on localization errors (using the SIOKS metric) is conducted. It is shown that the proposed hybrid algorithm maintains accuracy close to that of classical methods under ideal conditions (average SIOKS ~ 0.010 – 0.013) and ensures robust operation in noisy environments where classical methods fail, relying on a robust neural network component. **Conclusion.** The developed adaptive algorithm successfully resolves the fundamental tradeoff between the subpixel accuracy of classical computer vision methods and the high noise immunity of neural networks. The proposed histogram bimodality criterion has proven its effectiveness as a fast and reliable trigger for switching processing modes in real time. A validation methodology linking pixel accuracy with local image quality analysis is substantiated, which is critical for the correct operation of onboard video surveillance and aircraft navigation systems.

Keywords: accuracy assessment, neural networks, computer vision, aircraft, navigation, graphic markers, key points, onboard video surveillance systems

For citation: Zamyshlyayeva A.A., Kuznetsov A.A. Assessment of the accuracy of localization of key points of reference markers by a neural network algorithm when analyzing video from on-board cameras of an aircraft. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*. 2026;26(2):16–29. (In Russ.) DOI: 10.14529/ctcr260202

Введение

В настоящее время бортовые системы видеонаблюдения летательных аппаратов становятся неотъемлемой частью современных систем навигации и стабилизации [1]. Одной из ключевых задач таких систем является точное определение положения и ориентации летательного аппарата относительно опорных графических маркеров, размещаемых на земле или на целевых объектах [2]. Традиционные методы (например, детекторы ArUco) теряют эффективность в условиях шумов, размытия и сложного освещения [3]. Напротив, нейросетевые подходы демонстрируют высокую работоспособность за счет возможности аппроксимировать сложные нелинейные зависимости [4, 5], однако часто уступают в точности локализации в идеальных условиях. Этим объясняется высокий интерес исследователей и разработчиков к использованию сверточных (CNN) и трансформерных архитектур нейронных сетей для решения задач компьютерного зрения на борту летательных аппаратов, в том числе для локализации объектов и ключевых точек [6]. В данном контексте под объектами понимаются целевые элементы сцены (например, визуальные маркеры),

относительно которых осуществляется навигация. Ключевыми точками называют характерные, локально уникальные особенности этих объектов (в данном исследовании – углы маркеров), корректная детекция которых на изображении позволит восстановить положение в пространстве летательного аппарата.

Однако применение нейросетевых алгоритмов порождает новую задачу – необходимость оценки погрешности определения координат ключевых точек [7]. Эта оценка критична для последующего использования координат маркеров при коррекции навигационной системы летательного аппарата. Ошибки в определении положения ключевых точек в видеопотоке напрямую трансформируются в ошибки навигационного решения, что может привести к недопустимым отклонениям от заданной траектории полета и нестабильности в контуре управления [8]. При этом степень влияния ошибок локализации маркеров на точность навигации зависит не только от абсолютной величины ошибок обнаружения, но и от их статистических характеристик, распределения ошибок по различным комбинациям условий съемки, а также от применяемых методов фильтрации и интеграции измерений на борту, таких как расширенный фильтр Калмана для комлексирования данных и видеосистемы [9, 10].

Целью исследования является повышение точности и надежности навигации БПЛА в сложных условиях посредством создания адаптивного гибридного алгоритма, комбинирующего нейросетевую детекцию [11] с уточнением классическими методами на основе анализа локального качества изображения. В статье рассмотрены вопросы формирования тестовых наборов данных, содержащих синтетические и реальные видеозаписи с маркерами [12], введена формализованная метрика для инвариантной к масштабу оценки точности детекции, проведена систематизация источников ошибок при обнаружении ключевых точек, а также обоснована необходимость и методика проведения валидации нейросетевого алгоритма применительно к задачам коррекции навигационной системы летательного аппарата.

1. Алгоритм анализа зашумленных видеоданных

Ранее в исследовании [11] авторами была продемонстрирована высокая работоспособность модифицированной сети YOLOv11 (LND-Net) при наличии сильных атмосферных помех. Однако анализ выявил, что данная помехоустойчивость достигается ценой снижения точности и появления систематического смещения в определении координат в идеальных условиях, где традиционные алгоритмы работают точнее, но теряют работоспособность при определенном уровне шума.

Очевидно, что ни один из подходов не является универсальным решением. Это подводит нас к необходимости разработки адаптивного гибридного алгоритма, который сочетал бы в себе сильные стороны обоих методов: высокую точность классических алгоритмов в благоприятных условиях и отказоустойчивость нейросетевой детекции в зашумленной среде. Идея состоит в том, чтобы делегировать принятие решения о выборе метода специализированному блоку оценки качества изображения. Однако глобальная оценка всего кадра малоэффективна, поскольку помехи могут быть локальными. Для принятия решения о переключении между нейросетевым и классическим режимом (уточнением) в реальном времени требуется быстрая и надежная метрика оценки локального качества изображения в окрестности ключевой точки. Сравнительный анализ метрик качества на валидационной выборке показал преимущество использования критерия бимодальности (анализ гистограммы яркости, надежность > 94 %) перед метриками резкости (лапласиан, ~ 85 %) и локального контраста (RMS, ~ 91 %), что и определило выбор метода. Предлагается проверка критерия бимодальности распределения в окрестности каждой потенциальной ключевой точки, детектированной нейронной сетью. Сеть, разработанная в [11], обладая высокой помехоустойчивостью, выступает в роли «постановщика задачи»: она предоставляет первоначальные, пусть и не всегда самые точные, координаты ключевых точек. Эти координаты затем используются как центры областей интереса для более детального анализа. Для оценки качества изображения в окрестностях ключевых точек предлагается использовать анализ формы гистограммы яркости. Функциональная схема разработанного гибридного метода, иллюстрирующая потоки данных и логику переключения между нейросетевым и классическим контурами обработки, представлена на рис. 1. Детальный алгоритм работы блока «Анализ гистограммы», основанный на проверке критериев бимодальности, подробно описан в разделе «Блок оценки качества изображения».

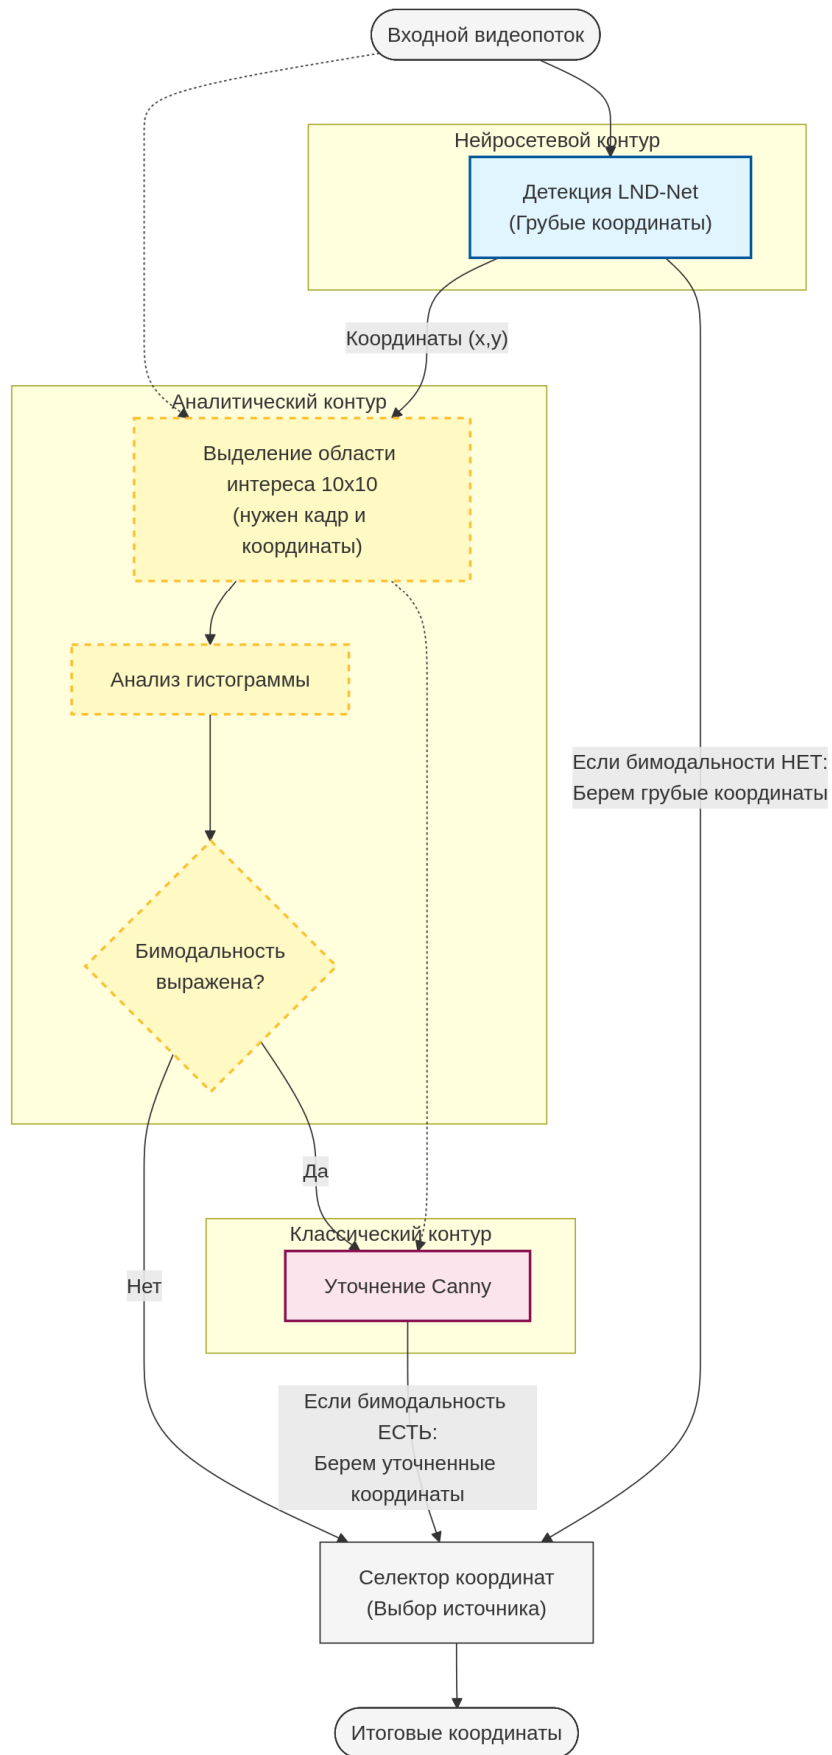


Рис. 1. Функциональная схема адаптивного гибридного алгоритма
Fig. 1. Functional diagram of the adaptive hybrid algorithm

Блок оценки качества изображения

В качестве примера, иллюстрирующего логику работы блока оценки качества изображения, рассмотрим этап детекции ключевых точек навигационного маркера. Под ключевыми точками в данной задаче понимаются углы контрастного маркера. Сам маркер необходим как референсный объект с заранее известными размерами, что позволит через решение задачи PnP (Perspective-n-Point) однозначно восстанавливать положение и ориентацию летательного аппарата в пространстве. На рис. 2 представлено исходное входное изображение высокого качества без помех, в центре которого расположен целевой навигационный маркер.




Рис. 2. Изображение без шумов
Fig. 2. Noise-free image

Для принятия решения о том, что изображение не имеет значительных помех и классические алгоритмы обеспечат более высокую точность, проводится анализ локальных областей вокруг ключевых точек (рис. 3), детектированных нейронной сетью. В качестве метрики используется анализ гистограммы яркости и текстуры в окрестности каждой точки.




Рис. 3. Изображение с навигационными точками, полученные через нейросеть
Fig. 3. An image with navigation points obtained through a neural network

Вокруг координат, предсказанных нейросетью, формируется область интереса размером 10×10 пикселей, как проиллюстрировано на рис. 4 (верхние фрагменты). Данная размерность выбрана экспериментально как оптимум: выборка из 100 пикселей статистически достаточна для

формирования репрезентативной гистограммы и идентификации бимодальности, но при этом минимизирует вероятность захвата посторонних объектов фона, характерную для окон большего размера. Оценка вычислительных затрат на целевой платформе NVIDIA Jetson Orin NX показала, что анализ гистограммы для выбранной области занимает менее 10 мкс ($< 0,01$ мс). Это значение на три порядка меньше времени обработки одного кадра используемой нейросети LND-Net, которое составляет $\sim 18\text{--}22$ мс. Столь низкие накладные расходы (менее 0,1 % от времени обработки кадра) гарантируют работу алгоритма в реальном времени без внесения ощутимых задержек в контур управления бортового вычислителя.



Рис. 4. Окрестности ключевых точек
Fig. 4. The vicinity of key points

Как видно из нижних фрагментов, представленных на рис. 4, выделенные окрестности предварительно конвертируются в полутоновое представление для алгоритма оценки гистограммы яркости. Размер окна 10×10 также выполняет функцию неявного пространственного фильтра: если вследствие расфокусировки, смаза движения или других шумов ширина переходной зоны градиента становится сопоставимой с размером окна, более 3–5 пикселей, гистограмма теряет бимодальность, вырождаясь в унимодальное распределение «серых» тонов. В этом случае система классифицирует область как непригодную для классического уточнения и сохраняет нейросетевую оценку, избегая генерации ложных координат на размытых границах. Пример гистограммы яркости окрестности ключевой точки показан на рис. 5.

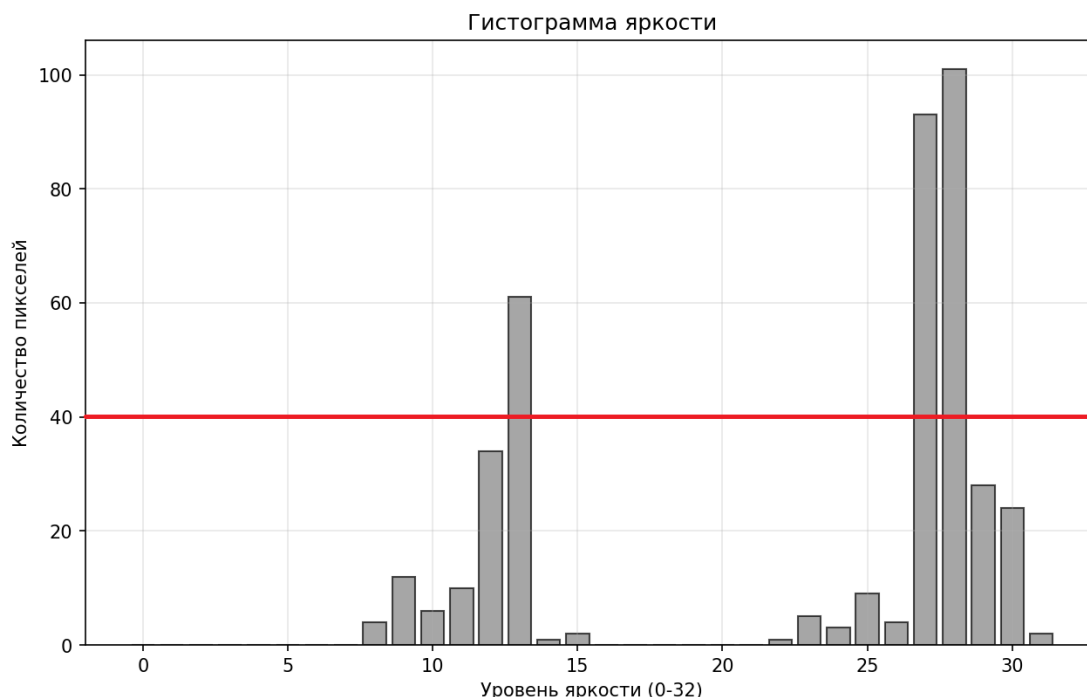


Рис. 5. Гистограмма яркости окрестности ключевой точки
Fig. 5. Histogram of the brightness of the key point neighborhood

Как показано на рис. 5, в благоприятных условиях гистограмма характеризуется выраженной бимодальностью: два пика (чёрная и светлая части маркера) четко разделены областью низких значений – «долиной». Для исключения шума квантования учитываются только локальные максимумы, превышающие адаптивный порог ($\frac{1}{5}$ от высоты гистограммы). Наличие глубокой доли-

ны между пиками подтверждает высокую контрастность границы, необходимую для работы классических алгоритмов.

Анализ гистограммы проводится следующим образом. Пусть $H(i)$ – количество пикселей с яркостью i . Для устранения шума квантования выполняется сглаживание гистограммы фильтром Гаусса ($\sigma = 3$). Далее проверяется выполнение следующих критериев бимодальности:

- 1) число локальных максимумов гистограммы $H(i)$, выделенных после сглаживания, равно 2;
- 2) $|p_1 - p_2| > T_{distance}$, где p_1, p_2 – позиции пиков (значения интенсивности), а $T_{distance} = 30\%$ – диапазон интенсивностей. Этот критерий гарантирует, что пики не слиплись;
- 3) $\min_{p_1 < i < p_2} (H(i)) < 0,3 \max (H(p_1), H(p_2))$. Данный критерий формализует требование к «глубине долины», гарантируя, что долина между пиками достаточно выражена.

При ухудшении условий съемки (размытие, туман) четкая граница размывается, вследствие чего бимодальное распределение гистограммы деградирует в унимодальное (одногорбое). Как показано на рис. 6, гистограмма имеет единственный, часто широкий, пик, обычно локализованный в области полутонов.

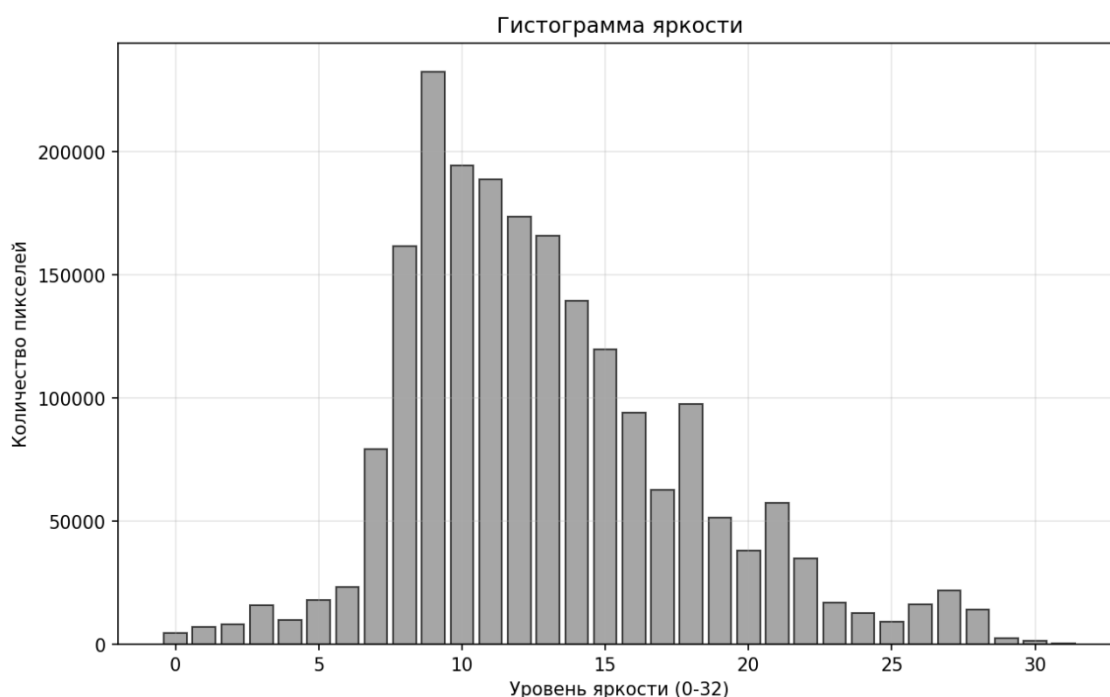


Рис. 6. Гистограмма яркости окрестности ключевой точки с зашумлением
Fig. 6. Histogram of the brightness of a noisy keypoint neighborhood

Для изображений, гистограмма яркости которых была классифицирована как выраженно бимодальная (согласно критериям, описанным выше), применяется автоматизированный подход к выбору порогов для алгоритма Кенни [13]. Метод Otsu [14] минимизирует межклассовую дисперсию и оптимален именно для бимодальных распределений. В условиях унимодального распределения (зашумленные сцены) метод может выдавать нестабильные пороги. Поэтому применение Otsu активируется только при подтверждении бимодальности через описанные выше критерии.

Для бимодальных гистограмм адаптивные пороги вычисляются на основе глобального порога Otsu (T_{otsu}). Значение нижнего порога $t_{low} = 0,5T_{otsu}$ выбрано экспериментально, показав максимальную F-меру (0,94).

Данная методология позволяет использовать статистические свойства самого изображения для определения границ и, соответственно, углов, где верхний порог идентифицирует достоверные «сильные» ребра, соответствующие границе между классами, а нижний порог обеспечивает трассировку и включение связанных с ними «слабых» ребер, повышая таким образом надежность и воспроизводимость детекции контуров.

Оценка погрешности поиска ключевых точек при различных параметрах зашумления

В рамках данного исследования для расчета погрешности, не зависящей от размера объекта на изображении, авторами предложена метрика $SIOKS_i$, которая имеет вид

$$SIOKS_i = \frac{a_i}{b_i},$$

где i – индекс ключевой точки; a_i – евклидово расстояние между предсказанной A_i и размеченной B_i ключевыми точками с индексом i ; b_i – евклидово расстояние между размеченной ключевой точкой с индексом i и противоположной ей относительно центра размеченной ключевой точкой (рис. 7).

Для оценки стабильности и надежности алгоритма недостаточно анализа единичных ошибок. Необходимо оценить статистические характеристики погрешности на репрезентативном наборе данных. Для этой цели вычисляется 95%-ный доверительный интервал для математического ожидания (истинного среднего) погрешности $SIOKS$.

Для установления базовых показателей точности и экспериментальной проверки тезиса о компромиссе между помехоустойчивостью и точностью был проведен анализ работы алгоритмов в идеальных условиях и в условиях с окклюзией ключевых точек маркера (случай, при котором классические методы не работают). Использовались эталонные изображения высокого качества, не содержащие синтетических или естественных шумов, на которых навигационные маркеры четко различимы.

На рис. 8 представлены 95%-ные доверительные интервалы для относительной ошибки $SIOKS$, вычисленной для каждой из четырех ключевых точек маркера в идеальных условиях. Сравнение проводилось между классическим методом, реализованным в библиотеке OpenCV, и разработанной авторами нейросетевой архитектурой LND-Net (модификацией YOLOv11) [11].




Рис. 7. Пример возможной работы нейронной сети
Fig. 7. An example of how a neural network might work




Рис. 8. Доверительные интервалы для ошибок детекции при идеальных условиях для нейросети и классических методов
Fig. 8. Confidence intervals for detection errors under ideal conditions for neural networks and classical methods

Рис. 8 демонстрирует явное преимущество классического метода в идеальных условиях: верхняя граница доверительного интервала ошибки не превышает ~0,013. Нейросетевой подход,

напротив, показывает в 2,5–3 раза более широкие интервалы (до $\sim 0,034$), что свидетельствует о существенно меньшей точности и стабильности позиционирования при отсутствии помех.

После анализа идеальных условий рассмотрим еще один критически важный для практического применения сценарий – частичную окклюзию маркера (рис. 9). В таких условиях классические методы, основанные на поиске замкнутых контуров или анализе углов (например, OpenCV), мгновенно перестают работать. Они либо не обнаруживают маркер вовсе, либо, что хуже, выдают ошибочные координаты, так как структура угла, которую они ищут, нарушена. Нейросетевой компонент, напротив, демонстрирует ключевое преимущество – помехоустойчивость. Нейросеть сохраняет функциональность при окклюзии одной из четырех ключевых точек.



Рис. 9. Пример маркера с перекрытием ключевой точки
Fig. 9. An example of a marker with a keypoint overlap

Однако анализ (рис. 10) показывает, что ошибка локализации для перекрытой точки возрастает до 15 % (с SIOKS от 0,034 до 0,039). При этом видимые точки показывают рост ошибки менее чем на 5 %, что указывает на относительную помехоустойчивость внутреннего представления маркера в сети.




Рис. 10. Доверительные интервалы для ошибок детекции в условиях перекрытия ключевой точки маркера для нейросети и классических методов
Fig. 10. Confidence intervals for detection errors under conditions of overlapping marker keypoints for neural networks and classical methods

Это незначительное снижение точности (15 % для одной точки) является допустимой платой за сохранение полной работоспособности системы в сценарии, который является фатальным для классических подходов. Более того, эта ошибка может быть эффективно компенсирована на следующем этапе обработки (например, в расширенном фильтре Калмана) за счет использования временной когерентности и данных от трех других, точно локализованных, точек.

На рис. 11 представлены 95%-ные доверительные интервалы для относительной ошибки SIOKS, вычисленной для каждой из четырех ключевых точек маркера в идеальных условиях. Сравнение проводилось между классическим методом, реализованным в библиотеке OpenCV, и гибридным алгоритмом на основе LND-Net.




Рис. 11. Доверительные интервалы для ошибок детекции при идеальных условиях для гибридного метода с использованием LND-Net и классических методов
Fig. 11. Confidence intervals for detection errors under ideal conditions for a hybrid method using LND-Net and classical methods

Анализ рис. 11 показывает, что гибридный алгоритм в идеальных условиях достигает точности, близкой к классическому методу на основе OpenCV. Это закономерно, так как архитектура гибрида подразумевает прямое использование классического алгоритма для уточнения координат ключевых точек при идеальных условиях. Незначительное расхождение доверительных интервалов объясняется не качеством самого вычисления, а редкими ошибками модуля принятия решений, когда система ошибочно оставалась на базовой нейросетевой оценке (LND-Net), не переключившись на точный классический метод.

Результаты анализа базовых показателей точности наглядно демонстрируют, что использование исключительно нейросетевого метода для всех режимов работы нецелесообразно. Точность LND-Net в благоприятных условиях, уступающая классическим методам, может оказаться недостаточной для задач высокоточной навигации, где ошибки локализации напрямую транслируются в ошибки навигационного решения. Полученные данные подтверждают необходимость использования разработанной гибридной схемы: при выявлении «благоприятных» условий (на основе анализа гистограммы) активация модуля уточнения методом Санны позволяет компенсировать погрешность нейросети, обеспечивая точность, сопоставимую с классическими алгоритмами, без потери общей помехоустойчивости системы.

Для валидации эффективности предложенного гибридного алгоритма был проведен эксперимент на синтетически зашумленных данных. В качестве основы использовался фрагмент видео длиной в 100 кадров, записанный во время испытаний демонстратора двигательной установки. На исходное видео последовательно накладывались три типа слабовыраженных помех: аддитивный гауссов шум с низкой дисперсией, незначительное размытие по Гауссу и имитация легкого тумана. Важно подчеркнуть, что интенсивность всех помех умышленно подбиралась такой, чтобы визуальное качество изображения оставалось высоким, создавая, таким образом, условия, в кото-

рых стандартные алгоритмы компьютерного зрения демонстрируют максимальную точность и превосходят по этому показателю чисто нейросетевой подход из [1]. Это позволило проверить ключевое преимущество гибридной системы – способность корректно идентифицировать «благоприятную» среду и переключаться на более точный метод.

На рис. 12 (низкий уровень тумана) и рис. 13 (низкий уровень размытия) представлено прямое сравнение относительной ошибки SIOKS для двух методов: эталонного классического (OpenCV) и предлагаемого гибридного алгоритма.

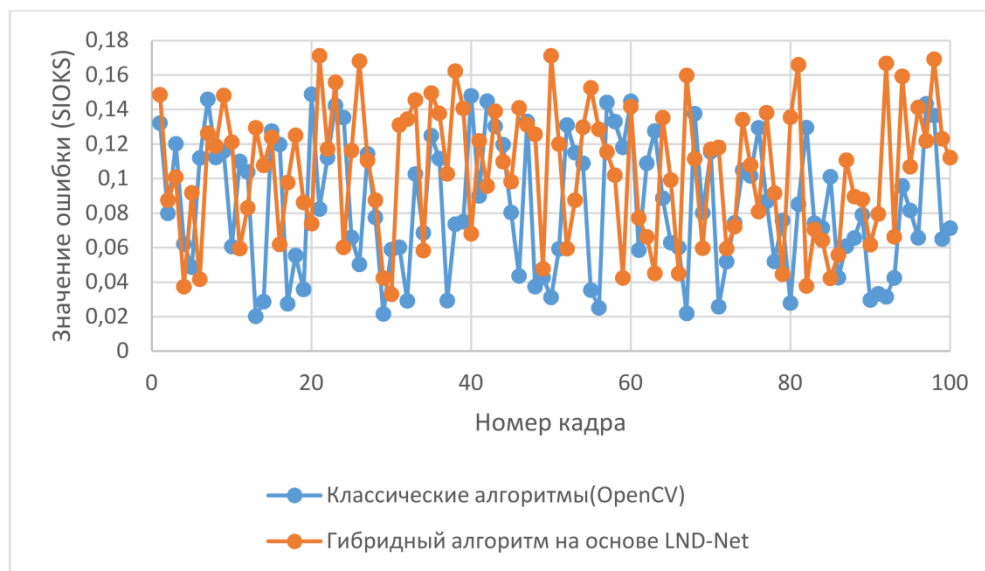


Рис. 12. Значения ошибки при низком уровне тумана
Fig. 12. Low fog level error values




Рис. 13. Значения ошибки при низком уровне размытия
Fig. 13. Error values at low blur levels

Графики на рис. 12, 13 демонстрируют, что при слабых помехах гибридный алгоритм вплотную приближается по точности к классическому методу. Это подтверждает эффективность критерия бимодальности: система успешно идентифицирует пригодные кадры и активирует уточнение. Незначительное отставание объясняется редкими ошибками классификатора 1-го рода (False Negative), когда благоприятные кадры ошибочно обрабатываются без уточнения, используя только нейросетевую оценку.

Рис. 14 представляет результаты ключевого валидационного теста, проверяющего вторую, не менее важную, функцию гибридного алгоритма: способность избежать применения классических методов в условиях, где они заведомо неэффективны и могут привести к деградации решения.




Рис. 14. Значения ошибки при низком уровне шума Гаусса
Fig. 14. Error values at low Gaussian noise levels

В условиях аддитивного гауссова шума, как показано на рис. 14, классические градиентные методы теряют работоспособность из-за множества ложных микроградиентов. Гибридный алгоритм, идентифицировав сцену как зашумленную (отсутствие бимодальности), корректно блокирует этап уточнения и полагается исключительно на нейросетевую оценку. Это обеспечивает существенно лучшую точность (SIOKS) и меньшую дисперсию ошибки по сравнению с классическим подходом, подтверждая способность системы избежать деградации решения в сложных условиях.

Заключение

В работе предложен и протестирован гибридный алгоритм для навигации автономных БПЛА, призванный разрешить фундаментальный компромисс между помехоустойчивостью нейросетевых методов и точностью классических алгоритмов компьютерного зрения в благоприятных условиях. Разработанный подход совмещает разработанный авторами нейросетевой детектор LND-Net, обеспечивающий работоспособность при сильных помехах, и адаптивный модуль принятия решений, управляющий активацией точных классических алгоритмов. В основе работы модуля принятия решений в режиме реального времени лежит проверка критерия бимодальности локальных гистограмм яркости, что позволяет автоматически активировать субпиксельное уточнение только при наличии четких границ и блокировать его при шумах.

Экспериментальная валидация на синтетических данных, имитирующих слабовыраженные помехи (гауссов шум, размытие, туман), подтвердила эффективность предложенного решения. В условиях, где чисто нейросетевой метод [11] начинает уступать в точности, гибридный алгоритм корректно переключался на стандартные алгоритмы и успешно идентифицировал высокое качество изображения, тем самым демонстрируя более высокую точность позиционирования. Это доказывает, что система достигла своей основной цели – обеспечения высокой помехоустойчивости в сложных условиях при сохранении субпиксельной точности в благоприятных средах.

Таким образом, представленный гибридный алгоритм предлагает гибкое и эффективное решение для навигации в изменчивой внешней среде, согласуясь с актуальными исследованиями, подтверждающими высокую алгоритмическую устойчивость глубоких нейросетевых моделей при анализе изображений сложной структуры [15]. Перспективы дальнейших исследований

видятся в усовершенствовании модуля принятия решений за счет введения более сложных признаков и машинного обучения, а также в проведении натуральных испытаний в реальных сценариях с динамически меняющимися погодными условиями.

Список литературы/References

1. Wang N.-Q., Chen Y.-H., Hsu C.-T., Chuang J.-H. Vision-Based UAV Navigation Using Multi-Intensity Illumination and Fiducial Markers in GPS-Denied Environments. *Research Square*. 2025. DOI: 10.21203/rs.3.rs-7301312/v1
2. Raxit, S., Singh S.B., Al Redwan Newaz A. YoloTag: Vision-Based Robust UAV Navigation with Fiducial Markers. *ArXiv preprint: arXiv:2409.02334*. 2024. DOI: 10.48550/arXiv.2409.02334
3. Lai T. Real-Time Aerial Detection and Reasoning on Embedded-UAVs. *ArXiv preprint: arXiv:2305.12414*. 2023. DOI: 10.48550/arXiv.2305.12414
4. Yao B., Wang W., Wang Z., Song Q. UVPose: A Real-Time Key-Point-Based Skeleton Detection Network for a Drone Countermeasure System. *MDPI Drones*. 2025;9(3):214. DOI: 10.3390/drones9030214
5. Huang S., Gong M., Tao D. A Coarse-Fine Network for Keypoint Localization. In: *2017 IEEE International Conference on Computer Vision (ICCV)*. Venice, Italy, 2017. P. 3047–3056. DOI: 10.1109/ICCV.2017.329
6. 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 (ECCV)*. 2016. DOI: 10.1007/978-3-319-46448-0_2
7. Billot B., Muthukrishnan R., Abaci-Turk E., Grant P.E., Ayache N., Delingette H., Golland P. Spatial Regularisation for Improved Accuracy and Interpretability in Keypoint-Based Registration. *ArXiv preprint: arXiv:2503.04499*. 2025. DOI: 10.48550/arXiv.2503.04499
8. Shankar R., Prachand C., Singh J., Abhishek, Venkatesh K.S. Vision-based Landing of UAV on Simulated Ship Deck with Roll, Pitch and Sway Motions. In: *Proceedings of the Vertical Flight Society 81st Annual Forum & Technology Display*. 2025. P. 1–16. DOI: 10.4050/F-0081-2025-0358
9. Yang X., Mejias L., Garratt M. Multi-sensor data fusion for UAV navigation during landing operations. In: *Proceedings of the 2011 Australasian Conference on Robotics and Automation (ACRA 2011)*. Melbourne, VIC: Monash University, 2011. P. 1–10.
10. Xing B., Zhu Q., Pan F., Feng X. Marker-Based Multi-Sensor Fusion Indoor Localization System for Micro Air Vehicles. *MDPI Sensors*. 2018;18(6):1706. DOI: 10.3390/s18061706
11. Кузнецов, А.А. Алгоритм анализа зашумленных видеоданных для навигации автономных роботов // Вестник ЮУрГУ. Серия «Математика. Механика. Физика». 2025. Т. 17, № 3. С. 38–46. [Kuznetsov A.A. Algorithm for analyzing noisy video data for autonomous robots navigation. *Bulletin of the South Ural State University Series "Mathematics. Mechanics. Physics"*. 2025;17(3):38–46. (In Russ.)]. DOI: 10.14529/mmph250304
12. Menze M., Geiger A. Object Scene Flow for Autonomous Vehicles. In: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, MA, USA, 2015. P. 3061–3070. DOI: 10.1109/CVPR.2015.7298925
13. Canny J. A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1986;PAMI-8(6):679–698. DOI: 10.1109/TPAMI.1986.4767851
14. Otsu N. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*. 1979;9(1):62–66. DOI: 10.1109/TSMC.1979.4310076
15. Клестов Р.А., Ключев А.В., Столбов В.Ю. Алгоритмическая устойчивость нейронных сетей глубокого обучения при распознавании микроструктуры материалов // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». 2021. Т. 21, № 1. С. 159–166. [Klestov R.A., Klyuev A.V., Stolbov V.Yu. Algorithmic Stability of Deep Learning Neural Networks in Recognizing the Microstructure of Materials. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*. 2021;21(1):159–166. (In Russ.)]. DOI: 10.14529/ctcr210114

Информация об авторах

Замышляева Алена Александровна, д-р физ.-мат. наук, проф., директор института естественных и точных наук, Южно-Уральский государственный университет, Челябинск, Россия; zamyshlyaeva@susu.ru.

Кузнецов Антон Андреевич, инженер научной лаборатории «Системы управления летательными аппаратами», Южно-Уральский государственный университет, Челябинск, Россия; kuznetsova@susu.ru.

Information about the authors

Alena A. Zamyshlyeva, Dr. Sci. (Phys. and Math.), Prof., Director of the Institute of Natural Sciences and Mathematics, South Ural State University, Chelyabinsk, Russia; zamyshlyaeva@susu.ru.

Anton A. Kuznetsov, Engineer of the Scientific Laboratory “Aircraft Control Systems”, South Ural State University, Chelyabinsk, Russia; kuznetsova@susu.ru.

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации.

Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article.

The authors declare no conflicts of interests.

Статья поступила в редакцию 19.12.2025

The article was submitted 19.12.2025