

УДК 004.932.2

МЕТОДЫ ОПРЕДЕЛЕНИЯ ГРАНИЦ ОБЛАСТЕЙ НА ОСНОВЕ ДАННЫХ АЭРОФОТОСЪЕМКИ ЗЕМНОЙ ПОВЕРХНОСТИ

Тюрикова В. А., студент гр. ИВМ-25, I курс

Научный руководитель: Гусаров А. В., канд. техн. наук, доцент
Рыбинский государственный авиационный технический университет
имени П. А. Соловьева, г. Рыбинск

Беспилотные летательные аппараты (БПЛА) все шире применяются для решения задач мониторинга земной поверхности, картографирования и автономной навигации.

Ключевым этапом обработки аэрофотоснимков в этих задачах является выделение границ объектов — от полей и дорог до зданий и водных объектов. Однако качество работы существующих алгоритмов сильно зависит от условий съемки. Классические детекторы (Кэнни, Собель) требуют ручной настройки и теряют точность при изменении освещения или появлении шумов. Современные методы глубокого обучения показывают высокую точность, но обладают вычислительной сложностью, не позволяющей реализовать их на борту малых БПЛА.

Данная работа посвящена систематизации факторов, влияющих на устойчивость выделения границ, и обзору современных адаптивных подходов, позволяющих повысить надежность обработки в изменчивых условиях аэрофотосъемки.

Основные факторы, влияющие на качество работы алгоритма и его устойчивость, включают атмосферные и погодные условия, освещение, технические параметры съемки, а также характеристики местности и объектов. Рассмотрим подробнее каждый из них.

1. Атмосферные и погодные условия.

Облачность существенно влияет на уровень освещения, изменяет цветопередачу и создает тени, которые могут восприниматься как ложные границы. Туман «размывает» изображение. Осадки, такие как дождь и снег, создают блики и шумы, а высокая влажность может привести к запотеванию линз камеры.

2. Освещение.

Угол падения солнечных лучей играет роль в формировании теней, которые могут как подчеркивать, так и маскировать границы объектов. При низком солнце создаются длинные тени, а при высоком — короткие. Утренние и вечерние часы характеризуются «мягким» светом с преобладанием теплых тонов и минимально контрастных теней, полдень — «жестким» светом с максимально контрастными тенями.

3. Технические параметры съемки.

Высота полета влияет на масштаб изображения и его детализацию. С увеличением высоты снижается детализация, но увеличивается охват территории, что в свою очередь заставляет границы мелких объектов «сливаться». Высокая скорость БПЛА и вибрации платформы приводят к смазыванию изображения и размытию границ. Разрешение камеры и характеристики сенсора также играют важную роль, так как от них зависит детализация и уровень шума.

4. Характеристики местности и объектов.

Контрастность текстур влияет на восприятие объектов. Границы между объектами с резко различной текстурой, например, асфальт и трава, выделяются легко, тогда как между объектами со схожей текстурой, например, разные типы почвы или породы деревьев, сложнее. Собственные тени объектов могут усиливать их границы, а падающие тени от других объектов создавать ложные границы или маскировать истинные. Динамические объекты, например, транспорт, животные или люди, на одиночных снимках создают размытые границы. Также сезонные изменения состояния растительности существенно влияют на визуальное восприятие границ, такие как листва или голые ветки, сухая или зеленая трава, а снежный покров может маскировать истинные границы объектов.

Далее рассмотрим современные подходы, позволяющие повысить надежность обработки в изменчивых условиях аэрофотосъемки.

Классические градиентные операторы (Собеля, Превитта, Робертса), основываются на одном из базовых свойств сигнала яркости – разрывности [1]. Наиболее общим способом поиска разрывов является обработка изображения с помощью скользящей маски, или фильтра, которая представляет собой некую квадратную матрицу, соответствующую указанной группе пикселей исходного изображения. Такие операторы просты в реализации и обладают низкой вычислительной сложностью. Однако они чувствительны к шуму и не обладают адаптивностью к изменяющимся условиям съемки.

Наиболее подходящим, для выделения границ в данной ситуации мог бы стать детектор границ Кэнни. Данный оператор включает пять последовательных шагов: сглаживание фильтром Гаусса, которое необходимо для удаления лишнего шума, затем вычисление градиента, при этом границы отмечаются там, где градиент изображения максимален, далее подавление немаксимумов, двойную пороговую фильтрацию, где потенциальные границы определяются порогами, и гистерезис, который завершает работу алгоритма и отсекает все границы, несвязные с сильными [2].

При этом шумоподавление может привести к разрушению границ в точках соединений и скруглению углов объектов на итоговом изображении. Также данный алгоритм зависит от трёх параметров: верхнего порога, нижнего порога и размера фильтра Гаусса, и, соответственно, требует точной их настройки, что не подходит для изменчивых условий съемки.

Следующим методом для выделения границ на изображении является вейвлет-преобразование — это математический метод анализа, который поз-

воляет одновременно исследовать как частотные характеристики сигнала, так и их положение во времени [3]. В процедурах обработки изображений, вейвлет-преобразование используется для уменьшения уровня шумов, анализа текстур, выделения границ объектов и сжатия изображений.

Вейвлет выделяет границу на основе перепада яркости и коэффициентов детализации. Если на изображении присутствует чёткая граница, то значение коэффициентов будет высоким. Если же границы нет или она смазанная, то значение будет малым. Соответственно, если на изображении будет множество текстур с яркими контрастами, например, лес или вспаханное поле, то в итоге может быть обнаружено много ложных границ.

В итоге вейвлет-методы имеют более высокую вычислительную сложность по сравнению с классическими градиентными операторами, что может ограничивать их применение в системах реального времени на борту БПЛА, а также склонен к появлению ложных границ.

Для выделения границ на изображении также можно рассмотреть алгоритмы сегментации, такие как пороговая сегментация, алгоритм водораздела и *Mean Shift*. После их выполнения изображение разбивается на множество областей, на которых можно выделить границы объектов, используя простые алгоритмы, рассмотренные выше, например, детектор Кэнни.

Пороговая сегментация (глобальная и адаптивная) проста и быстра, а также эффективна для изображений, где объект и фон четко разделены по яркости, например, темный объект на светлом фоне при равномерном освещении [4]. Для разделения изображения на области используется пороговое значение. Для его автоматического вычисления может использоваться классический метод Оцу, который определяет оптимальный глобальный порог, на основе гистограммы яркости пикселей изображения. При этом, если изображение контрастно, то на гистограмме будут присутствовать два пика, один в области темных пикселей, другой – в области светлых. Идеальное значение порога подбирается так, чтобы минимизировать дисперсию между этими пиками. Если же снимок сделан в туман, то два выраженных пика пропадают и метод Оцу не может корректно определить порог. Следовательно данный метод не подходит для выделения границ в изменчивых погодных условиях.

Алгоритм водораздела интерпретирует изображение как топографическую карту, где интенсивность пикселей соответствует высоте рельефа: высокие значения — вершины и холмы, а низкие — долины [5]. Алгоритм как будто заливает карту водой, начиная с долин и постепенно поднимая уровень воды. В местах столкновения образующихся бассейнов формируется граница. Данный метод хорошо подходит для задач, где объекты имеют чёткие границы и соприкасаются. В случае, если изображение имеет сложную текстуру, образуется большое количество ложных долин, что приводит к разбиению на тысячи мелких областей, в которых теряются истинные границы.

Mean Shift группирует пиксели по схожим признакам, на основе плотности их распределения [6]. В результате работы алгоритма – изображение с однородными областями. В качестве признаков выступают координаты пик-

селя и его цвет (*RGB*), соответственно при обработке больших изображений потребуются высокие вычислительные затраты из-за необходимости обрабатывать каждый пиксель в 5-мерном пространстве признаков. Также у данного метода есть недостаток, если объект на изображении состоит из нескольких контрастных областей, то в результате работы алгоритма объект будет разделен на области.

Предпоследний рассмотренный метод это сверточные нейронные сети для семантической сегментации (*U-Net*, *DeepLab*), которые решают задачу пиксельной классификации, формируя выходную маску, где каждому пикселю присвоена метка класса [7].

U-Net состоит из энкодера (*Contracting Path*), декодера (*Expanding Path*) и скип-соединения (*Skip Connections*). Энкодер извлекает признаки из изображения, постепенно уменьшая размер изображения. Декодер восстанавливает размер изображения, пытаясь предсказать класс для каждого пикселя. Скип-соединение соединяет энкодер и декодер, позволяют передавать признаки с уровней энкодера в декодер, тем самым сохраняя мелкие детали объектов.

В основе *DeepLab* лежат пространственное пирамидальное свертывание (*Atrous Spatial Pyramid Pooling*, *ASPP*), позволяющее захватывать объекты разных размеров на изображении, декодирующие модули для восстановления пространственного разрешения изображения и улучшения качества сегментации, а также нейронные сети для извлечения признаков, обученные на задачах классификации [8].

Достоинствами такого подхода являются высокая точность и устойчивость, а недостатками потребность в большом объеме размеченных данных и высокая вычислительная сложность, которая делает подход не применимым на борту малых БПЛА.

В завершении рассмотрим гибридные методы, которые объединяют классические методы обработки изображений с моделями машинного обучения (*ML*-модель). В основе данного метода три этапа: предварительная обработка информации, детальный анализ и прогнозирование результата на основе полученных данных. Данные этапы настраиваются в зависимости от решаемой задачи. В данном случае, например, можно использовать комбинацию вейвлет-преобразования для извлечения признаков на изображении с анализом этих признаков обученной *ML*-моделью для финального выделения границ объектов.

Преимущества таких методов в балансе производительности, адаптивности и меньшей потребности в данных [9]. Однако они имеют архитектурную сложность (необходимость проектирования и интеграции нескольких компонентов) и, как правило, не достигают пиковых показателей моделей глубокого обучения.

На основе рассмотренных методов проведем сравнительный анализ методов выделения границ объектов на изображении по критериям точности,

устойчивости, вычислительной сложности, адаптивности и возможности применения на БПЛА. Результаты представлены в таблице 1.

Таблица 1 – Результаты анализа

Метод	Точность	Устойчи- вость	Вычисли- тельная сложность	Адаптив- ность	Возмож- ность при- менения на БПЛА
Оператор Кэнни	Средняя	Средняя	Средняя	Средняя	Средняя
Вейвлет- преобразование	Высокая	Высокая	Высокая	Средняя	Средняя
Алгоритм водо- раздела	Средняя	Низкая	Высокая	Низкая	Низкая
<i>Mean Shift</i>	Высокая	Высокая	Высокая	Средняя	Низкая
<i>U-Net, DeepLab</i>	Высокая	Высокая	Высокая	Высокая	Низкая
Гибридный под- ход	Высокая	Высокая	Средняя	Высокая	Высокая

Анализ показывает, что ни один из существующих методов не удовлетворяет всем требованиям одновременно. Классические операторы (Собель, Кэнни) и пороговая сегментация обладают низкой вычислительной сложностью и применимы на борту БПЛА, но страдают от низкой адаптивности и устойчивости. Вейвлет-методы, водораздел и *Mean Shift* дают лучшую точность и устойчивость, но имеют высокую вычислительную сложность. Глубокие нейронные сети (*U-Net, DeepLab*) обеспечивают максимальную точность и адаптивность, однако ресурсоемкость делает их трудноприменимыми на малых БПЛА.

Наиболее перспективным является гибридный подход, обеспечивающий высокую точность и адаптивность при средней вычислительной сложности, что позволяет реализовать его на борту БПЛА с ограниченными ресурсами.

В работе проведена систематизация факторов, влияющих на устойчивость выделения границ при аэрофотосъемке с БПЛА. Выделены четыре группы факторов: атмосферные и погодные условия, освещение, технические параметры съемки, а также характеристики местности и объектов. Выполнен обзор и сравнительный анализ существующих методов. Установлено, что классические методы обладают низкой адаптивностью, а методы глубокого обучения — чрезмерной вычислительной сложностью, что препятствует их применению на борту малых БПЛА. Гибридные подходы признаны наиболее сбалансированным решением, обеспечивающим высокую точность, устойчивость и адаптивность при умеренных вычислительных затратах.

Список литературы:

1. Хабр. Алгоритмы выделения контуров изображений [Электронный ресурс], URL: <https://habr.com/ru/articles/114452/> (дата обращения 29.03.2026).
2. Хабр. Детектор границ Канни [Электронный ресурс], URL: <https://habr.com/ru/articles/114589/> (дата обращения 29.03.2026).
3. Хабр. Вейвлет – анализ. Основы [Электронный ресурс], URL: <https://habr.com/ru/articles/449646/> (дата обращения 29.03.2026).
4. Хабр. Сегментация изображения [Электронный ресурс], URL: <https://habr.com/ru/articles/128768/> (дата обращения 29.03.2026).
5. Хабр. Обзор алгоритмов сегментации [Электронный ресурс], URL: <https://habr.com/ru/companies/intel/articles/266347/> (дата обращения 29.03.2026).
6. Scikit-learn. MeanShift [Электронный ресурс], URL: <https://scikit-learn.org/stable/modules/generated/sklearn.cluster.MeanShift.html> (дата обращения 29.03.2026).
7. Хабр. Эволюция архитектур нейросетей в компьютерном зрении: сегментация изображений [Электронный ресурс], URL: <https://habr.com/ru/companies/slsoft/articles/864994/> (дата обращения 29.03.2026).
8. Dzen. DeepLab: Революция в семантической сегментации изображений — технологии и реальные примеры применения [Электронный ресурс], URL: https://dzen.ru/a/Z7Mfhze_OB7wXdyz (дата обращения 29.03.2026).
9. Fastercapital. Гибридная сегментация [Электронный ресурс], URL: <https://fastercapital.com/ru/content/Гибридная-сегментация--как-объединить-несколько-методов-и-подходов-к-сегментации.html> (дата обращения 29.03.2026).