



Ш.К. Кадиркулов¹, Ж.С. Оспанов¹, А.А. Анетбаев²

¹Military Institute of Land Forces named after S. Nurmagambetov,
Алматы, Казахстан

²Almaty Institute of Technology, Алматы, Казахстан

E-mail: ksh777@mail.ru

РАЗРАБОТКА Ψ -ДЕСКРИПТОРА ДЛЯ СИСТЕМЫ ТЕХНИЧЕСКОГО ЗРЕНИЯ ПРИВЯЗНОГО МУЛЬТИКОПТЕРА НА ОСНОВЕ МЕТОДА КЛЮЧЕВЫХ ТОЧЕК

Аннотация. В статье дается общая характеристика привязных мультикоптеров, приводятся их основные функциональные возможности, ставится задача разработки системы автономной навигации для использования в одном из сложных процессов функционирования привязных БПЛА – его посадки на землю. Для разработки системы автономной навигации предлагается использование технологии ключевых точек.

Проведен краткий обзор детекторов и дескрипторов ключевых точек. Показано, что в качестве детектора ключевых точек можно использовать детектор FAST. Однако для построения дескриптора была использована математическая модель метода Ψ -преобразований в задачах оптимизации нелинейных функций, которая легла в основу построения собственного дескриптора ключевых точек - Ψ -дескриптора.

Приведены результаты практического использования разработанного Ψ -дескриптора для решения задачи автономной навигации БПЛА. Разработанный новый метод определения ключевых точек может быть использован в системах технического зрения привязных беспилотных летательных аппаратов для решения задач посадки в качестве альтернативы штатным системам GPS.

Ключевые слова: привязной БПЛА, дескриптор, автономная навигация, ключевая точка, техническое зрение, искусственный интеллект.

Введение.

Общая характеристика привязных мультикоптеров.

В последние годы набирают популярность для гражданского и военного применения привязные мультикоптеры, или в англоязычной литературе «Tethered Drones». Привязные мультикоптеры (ПМ) — это беспилотные летательные аппараты, которые соединены с наземной станцией управления гибким кабелем (привязью).

Хотя привязные дроны ограничены кабелем питания, именно эта особенность в сочетании с искусственным интеллектом и системой

технического зрения (СТЗ) открывает для них уникальные ниши, недоступные обычным беспилотникам. Кабель обеспечивает ПМ квазипостоянное питание (время полета ограничивается лишь ресурсом двигателей и может измеряться сутками) и высокоскоростную, защищенную от помех систему управления и передачи данных. СТЗ превращает такой квадрокоптер из простого «высотного штатива для камеры» в интеллектуальный автономный центр мониторинга и аналитики. На рисунке 1 приведен общий вид привязного мультикоптера [1].

ПМ имеет следующие технические особенности:

- почти неограниченное время нахождения в воздухе: одной из больших проблем автономного квадрокоптера является система питания, в основе которой находится литий-ионный или литий-полимерный аккумулятор, запаса энергии которого хватает на 30-40 минут. ПМ получает электроэнергию от наземного источника энергии и может находиться в воздухе, пока не исчерпается механический ресурс двигателей;
- защищенный канал управления и передачи данных: управление ПМ и передача целевой информации осуществляется по медному или оптоволоконному кабелю внутри привязного кабеля.
- низкий уровень безопасности: привязной кабель ограничивает радиус полета (обычно от 50 до 150 метров), и если будет выведена из строя система питания, встроенная батарея ПМ позволит ему плавно сесть.



Рисунок 1 – Общий вид привязного мультикоптера

Одним из ключевых процессов функционирования ПМ является процесс посадки. Подавляющее большинство ПМ используют при посадке данные штатных систем GPS, однако в условиях подавления навигационных сигналов глобальных навигационных спутниковых систем надо искать альтернативные системы навигации, независимые от сигналов GPS – это является одной из главных задач этой работы.

ПМ имеет широкие функциональные возможности, основные из которых приведены в таблице 1.



Таблица 1 – Основные функциональные возможности привязных мультикоптеров

Сфера применения	Техническая спецификация	Функции
Военное дело	Непрерывный подъем ретрансляторов связи и камер над полем боя (на 50–150 метров).	Обнаружение замаскированной техники, фиксация вспышек/выстрелов, отслеживание перемещений противника, корректировка артиллерии.
Промышленный мониторинг	Длительный осмотр высоких объектов (факельные установки, градирни, ЛЭП, плотины).	Автоматическое выявление дефектов, трещин, утечек газа (в ИК-диапазоне) методами определения аномалий.
Управление агропредприятиями	Стационарный пост над полем во время посевной или сбора урожая.	Оценка плотности всходов, определение сорняков или очагов заболеваний растений на обширной территории в реальном времени.
Ликвидация ЧС и пожаротушение	Наблюдение за зоной бедствия, координация спасателей.	Сквозь дым (с помощью тепловизионной СТЗ) обнаружение очагов возгорания, прогнозирование направления распространения огня, поиск людей.

Таким образом, сочетание “неограниченной” энергии (от кабеля) и “умных глаз” системы технического зрения превращает привязной дрон из летающей камеры в полноценную роботизированную интеллектуальную систему мониторинга, способную работать автономно в режиме 24/7.

Ключевые точки в системе технического зрения привязного мультикоптера.

Одной из основных подсистем привязных мультикоптеров является система технического зрения, которая позволяет получать и распознавать цифровые изображения, полученные с цифровой камеры.

Наиболее распространенным подходом при обработке полученных камерой ПМ цифровых изображений является применение нейронных сетей, глубокого обучения и других алгоритмов искусственного интеллекта [2-6].

Из алгоритмов искусственного интеллекта наиболее часто используются сверточные нейронные сети (convolutional neuron networks - CNN) [7-11].



В последние годы начали получать большое распространение при обработке цифровых изображений методы ключевых точек (Keypoint Detection Methods) [12, 13, 14]. При обработке цифровых изображений, полученных с БПЛА, методы ключевых точек играют фундаментальную роль. Они используются для сшивания панорам (ортофотопланов), трехмерной реконструкции местности (SfM - Structure from motion), навигации в зонах без GPS/ГЛОНАСС (визуальная одометрия) и отслеживания объектов. В контексте БПЛА под методами ключевых точек понимаются алгоритмы компьютерного зрения, которые находят на изображении стабильные, уникальные и легко опознаваемые локальные особенности (углы, границы, перепады яркости) и описывают их так, чтобы их можно было сопоставить на других кадрах (даже при изменении масштаба, угла съемки или освещения).

Процесс распознавания ключевых точек обычно делится на три этапа, каждый из которых имеет свое определение:

- детектирование ключевых точек (Keypoint Detection): Алгоритмический поиск особых пикселей или областей на изображении. Ключевая точка — это точка, которая отличается от других (например, край берега, угол бордюра, одинокое дерево);

- описание ключевых точек/извлечение дескрипторов (Descriptor Extraction): Создание математического вектора (дескриптора) для каждой найденной точки. Дескриптор кодирует информацию о градиентах яркости в окрестности точки. Он должен быть инвариантен к поворотам, изменению масштаба и освещенности, что критично для БПЛА из-за постоянного крена, тангажа и изменения высоты полета;

- сопоставление точек (Keypoint Matching): Процесс поиска пар взаимно соответствующих ключевых точек на двух и более разных изображениях на основе близости их дескрипторов (например, по расстоянию Хэмминга или Евклидову расстоянию).

Приведем сравнительный анализ и отметим плюсы и минусы обработки цифровых изображений сверточными нейронными сетями и ключевыми точками.

Как уже было отмечено, обработка цифровых изображений с помощью сверточных нейронных сетей (CNN/Deep Learning) и классических методов на основе ключевых точек (Keypoints/Hand-crafted features) — это два принципиально разных подхода. Если сверточные сети «учатся» извлекать признаки сами на основе огромного количества данных, то методы ключевых точек (такие как SIFT, SURF, ORB, FAST и др.) используют строгие математические алгоритмы, заложенные разработчиками.

Приведем сравнительный анализ преимуществ и недостатков этих подходов.



1. Сверточные нейронные сети (CNN):

Плюсы:

- высокая точность в сложных задачах: CNN доминируют в семантической сегментации, классификации и детекции объектов; они способны улавливать высокоуровневые абстрактные признаки (например, контекст, текстуру, форму объекта в целом);

- автоматическое извлечение признаков (End-to-End): сеть в процессе обучения понимает, какие паттерны важны для решения конкретной задачи;

- устойчивость к вариативности данных: хорошо обученная сеть устойчива к изменению освещения, ракурса, шумам и частичному перекрытию (окклюзии) объектов;

- универсальность: одна и та же архитектура сети (например, ResNet или YOLO) может быть переобучена как на поиск дефектов на металле, так и на распознавание лиц.

Минусы:

- требовательность к ресурсам (вычислительная сложность): для обучения и работы глубоких сетей требуются мощные GPU или NPU; на «слабом железе» или микроконтроллерах запустить тяжелую сеть в реальном времени практически невозможно;

- потребность в огромных датасетах: чтобы сеть работала хорошо, нужны тысячи (или миллионы) размеченных изображений; если данных мало, сеть просто «зазубрит» их (эффект переобучения/overfitting);

- проблема «черного ящика» (отсутствие интерпретируемости): сложно математически доказать, почему сеть приняла то или иное решение - в критически важных сферах (медицина, военные системы, авиация) это огромный минус;

- длительное время обучения: процесс обучения моделей может занимать дни и недели.

2. Методы ключевых точек (Key points):

Плюсы:

- высокая скорость работы и легковесность: алгоритмы работают чрезвычайно быстро и могут выполнять вычисления в реальном времени даже на слабых процессорах (CPU) мобильных устройств, умных камер или микроконтроллеров;

- не требуют обучения и датасетов: алгоритм может работать «из коробки», ему не нужны гигабайты размеченных картинок — он просто берет два изображения и ищет на них математические соответствия;

- математическая строгость и интерпретируемость: каждый шаг (вычисление градиентов, построение гистограмм дескрипторов) прозрачен, легко понять, почему алгоритм ошибся, и скорректировать формулу или коэффициенты;

- инвариантность к геометрии: классические дескрипторы (например, SIFT) математически инвариантны к масштабированию и повороту (даже на



180°С или любой другой угол), они идеально подходят для сшивания панорам или фотограмметрии.

Минусы:

- плохо работают со сложной семантикой: ключевые точки ищут углы, перепады яркости и контрастные границы, они не понимают, что перед ними — «аэроснимок», «собака» или «человек»; если объект не имеет четких углов метод не сможет отработать;

- чувствительность к изменению света при изменении перспективы съемки (трехмерном повороте объекта) или при резком изменении теней дескрипторы точек сильно меняются, и алгоритм может потерять связь между кадрами;

- зависимость от ручной настройки: инженеру приходится вручную подбирать пороги чувствительности, фильтры шумов и параметры детектора под конкретные условия.

Можно сказать, что CNN настроены на выделение объектов, тогда как ключевые точки настроены на выделение признаков объектов.

В таблице 2 приведены основные сравнительные характеристики сверточных нейронных сетей и ключевых точек при анализе цифровых изображений.

Таблица 2 – Таблица сравнительного анализа характеристик сверточных нейронных сетей и ключевых точек

№	Критерий	Сверточные нейронные сети	Ключевые точки
1	Выявляемые ключевые признаки	Глубокие семантические признаки, контекст.	Локальные геометрические аномалии (углы, края).
2	Необходимость данных для обучения	Необходим большой размеченный датасет.	Работают на чистой математике здесь и сейчас.
3	Требования к аппаратуре	Высокие (требуется GPU/специализированные NPU).	Низкие (достаточно стандартного CPU).
4	Применение в БПЛА	Навигация, распознавание и классификация препятствий.	Одометрия, построение 3D карт в режиме реального времени, стабилизация положения БПЛА

Материалы и методы.

Обзор методов ключевых точек.

Основу распознавания особых точек на цифровом изображении составляют алгоритмы вычисления ключевых точек. Ключевые точки — это точки, которые выделяются на изображении и могут быть использованы для распознавания объектов. Методы ключевых точек играют важную роль в задачах построения 3D моделей местности, автономной навигации, обеспечивая распознавание, отслеживание и/или сопоставление объектов на сравниваемых цифровых изображениях. Эти алгоритмы могут также использоваться в различных приложениях, таких как позиционирование



робототехнических устройств, системы автоматизированного вождения автомобилей, поиск похожих изображений в Интернете, распознавание лиц, построение 3D-моделей и др.

Требования к определению ключевых точек. Для извлечения информативных признаков из цифрового изображения необходимо опираться на его локальные особенности. В качестве таких особенностей выступают ключевые (особые) точки. Под ключевой точкой понимают элемент изображения, окрестность которого существенно отличается от окрестностей других точек и может быть однозначно идентифицирована.

Обнаружение ключевых точек осуществляется с помощью специальных алгоритмов — детекторов. После обнаружения каждая точка описывается набором характеристик, называемых дескриптором.

Согласно работам [15, 16], ключевые точки должны удовлетворять следующим требованиям:

- *отличимость* — точка должна хорошо выделяться на фоне окружающих элементов и быть уникальной в пределах своей локальной области;

- *инвариантность* — обнаружение точки должно сохраняться при различных аффинных преобразованиях изображения;

- *устойчивость* — процесс выделения должен быть малочувствительным к шумам и искажениям;

- *уникальность* — помимо локальной различимости, точка должна обладать глобальной уникальностью, что позволяет корректно распознавать повторяющиеся структуры;

- *интерпретируемость* — ключевые точки должны быть пригодны для анализа соответствий между изображениями и облегчать их интерпретацию.

Процесс сопоставления изображений обычно включает три основных этапа.

На первом этапе выполняется поиск множества ключевых точек с использованием детекторов. Такие методы обеспечивают обнаружение одних и тех же характерных точек на различных изображениях объекта. Однако только детектирования недостаточно, поскольку количество найденных точек может различаться для каждого изображения. Поэтому на втором этапе для каждой найденной точки формируется дескриптор. Дескриптор представляет собой численное описание локальной области изображения, позволяющее однозначно идентифицировать точку среди множества других. Хороший дескриптор должен сохранять свою информативность при изменении масштаба, повороте и других преобразованиях изображения. Некоторые современные методы объединяют этапы детектирования и построения дескрипторов. Третий этап заключается в сравнении дескрипторов и установлении соответствий между ключевыми точками различных изображений.

Детекторы ключевых точек. Одним из основных типов особых точек являются углы. Угол представляет собой область пересечения двух или более



границ объектов. Иначе говоря, это точка, в окрестности которой интенсивность изображения изменяется сразу по нескольким направлениям.

Ключевой особенностью углов является наличие двух доминирующих направлений градиента в их окрестности, благодаря чему такие точки хорошо различимы и могут использоваться для последующего сопоставления изображений [17].

Существующие методы обнаружения ключевых точек можно разделить на три группы:

- методы, основанные на анализе интенсивности изображения;
- методы, использующие контуры объектов;
- методы, основанные на модельном представлении изображения.

Первая группа определяет особые точки непосредственно по значениям яркости пикселей. Методы второй группы выполняют поиск характерных участков на контурах объектов, например точек максимальной кривизны или пересечений контуров. Методы третьей группы используют заранее заданные модели, параметры которых подстраиваются под исследуемое изображение.

На практике наибольшее распространение получили методы, основанные на анализе интенсивности изображения, поскольку они обеспечивают хорошее соотношение между точностью и вычислительной эффективностью.

Детектор Моравеца. Детектор Моравеца является одним из первых методов обнаружения угловых точек. Его работа основана на анализе изменения яркости внутри небольшого окна при его смещении в восьми направлениях. Обычно используются окна размером 3×3 , 5×5 или 9×9 пикселей [18].

Результатом работы алгоритма является карта вероятностей, на которой точки с ненулевым откликом рассматриваются как потенциальные углы.

К недостаткам метода относятся высокая чувствительность к шумам, ограниченное количество направлений анализа и отсутствие инвариантности к повороту изображения.

Детектор Харриса. Детектор Харриса представляет собой усовершенствование метода Моравеца. В отличие от предшественника он учитывает изменения яркости по всем направлениям, что делает обнаружение углов более точным и устойчивым.

Основным преимуществом алгоритма является инвариантность к повороту изображения. Однако его эффективность снижается при значительном изменении масштаба и наличии сильного шума.

Детектор Ши–Томаси. Метод Ши–Томаси основан на детекторе Харриса и отличается способом вычисления меры отклика. Благодаря этому он обеспечивает более точное выделение угловых точек, сохраняя основные достоинства исходного подхода.

Детектор Фёрстнера. Метод Фёрстнера использует те же принципы анализа углов, что и детектор Харриса, однако предполагает явное вычисление собственных значений матрицы. Это позволяет более точно



локализовать особые точки и дополнительно обнаруживать круговые структуры.

Детектор SUSAN. Алгоритм SUSAN определяет углы на основе анализа сходства интенсивностей пикселей внутри круговой области фиксированного радиуса [19].

Для каждого пикселя формируется область сравнения, где соседние точки разделяются на похожие и непохожие относительно центрального пикселя. Углы соответствуют областям, в которых доля похожих пикселей достигает локального минимума. Для повышения устойчивости алгоритма пикселям, расположенным ближе к центру области, назначаются большие весовые коэффициенты.

Детектор FAST. Принцип функционирования детектора FAST отличается от ранее рассмотренных методов обнаружения особых точек. Его работа основана на анализе яркостей пикселей, расположенных на окружности вокруг исследуемой точки-кандидата P . Для этого используется окружность, состоящая из 16 пикселей, построенная по алгоритму Брезенхема [20].

Точка P признаётся угловой, если на данной окружности существует не менее N последовательных соседних пикселей, яркость которых либо превышает значение $(I + t)$, либо оказывается меньше значения $(I - t)$, где (I) — интенсивность центральной точки P , а (t) — заданный порог яркости.

Для повышения скорости вычислений сначала выполняется предварительная проверка четырёх пикселей окружности с номерами 1, 5, 9 и 13, расположенных по вертикали и горизонтали относительно точки P . Если как минимум три из них удовлетворяют условию $(I_i > I + t)$ или $(I_i < I - t)$, проводится полный анализ всех 16 пикселей окружности. В противном случае точка сразу отбрасывается как не являющаяся угловой. Экспериментально установлено, что минимальное значение параметра N , обеспечивающее устойчивое обнаружение особых точек, равно 9.

Алгоритм работы детектора FAST включает следующие этапы:

- 1) Выбирается пиксель изображения (p) , для которого определяется принадлежность к особым точкам. Его яркость обозначается как (I_p) .
- 2) Задаётся пороговое значение (t) .
- 3) Рассматривается окружность из 16 пикселей вокруг точки (p) .
- 4) Точка считается угловой, если на окружности присутствует не менее (n) последовательных пикселей, яркость каждого из которых больше $(I_p + t)$ либо меньше $(I_p - t)$. На практике параметр (n) обычно принимается равным 12.

Исследования показали, что устойчивое обнаружение угловых точек начинается уже при $(n = 9)$. Высокая производительность алгоритма достигается благодаря предварительной проверке только четырёх пикселей окружности. Полный анализ оставшихся двенадцати пикселей выполняется лишь для тех кандидатов, которые успешно проходят начальный тест. В противном случае алгоритм переходит к следующей точке изображения.




Рисунок 2 – Графическое отображение алгоритма FAST

Несмотря на высокую скорость работы, детектор FAST имеет ряд ограничений. В частности, его эффективность зависит от порядка обработки изображения и характера распределения яркостей пикселей. Кроме того, в пределах небольшой области изображения может быть обнаружено несколько близко расположенных особых точек, что приводит к появлению избыточных срабатываний.

Детектор SIFT. Метод SIFT был разработан для обеспечения устойчивости к изменению масштаба изображения. В его основе лежит построение пирамид Гаусса и разностей гауссианов, позволяющих выявлять характерные точки на различных уровнях масштабирования [21].

Преимуществами SIFT являются инвариантность к повороту, смещению и частичная устойчивость к изменениям масштаба, освещения и положения камеры. Основным недостатком считается высокая вычислительная сложность.

Детектор SURF. SURF является развитием идей SIFT и ориентирован на повышение производительности. Метод использует прямоугольные фильтры для приближения гауссового сглаживания и интегральные изображения, что существенно ускоряет вычисления.

Для поиска ключевых точек применяется детектор на основе матрицы Гессе. Точки выбираются по максимальному значению её определителя, который характеризует локальные изменения изображения.

Детектор BRISK. Метод BRISK был разработан как быстрый алгоритм, устойчивый к изменению масштаба. Он базируется на детекторе AGAST, являющемся развитием FAST.

В отличие от FAST, поиск особых точек выполняется не только на исходном изображении, но и в масштабном пространстве, представленном набором октав. После обнаружения кандидатов осуществляется поиск локальных максимумов во всём пространстве масштабов.

Дескрипторы ключевых точек. После обнаружения ключевых точек необходимо сформировать их описания — дескрипторы. Дескриптор представляет собой набор числовых характеристик, позволяющих отличать

одну особую точку от другой и устанавливать соответствия между изображениями [23, 24, 25].

Типовой процесс сопоставления включает следующие этапы:

- обнаружение ключевых точек;
- определение локальных областей вокруг них;
- нормализацию выделенных областей;
- вычисление дескрипторов;
- сопоставление полученных дескрипторов.

Эффективность алгоритмов сопоставления зависит как от качества обнаруженных точек, так и от выбранного способа их описания.

Дескриптор BRIEF. BRIEF представляет собой компактный бинарный дескриптор, основанный на сравнении интенсивностей пар пикселей внутри локальной области изображения.

Каждая ключевая точка кодируется бинарным вектором длиной от 128 до 512 бит. Благодаря простоте вычислений BRIEF обеспечивает высокую скорость работы, однако отличается чувствительностью к шумам и поворотам изображения [26, 27].

Дескриптор ORB. ORB является усовершенствованной версией BRIEF. Для поиска ключевых точек используется FAST, дополненный механизмом определения ориентации.

Основными преимуществами ORB являются высокая скорость работы, устойчивость к повороту изображения и низкие вычислительные затраты [28, 29].

Дескриптор SIFT. Дескриптор SIFT строится на основе локальных градиентов изображения и обладает высокой устойчивостью к изменениям масштаба, поворотам и частичным перекрытиям объектов.

Метод использует многомасштабное представление изображения, сформированное с помощью пирамиды Гаусса, что позволяет эффективно работать с объектами различного размера.

Дескриптор SURF. Работа SURF включает два этапа: обнаружение ключевых точек и их описание. Для ускорения вычислений используются интегральные изображения и приближённая матрица Гессе.

Интегральное представление позволяет быстро вычислять суммы яркостей внутри прямоугольных областей, что значительно повышает производительность алгоритма по сравнению с SIFT [30].

Выводы. Сравнение детекторов ключевых точек обычно проводится по двум основным критериям: качеству обнаружения и скорости работы.

Детектор Харриса обеспечивает хорошую устойчивость к поворотам и шумам при достаточно высокой скорости обработки. Он особенно эффективен для изображений с выраженными угловыми структурами, однако плохо справляется с масштабными изменениями.

Метод Ши–Томаси обеспечивает более высокую точность обнаружения по сравнению с Харрисом, но требует больших вычислительных затрат. Поэтому он предпочтителен в задачах, где точность важнее скорости.



Детектор FAST отличается чрезвычайно высокой производительностью и подходит для обработки видеопотока в режиме реального времени. Несмотря на меньшую точность и чувствительность к шуму, он широко применяется в системах слежения за объектами и задачах компьютерного зрения, требующих высокой скорости обработки.

С точки зрения качества детектирования, т.е. количество выявляемых ключевых точек, наилучшими детекторами являются SIFT и SURF. Однако следует отметить, что эти два детектора обладая хорошим качеством детектирования, имеют относительно невысокую скорость работы, что критично для систем реального времени, к которым относится система автономной навигации. Кроме того, эти два метода запатентованы, и для их использования требуется разрешение и необходимость финансовых отчислений при их использовании.

Наиболее скоростными детекторами являются FAST и BRISK. BRISK обладает неплохим качеством и хорошей скоростью детектирования. Обладая почти всеми недостатками детектора FAST, для качественной работы детектора BRISK требуются цифровые изображения большого разрешения, что в реалиях подготовки цифровых изображений в военной обстановке достаточно затруднительно.

Поэтому для использования детекторов в системе технического зрения остановимся на детекторе FAST, который обладает наиболее оптимальными характеристиками для решения задачи нахождения ключевых точек в режиме реального времени на цифровых изображениях разного качества: самая высокая скорость среди современных детекторов и достаточно неплохое качество. Предварительные исследования детектора FAST показали, что количество выявляемых ключевых точек даже при низком качестве детектирования очень большое, и зачастую приходится прибегать к процедуре децимации, т.е. удаление из выявленного количества излишних ключевых точек. Поэтому в качестве детектора далее будем использовать детектор FAST.

Проведем анализ рассмотренных алгоритмов дескрипторов. Дескриптор BRIEF является быстрым дескриптором, который может хорошо дополнять детектор FAST. Однако необходимо отметить, что дескриптор BRIEF неэффективно осуществляет выбор точек для расчёта дескриптора и имеет плохую устойчивость к вращению при распознавании изображений.

Дескриптор ORB является улучшенной версией дескриптора BRIEF и имеет большую устойчивость к вращению при распознавании изображений, однако имеет низкую скорость.

Алгоритм SIFT обладает рядом преимуществ, таких как инвариантность к поворотам, смещению, а также частичная инвариантность к изменению масштаба, яркости и положения камеры, однако также имеет невысокую скорость работы алгоритма.



Дескриптор SURF является одним из лучших дескрипторов ключевых точек, однако ввиду сложности реализации алгоритма, имеет низкую скорость выполнения.

При этом алгоритмы SIFT и SURF запатентованы, и для их использования требуется разрешение и необходимость финансовых отчислений при их использовании.

Исходя из этого можно сделать следующие выводы.

Для детектирования ключевых точек в режиме реального времени с частотой выдачи информации не менее 1Гц может быть использован детектор FAST с некоторой его модификацией, в частности с возможностью децимации излишнего количества ключевых точек, при этом можно ставить задачу оптимальной в некотором смысле децимации.

Что касается дескрипторов, то ситуация здесь более сложная. Проведенный анализ дескрипторов показал, что относительно быстрые дескрипторы BRIEF и ORB имеют некоторые проблемы с инвариантностью к вращениям [31]. С точки зрения системы компьютерного зрения это означает следующее. Как правило, берется базовое цифровое изображение при каком-то фиксированном угловом положении, и для этого положения вычисляются детекторы и дескрипторы. Повернем наше изображение на некоторый угол. Если для детекторов вращение не сильно изменяет его характеристики, то дескриптор для первоначального углового положения может сильно отличаться от повернутого на некоторый угол. Проблема определения ключевых точек при вращении означает, что одна и та же ключевая точка не всегда однозначно обнаруживается в разных версиях одной и той же сцены, т.е. различные ракурсы и перспективы цифрового изображения могут затруднить поддержание неизменности обнаруженных ключевых точек. Поэтому рассмотренные дескрипторы ключевых точек либо не подходят по ограничениям на вращение (БПЛА может подлететь к заданной точке с любой стороны), либо по скорости вычислений.

Поэтому стоит задача - для успешного функционирования системы автономной навигации с использованием ключевых точек необходима разработка дескриптора, инвариантного относительно освещения, масштаба и вращения, и кроме того, обладающего высокой скоростью вычислений.

1. Основные формулы и используемые методы.

Метод Ψ -преобразований в задачах оптимизации нелинейных функций.

Пусть задана целевая нелинейная функция $F(x)$ в N -мерном пространстве. Рассмотрим случай, когда целевая функция многоэкстремальная и терпит разрывы первого рода [32].

Пусть E - некоторое измеримое множество из пространства R^N , и $F(x)$ - некоторая функция класса $L_p(E)$. Обозначим:

$$E_{\zeta}^* = \{x : x \in E, F(x) \geq \zeta\}. \quad (1)$$

При $\zeta=0$ будем иметь:

$$E_0^* = \{x : x \in E, F(x) \geq 0\}. \quad (2)$$



Пусть функция $F(x)$ принимает только положительные значения, тогда

$$E = E_0^* \text{ и } E \setminus E_0^* = \bar{E}_0 = \emptyset. \text{ Для } \zeta > 0:$$

$$E \setminus E_\zeta^* = \bar{E}_\zeta, \quad (3)$$

где

$$E_\zeta^* = \{x : x \in E, F(x) < \zeta\}.$$

Обозначим теперь через $m(E)$ меру множества E , а мерами множеств E_ζ^* и $\bar{E}_\zeta$ соответственно $m(E_\zeta^*)$ и $m(\bar{E}_\zeta)$.

Определим функцию:

$$\Psi(\zeta) = m(E_\zeta^*). \quad (4)$$

Нетрудно видеть, что:

$$\Psi(\zeta) = m(E_\zeta^*) = (L) \int \dots \int_E \theta_\zeta(x_1, \dots, x_N) dx_1 \dots dx_N, \quad (5)$$

где $\int \theta_\zeta(x_1, \dots, x_N)$ является характеристической функцией:

$$\theta_\zeta(x_1, \dots, x_N) = \begin{cases} 1 \text{ на } E_\zeta^*, \\ 0 \text{ на } E \setminus E_\zeta^*. \end{cases} \quad (6)$$

Произведем теперь Лебегово разбиение функции $F(x)$. Для этого интервал изменения функции $F(x)$ разделим на ряд подинтервалов:

$$0 = \zeta_0 < \zeta_1 < \dots < \zeta_\nu < \dots < \zeta^* = \max F(x). \quad (7)$$

Далее будем считать, что задачей является нахождение максимума $F(x)$. Для каждого значения ζ_ν можно записать:

$$\Psi(\zeta_\nu) = (L) \int \dots \int_E \theta_\nu(x_1, \dots, x_N) dx_1 \dots dx_N. \quad (8)$$

Рассмотрим теперь некоторые свойства множеств, образуемых в результате подобного Лебегова разбиения. Как уже отмечалось, рассматриваются функции класса $L_p(E)$, определенные на множестве E .

Пусть функция $F(x)$ такова, что множество E можно разбить на ряд связанных подмножеств e_{0i} ($i=1, \dots, \nu$), так что на каждом из подмножеств e_{0i} функция $F(x)$ была бы выпуклой. Обозначим $e_{\nu i}^* \subset e_i$ множество, на котором $F(x) \geq \zeta_\nu$.

Для случая $N=2$ вышесказанное можно проиллюстрировать следующим рисунком:




Рисунок 3 – Графическая 3D интерпретация разбиения функции $F(x)$ на подинтервалы

На рисунке 4 представим принцип формирования функции $\Psi(\zeta_\nu)$.




Рисунок 4 – Проекция функции $F(x)$ на плоскость $F0x_1$

После того, как согласно рисунку 4 вычислены значения $\Psi(\zeta_\nu)$, построим зависимость функции $\Psi(\zeta_\nu)$ от переменной ζ_ν , которая показана на рисунке 5.




Рисунок 5 - Зависимость функции $\Psi(\zeta_\nu)$ от переменной ζ_ν



По сути, рисунок 5 показывает основную идею метода Ψ -преобразований в задачах оптимизации нелинейных функций заключающуюся в том, что поиск глобального экстремума сводится к разбиению исследуемой функции $F(x)$ на уровни, для каждого уровня вычисляется функция $\Psi(\zeta_v)$ и строится зависимость этой функции от ζ_v , позволяющая в конечном итоге выйти в область глобального экстремума исследуемой функции.

Математическая модель Ψ -дескриптора для описания найденных ключевых точек.

Рассмотрим рисунок 2, на котором показан алгоритм выявления ключевых точек на основе детектора FAST. Детектор FAST выявляет такие пиксели, яркость которых превышает заданную величину порога яркости (или яркость которых находится ниже на величину порога яркости), т.е. рассматривает пиксели, находящиеся на окружности радиуса 3, яркость которых ниже яркости центрального пикселя на величину порога яркости. Если построить 3D модель функции $F(x_1^i, x_2^i)$, где i – это i -й пиксель цифрового изображения, имеющий координаты (x_1^i, x_2^i) , то получим картину, практически совпадающую с рисунком 3, где в качестве ключевой определена точка (x_1^i, x_2^i) яркость которой:

$$F_i = F(x_1^i, x_2^i). \quad (9)$$

Учитывая, что вокруг выявленной ключевой точки была построена окружность радиуса 3, определим максимальный радиус R_N , и вокруг выявленной ключевой точки построим последовательность окружностей с радиусами R такими, что:

$$R \in [1, R_N] \quad (10)$$

т.е. R принимает значения: $1, 2, \dots, R_N$. Для каждого значения радиуса R_i введем функцию меры Ψ_i следующим образом:

$$\Psi_i = \frac{\int_0^{2\pi} I(\varphi) R_i d\varphi}{\int_0^{2\pi} R_i d\varphi}, \quad (11)$$

где $I(\varphi)$ - интенсивность (яркость) точки на окружности. Учитывая, что $\int_0^{2\pi} R_i d\varphi = 2\pi R_i$, получим меру интенсивности окружности радиуса R_i цифрового изображения с центром в ключевой точке:

$$\Psi_i = \frac{1}{2\pi R_i} \int_0^{2\pi} I(\varphi) R_i d\varphi. \quad (12)$$



Отметим, что данная мера не зависит от угла поворота изображения, положения камеры. Учитывая, что изображение предварительно переводится в серые цвета, то яркость не будет влиять на данную меру.

Касательно масштаба можно отметить следующее: как было указано выше, мы определили, что целевая функция многоэкстремальная и терпит разрывы первого рода. Это говорит о том, что, изменяя масштаб изображения, обобщенная интенсивность окружности радиуса R_i , определяемая формулой (12), естественно изменится. Однако можно построить изменения меры интенсивности в зависимости от масштаба – тогда проблема масштаба может быть также решена. Однако это задача другого исследования и в этой статье это решение не будет исследовано.

Таким образом, мера интенсивности на расстоянии R_i от ключевой точки может быть использована для описания ключевой точки и положена в основу формирования вектора дескриптора.

Определим максимальное расстояние от ключевой точки, т.е. для определенности R пробегает значения от 1 до N . Для каждого $i=1, \dots, N$ вычислим меру интенсивности по формуле (12). Добавим к данному вектору еще один элемент, который может быть вычислен по следующей формуле:

$$\psi = \frac{1}{N} \int_{R_N} \psi_i(R) dR. \quad (13)$$

Неотъемлемой частью дескриптора должны быть также координаты ключевой точки (X, Y, Z) . Таким образом, предлагаемый дескриптор для ключевой точки будет описываться формулами (12), (13) и координатами (X, Y, Z) . Учитывая, что цифровое изображение дискретно, определим дискретный аналог формул (12) и (13). Для определенности положим $N=7$, длину окружности, нарисованную по алгоритму Брезенхама, заменим на количество пикселей, ее составляющих. Тогда формула (12) будет иметь следующий вид:

$$\psi_i = \frac{\sum_{j=1}^{K_i} I_j}{K_i}. \quad (14)$$

Формула (13) будет иметь вид:

$$\psi = \frac{\sum_{i=1}^N \psi_i}{N}. \quad (15)$$

Тогда при $N=7$ дескриптор ключевой точки будет описан следующим вектором из 8 компонентов:

$$D = (\psi_1, \psi_2, \psi_3, \psi_4, \psi_5, \psi_6, \psi_7, \psi, X, Y, Z). \quad (16)$$

Таким образом, для описания ключевых точек цифрового изображения, полученных методом FAST, можно использовать Ψ -дескриптор (16), который устойчив к поворотам и освещению.

Результаты и обсуждение.

Технические характеристики БПЛА с автономной системой навигации, построенной на основе ключевых точек с детектором FAST и Ψ -дескриптором

По разработанному техническому проекту был изготовлен беспилотный летательный аппарат на базе квадрокоптера с автономной системой навигации (рисунок 6).



Рисунок 6 – Общий вид экспериментального образца БПЛА с высокой детализацией: рама, шасси, полетный контроллер, штатная система навигации БПЛА, система связи и управления, полезная нагрузка (автономная система навигации)

На рисунке 7 показан момент проведения летных испытаний экспериментального образца БПЛА с автономной системой навигации (АСН) в качестве полезной нагрузки.

Основой АСН является одноплатное вычислительное устройство Mini PC Stick by AWOW, имеющий основные технические характеристики, представленные в таблице 1.

Таблица 1-Основные технические характеристики Mini PC Stick by AWOW

№	Характеристики	Параметры характеристики
1	Процессор	Intel Atom 1.44 GHz
2	Графика, графический интерфейс	Intel HD Graphics 400, HDMI 2.0
3	Интерфейс	2×USB
4	ОЗУ	4 GB
5	Операционная система	Windows 10
6	Габариты, см	12,1×3,6×1,19
7	Вес, грамм	63,5



Рисунок 7 - Летные испытания экспериментального образца БПЛА с автономной системой навигации на сборочном полигоне

Общий вид экспериментального образца автономной системы навигации с открытой крышкой корпуса показан на рисунке 8.



Рисунок 8 - Общий вид экспериментального образца автономной системы навигации с открытой крышкой корпуса



Рисунок 9 - Mini PC Stick by AWOW

На рисунке 9 показан используемый в АСН Mini PC Stick by AWOW.

В качестве фотокамеры была использована веб-камера Logitech C270 HD, характеристики которой приведены в таблице 2, и показанная на рисунке 10.



Рисунок 10 - Веб-камера Logitech C270 HD

Таблица 2 – Основные технические характеристики веб-камеры Logitech C270 HD

№	Характеристики	Параметры характеристики
1	Тип	Веб-камера
2	Общее количество пикселей	3 Мпикс
3	Стандартное разрешение	1280×780
4	Максимальное разрешение	2048×1536
5	Интерфейс	USB

В качестве источника питания используется внешний аккумулятор (Power Bank) Xiaomi Integrated Cable, показанный на рисунке 11.



Рисунок 11 - Внешний аккумулятор (Power Bank) Xiaomi Integrated Cable

Внешний аккумулятор (Power Bank) Xiaomi Integrated Cable имеет следующие основные технические характеристики: емкость, мА*час – 10000; выходные интерфейсы USB, USB Type C; максимальный выходной ток 3А; литий-полимерный тип аккумулятора; размеры 147,8 x 73,9 x 15,3 мм.

Результаты проведения испытаний экспериментального образца БПЛА с автономной системой навигации, построенной на основе ключевых точек с детектором FAST и Ψ -дескриптором

На базе математической модели Ψ -дескриптора (9)-(16) был разработан комплекс UML-диаграмм [33], разработано программное обеспечение, составляющее основу автономной системы навигации. Были разработаны программа и методика испытаний, проведены испытания автономной системы навигации, построенной на основе ключевых точек с детектором FAST и Ψ -дескриптором в рамках этой ПМИ.

В соответствии с ПМИ проведения испытаний экспериментального образца БПЛА с автономной системой навигации были выполнены следующие работы:

- предварительно с БПЛА было сделано 320 цифровых кадров района действий БПЛА – района испытаний, которые были объединены в единый ортофотоплан на программе Agisoft Metashape Professional, координаты углов которого имеют следующие координаты $\lambda_{\min}=76.7020$; $\lambda_{\max}=76.7316$; $\varphi_{\min}=43.1812$; $\varphi_{\max}=43.2027$.

- полученное базовое цифровое изображение было обработано на программном исполняемом модуле «Подготовка цифрового изображения к моделированию»;

- в результате обработки базового цифрового изображения в модуле «preparationMapOfEarth.exe» получены ключевые точки и вычислены их дескрипторы;

- определен маршрут движения экспериментального образца БПЛА с автономной системой навигации;

- была осуществлена предполетная подготовка экспериментального образца БПЛА с автономной системой навигации: в систему управления

БПЛА введены контрольные точки маршрута движения, в автономную систему навигации время начала съемок и частоту выполнения съемок;

– запущен экспериментальный образец БПЛА, который пролетел по заданному маршруту через контрольные точки, и запущена на выполнение автономная система навигации на базе технологии Key Point с детектором FAST и Ψ -дескриптором, которая независимо от штатных систем БПЛА выполнила цифровую съемку в нади́р и осуществила обработку полученных цифровых изображений;

– пролетев по заданному маршруту, БПЛА вернулся к месту запуска.




Рисунок 12 – Базовое цифровое изображения района действий БПЛА в нанесенным на него изображениями кадров с нанесенными двумя ключевыми точками

На рисунке 12 показана карта полета с нанесенными на нее изображениями кадров, которые был сняты автономной системой навигации. На каждом снятом кадре АСН определила две ключевые точки, которые позволили определить координаты текущего положения БПЛА.

Сравнительный анализ точности определения координат текущего положения БПЛА штатными средствами GPS и АСН показал, что точность определения координат текущего положения БПЛА АСН сравнима с точностными характеристиками штатного GPS приемника, при этом ошибка АСН не выходит за рамки стандартных ошибок GNSS-приемников 6-7 метров.



Выводы.

1. Анализ методов и алгоритмов решения задач автономной навигации с использованием методов искусственного интеллекта показал, что наиболее подходящими с точки зрения точности, алгоритмической сложности, подготовки данных и требований к техническому обеспечению являются методы и алгоритмы с использованием ключевых точек.

2. На основе метода Ψ -преобразований разработана математическая модель описания найденных ключевых точек Ψ -дескриптор.

3. Разработанный метод описания ключевых точек Ψ -дескриптор является новым и позволяет находить ключевые точки не зависимо от ориентации цифрового изображения и по этому свойству сопоставим с традиционными методами описания ключевых точек.

4. Проведенные испытания автономной системы навигации показали высокую точность определения координат с использованием метода ключевых точек с FAST-детектором и Ψ -дескриптором.

5. Разработанный новый метод определения ключевых точек может быть использован в системах технического зрения привязных беспилотных летательных аппаратов для решения задач посадки в качестве альтернативы штатным систем GPS.

Финансирование. Исследование выполнено в рамках грантового финансирования Комитетом науки Министерства науки и высшего образования Республики Казахстан по проекту ИРН AP23489996 «Разработка опытного образца привязной высотной мультиротаторной системы для обеспечения ведения боевых действий»

СПИСОК ЛИТЕРАТУРЫ

1. Leading Global Suppliers. Tethered Drones. [Электронный ресурс]: <https://www.unmannedsystemstechnology.com/expo/tethered-drones-uavs/> (дата обращения: 01.06.2026).

2. Kai Zhang, Wangmeng Zuo, Yunjin Chen, Deyu Meng, Lei Zhang. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. IEEE Transactions on Image Processing, Vol. 26, No. 7, pp. 3142-3155. 2017. 10.1109/TIP.2017.2662206

3. Chao Dong, Chen Change Loy, Kaiming He, Xiaoou Tang. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 38, No. 2, pp. 295-307. 2016. 10.1109/TPAMI.2015.2439281.

4. Olaf Ronneberger, Philipp Fischer, Thomas Brox. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, Lecture Notes in Computer Science, Vol. 9351, pp. 234-241. Springer, Cham. 10.1007/978-3-319-24574-4_28



5. Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778. 2016. 10.1109/CVPR.2016.90
6. R. Archana, P. S. Eliahim Jeevaraj. Deep learning models for digital image processing: a review. Artificial Intelligence Review, Vol. 57, Article number 11. 2024. 10.1007/s10462-023-10631-z
7. Milos Radovic, Offir Adato, Natan S. Kopeika, Roman Bligh. Object Recognition in Aerial Images Using Convolutional Neural Networks. Journal of Imaging, Vol. 3, No. 2, Article 21. 2017. 10.3390/jimaging3020021
8. Andy Couturier, Moulay A. Akhloufi. Convolutional neural networks and particle filter for UAV localization. Proceedings of SPIE 11758, Real-Time Image Processing and Deep Learning 2021, 117580G. 2021. 10.1117/12.2585986
9. Gengyu Wang, Xianping Fu. A Convolutional Neural Network Image Compression Algorithm for UAVs. Journal of Circuits, Systems and Computers, Vol. 33, No. 12, Article 2450211. 2024. 10.1142/S0218126624502116.
10. Radoki S. M. M., Akhloufi M. A., Couturier A. Drone Model Classification Using Convolutional Neural Network Trained on Synthetic Data. Journal of Imaging, Vol. 8, No. 8, Article 218. 2022. 10.3390/jimaging8080218.
11. (5) Gabriel Silva de Oliveira, José Marcato Junior, Caio Polidoro, Wesley Gonçalves, Mateus Santos, Edson Matsubara, et al. Convolutional Neural Networks to Estimate Dry Matter Yield in a Guinea Grass Breeding Program Using UAV Remote Sensing. Sensors, Vol. 21, No. 12, Article 3971. 2021. 10.3390/s21123971.
12. Chunyuan Cui, Juntong Fan, Xuanyao Zhao, Jianing Song, Leyuan Sun. An Improved ORB-SLAM3 System for UAV Localization and Mapping in GPS-Denied Environments. Drones, Vol. 8, No. 4, Article 132. 2024. 10.3390/drones8040132.
13. Muhammad Aamir, Zhao Jianqiang, Muhammad Ali, Saeed Ahmed, Muhammad Irfan. An Automated UAV Image Stitching Approach Based on Improved SIFT Features. IEEE Access, Vol. 9, pp. 62451-62461. 2021. 10.1109/ACCESS.2021.3073981.
14. Runwei Guan, Jinrong Hu, Yifei Huang, Liting Sun, Paolo Santi, Carlo Ratti. Deep Learning-Based Keypoint Detection and Matching for UAV Thermal Images. Remote Sensing, Vol. 15, No. 18, Article 4429. 2023. 10.3390/rs15184429
15. Rodehorst V., Koschan A. Comparison and evaluation of feature point detectors, 2006
16. Tinne Tuytelaars, Krystian Mikolajczyk. Local Invariant Feature Detectors: A Survey, 2008
17. Детектор Kitchen-Rosenfeld. L. Kitchen and A. Rosenfeld. Gray Level Corner Detection. Pattern Recognition Letters, pp. 95-102, 1982
18. Moravec, H. Rover visual obstacle avoidance // In International Joint Conference on Artificial Intelligence, Vancouver, Canada, 1981, pp. 785-790.



19. Детектор COP (Crosses as Oriented Pair). S.C. Bae, I.S. Kweon and C.D. Yoo. COP: a new corner detector. Pattern Recogn. Lett. 2002
20. E. R. a. T. Drummond. Fusing Points and Lines for High Performance Tracking, 2005
21. David G. Lowe. Distinctive Image Features from Scale-Invariant Keypoints, 2004
22. Шакенов А.К. Сравнение детекторов особых точек изображений и оценка их статистических характеристик. Журнал “Автометрия”, 2021. Т.57, №1
23. Клейнберг Дж., Тардос Е. Алгоритмы: разработка и применение. Классика Computers Science / Пер. с англ. Е. Матвеева. – СПб.: Питер, 2016. – 800 с
24. Системы компьютерного зрения: современные задачи и методы [Электронный ресурс]/Режим доступа: <http://controleng.ru/innovatsii/sistemy-komp-yuternogo-zreniya-sovremenny-e-zadachi-metody/>(дата обращения: 01.06.2025)
25. Паттерн посредник [Электронный ресурс]/Режим доступа: <https://refactoring.guru/ru/design-patterns/mediator>; A tutorial on binary descriptors [Электронный ресурс]/Режим доступа: <https://gilscvblog.com/2013/10/04/a-tutorial-on-binary-descriptors-part-3-the-orb-descriptor/> (дата обращения: 01.06.2025)
26. Just look at the image: viewpoint-specific surface normal prediction for improved multi-view reconstruction [Электронный ресурс]/Режим доступа: https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/Galliani_Just_Look_at_CVP_R_2016_paper.pdf (дата обращения: 16.04.2025)
27. James L. Pro JavaFX 2/ L. James, G. Weiqi, C. Stephen, I. Dean, V. Johan. – Apress, 2012. – 641 p.
28. Feature detection and description [Электронный ресурс]/Режим доступа: https://docs.opencv.org/3.0-beta/doc/py_tutorials/py_feature2d/py_table_of_contents_feature2d/py_table_of_contents_feature2d.html (дата обращения: 16.04.2025)
29. ORB: Oriented FAST and Rotated BRIEF [Электронный ресурс]/Режим доступа: http://www.willowgarage.com/sites/default/files/orb_final.pdf (дата обращения: 16.04.2025)
30. Introduction to SURF [Электронный ресурс]/Режим доступа: https://docs.opencv.org/3.0-beta/doc/py_tutorials/py_feature2d/py_surf_intro/py_surf_intro.html (дата обращения: 16.04.2025)
31. What is KeyPoint Detection? [Электронный ресурс]/Режим доступа: https://translated.turbopages.org/proxy_u/en-ru.ru.ead253e4-67ff9724-ab1a850e-74722d776562/https/www.geeksforgeeks.org/what-is-keypoint-detection/ (дата обращения: 16.04.2025)



32. Чичинадзе В.К. Решение невыпуклых нелинейных задач оптимизации. - М.: Наука. Главная редакция физико-математической литературы. 1983. – 256 с.

33. Кадиркулов Ш.К., Оспанов Ж.Ш., Бекмурзаев Б.Ж., Бекмухамедов Б.Э., Анетбаев А.А. Объектно-ориентированное моделирование с использованием диаграмм UML для разработки имитационной модели автономной системы навигации БПЛА. Научные труды военно-инженерного института радиоэлектроники и связи. Военный научно-технический журнал. №3 (65), 2026 г.

REFERENCES

1. Leading Global Suppliers. Tethered Drones. [Электронный ресурс]: <https://www.unmannedsystemstechnology.com/expo/tethered-drones-uavs/> (accessed: 01.06.2026).

2. Kai Zhang, Wangmeng Zuo, Yunjin Chen, Deyu Meng, Lei Zhang. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. IEEE Transactions on Image Processing, Vol. 26, No. 7, pp. 3142-3155. 2017. 10.1109/TIP.2017.2662206

3. Chao Dong, Chen Change Loy, Kaiming He, Xiaoou Tang. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 38, No. 2, pp. 295-307. 2016. 10.1109/TPAMI.2015.2439281.

4. Olaf Ronneberger, Philipp Fischer, Thomas Brox. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, Lecture Notes in Computer Science, Vol. 9351, pp. 234-241. Springer, Cham. 10.1007/978-3-319-24574-4_28

5. Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778. 2016. 10.1109/CVPR.2016.90

6. R. Archana, P. S. Eliahim Jeevaraj. Deep learning models for digital image processing: a review. Artificial Intelligence Review, Vol. 57, Article number 11. 2024. 10.1007/s10462-023-10631-z.

7. Milos Radovic, Offir Adato, Natan S. Kopeika, Roman Bligh. Object Recognition in Aerial Images Using Convolutional Neural Networks. Journal of Imaging, Vol. 3, No. 2, Article 21. 2017. 10.3390/jimaging3020021

8. Andy Couturier, Moulay A. Akhloufi. Convolutional neural networks and particle filter for UAV localization. Proceedings of SPIE 11758, Real-Time Image Processing and Deep Learning 2021, 117580G. 2021. 10.1117/12.2585986

9. Gengyu Wang, Xianping Fu. A Convolutional Neural Network Image Compression Algorithm for UAVs. Journal of Circuits, Systems and Computers, Vol. 33, No. 12, Article 2450211. 2024. 10.1142/S0218126624502116.

10. Radoki S. M. M., Akhloufi M. A., Couturier A. Drone Model Classification Using Convolutional Neural Network Trained on Synthetic Data. Journal of Imaging, Vol. 8, No. 8, Article 218. 2022. 10.3390/jimaging8080218.



11. (5) Gabriel Silva de Oliveira, José Marcato Junior, Caio Polidoro, Wesley Gonçalves, Mateus Santos, Edson Matsubara, et al. Convolutional Neural Networks to Estimate Dry Matter Yield in a Guineagrass Breeding Program Using UAV Remote Sensing. *Sensors*, Vol. 21, No. 12, Article 3971. 2021. 10.3390/s21123971.
12. Chunyuan Cui, Juntong Fan, Xuanyao Zhao, Jianing Song, Leyuan Sun. An Improved ORB-SLAM3 System for UAV Localization and Mapping in GPS-Denied Environments. *Drones*, Vol. 8, No. 4, Article 132. 2024. 10.3390/drones8040132.
13. Muhammad Aamir, Zhao Jianqiang, Muhammad Ali, Saeed Ahmed, Muhammad Irfan. An Automated UAV Image Stitching Approach Based on Improved SIFT Features. *IEEE Access*, Vol. 9, pp. 62451-62461. 2021. 10.1109/ACCESS.2021.3073981.
14. Runwei Guan, Jinrong Hu, Yifei Huang, Liting Sun, Paolo Santi, Carlo Ratti. Deep Learning-Based Keypoint Detection and Matching for UAV Thermal Images. *Remote Sensing*, Vol. 15, No. 18, Article 4429. 2023. 10.3390/rs15184429
15. Rodehorst V., Koschan A. Comparison and evaluation of feature point detectors, 2006
16. Tinne Tuytelaars, Krystian Mikolajczyk. Local Invariant Feature Detectors: A Survey, 2008
17. Detector Kitchen-Rosenfeld. L. Kitchen and A. Rosenfeld. Gray Level Corner Detection. *Pattern Recognition Letters*, pp. 95-102, 1982
18. Moravec, H. Rover visual obstacle avoidance // In International Joint Conference on Artificial Intelligence, Vancouver, Canada, 1981, pp. 785-790.
19. COP (Crosses as Oriented Pair) Detector. S.C. Bae, I.S. Kweon, and C.D. Yoo. COP: A New Corner Detector. *Pattern Recognition Letters*, 2002.
20. E. R. a. T. Drummond. Fusing Points and Lines for High Performance Tracking, 2005
21. David G. Lowe. Distinctive Image Features from Scale-Invariant Keypoints, 2004
22. Shakenov, A.K. Comparison of Image Keypoint Detectors and Evaluation of Their Statistical Characteristics. *Avtometriya (Optoelectronics, Instrumentation and Data Processing)*, 2021, Vol. 57, No. 1.
23. Kleinberg, J., and Tardos, É. Algorithm Design. Computers Science Classics Series. Translated from English by E. Matveev. St. Petersburg: Piter, 2016. 800 p.
24. Computer Vision Systems: Modern Challenges and Methods [Electronic Resource]. Available at: <http://controleng.ru/innovatsii/sistemy-komp-yuternogo-zreniya-sovremenny-e-zadachi-metody/> (accessed: June 1, 2025).
25. Mediator Design Pattern [Electronic Resource]. Available at: <https://refactoring.guru/ru/design-patterns/mediator>; A Tutorial on Binary Descriptors [Electronic Resource]. Available at:



<https://gilscvblog.com/2013/10/04/a-tutorial-on-binary-descriptors-part-3-the-orb-descriptor/> (accessed: June 1, 2025).

26. Galliani, S., et al. Just Look at the Image: Viewpoint-Specific Surface Normal Prediction for Improved Multi-View Reconstruction [Electronic Resource]. Available at: https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/Galliani_Just_Look_at_CVPR_2016_paper.pdf (accessed: April 16, 2025).

27. James L. Pro JavaFX 2/ L. James, G. Weiqi, C. Stephen, I. Dean, V. Johan. – Apress, 2012. – 641 p.

28. Feature detection and description [Electronic Resource]/Режим доступа: https://docs.opencv.org/3.0-beta/doc/py_tutorials/py_feature2d/py_table_of_contents_feature2d/py_table_of_contents_feature2d.html (accessed: April 16, 2025)

29. ORB: Oriented FAST and Rotated BRIEF [Electronic Resource]. Available at: http://www.willowgarage.com/sites/default/files/orb_final.pdf (accessed: April 16, 2025).

30. Introduction to SURF [Electronic Resource]. Available at: https://docs.opencv.org/3.0-beta/doc/py_tutorials/py_feature2d/py_surf_intro/py_surf_intro.html (accessed: April 16, 2025).

31. What Is KeyPoint Detection? [Electronic Resource]. Available at: <https://www.geeksforgeeks.org/what-is-keypoint-detection/> (accessed: April 16, 2025).

32. Chichinadze, V.K. Solving Non-Convex Nonlinear Optimization Problems. Moscow: Nauka, Main Editorial Board of Physical and Mathematical Literature, 1983. 256 p.

33. Kadirkulov, Sh.K., Ospanov, Zh.Sh., Bekmurzaev, B.Zh., Bekmukhamedov, B.E., and Anetbaev, A.A. Object-Oriented Modeling Using UML Diagrams for the Development of a Simulation Model of an Autonomous UAV Navigation System. Scientific Proceedings of the Military Engineering Institute of Radioelectronics and Communications. Military Scientific and Technical Journal, No. 3 (65), 2026.

Шингис Кадиркулов, э.ғ.к., PhD, қауымдастырылған профессор, профессор-оқу-әдістемелік басқарманың ғылыми-зерттеу бөлімінің бастығы, Military Institute of Land Forces named after S. Nurmagambetov, Алматы, Қазақстан, ksh777@mail.ru

Жанболат Оспанов, жауапты орындаушы, докторант, Military Institute of Land Forces named after S. Nurmagambetov, Алматы, Қазақстан, ospanov.zh.s.7@gmail.com

Аслан Анетбаев, ғылыми қызметкер, Almaty Institute of Technology, Алматы, Қазақстан, aslan.assylkhanovich@gmail.com



ТҮЙІНДІ НҮКТЕЛЕР ӘДІСІ НЕГІЗІНДЕ БАЙЛАНЫСТЫ МУЛЬТИКОПТЕРДІҢ ТЕХНИКАЛЫҚ КӨРУ ЖҮЙЕСІ ҮШІН Ψ - ДЕСКРИПТОРДЫ ӘЗІРЛЕУ

Аңдатпа. Мақалада байланыстырылған мультикоптерлердің жалпы сипаттамасы беріліп, олардың негізгі функционалдық мүмкіндіктері қарастырылады. Сонымен қатар, байланыстырылған ұшқышсыз ұшу аппараттарының (ҰҰА) жұмыс істеуіндегі күрделі процестердің бірі – жерге қону үдерісінде қолдануға арналған автономды навигация жүйесін әзірлеу міндеті қойылған. Автономды навигация жүйесін құру үшін түйінді нүктелер технологиясын пайдалану ұсынылады.

Түйінді нүктелердің детекторлары мен дескрипторларына қысқаша шолу жүргізілді. Түйінді нүктелердің детекторы ретінде FAST детекторын қолдануға болатыны көрсетілген. Алайда дескрипторды құру үшін сызықтық емес функцияларды оңтайландыру есептеріндегі Ψ -түрлендірулер әдісінің математикалық моделі пайдаланылды. Бұл модель авторлық түйінді нүктелер дескрипторы – Ψ -дескрипторды әзірлеудің негізі болды.

Әзірленген Ψ -дескрипторды ҰҰА-ның автономды навигациясы міндетін шешуде практикалық қолдану нәтижелері келтірілген. Ұсынылған жаңа түйінді нүктелерді анықтау әдісі байланыстырылған ұшқышсыз ұшу аппараттарының техникалық көру жүйелерінде қону міндеттерін шешу үшін GPS жүйелеріне балама ретінде пайдаланылуы мүмкін.

Түйінді сөздер: байланыстырылған пилотсыз ұшу аппараты, дескриптор, автономды навигация, негізгі түйін, машиналық көру, жасанды интеллект.

Shyngys Kadirkulov, candidate of military sciences, PhD, associate professor, Professor-Head of the Research Department of Educational and Methodological management, Military Institute of Land Forces named after S. Nurmagambetov, Almaty, Kazakhstan, ksh777@mail.ru

Zhanbolat Ospanov, responsible executor, doctoral student, Military Institute of Land Forces named after S. Nurmagambetov, Almaty, Kazakhstan, ospanov.zh.s.7@gmail.com

Aslan Anetbaev, researcher, Almaty Institute of Technology, Almaty, Kazakhstan, aslan.assylkhanovich@gmail.com

DEVELOPMENT OF A Ψ -DESCRIPTOR FOR THE COMPUTER VISION SYSTEM OF A TETHERED MULTICOPTER BASED ON THE KEYPOINT METHOD

Abstract. The article provides a general overview of tethered multicopters, describes their main functional capabilities, and formulates the task of developing an autonomous navigation system for use in one of the most challenging



operational processes of tethered unmanned aerial vehicles (UAVs) - their landing on the ground. The use of keypoint technology is proposed for the development of the autonomous navigation system.

A brief review of keypoint detectors and descriptors is presented. It is shown that the FAST detector can be used as a keypoint detector. However, for descriptor construction, a mathematical model based on the Ψ -transformation method used in nonlinear function optimization problems was employed, forming the basis for the development of a proprietary keypoint descriptor - the Ψ -descriptor.

The results of the practical application of the developed Ψ -descriptor for solving UAV autonomous navigation tasks are presented. The proposed new method for keypoint determination can be used in the computer vision systems of tethered unmanned aerial vehicles to solve landing tasks as an alternative to conventional GPS-based systems.

Keywords: tethered UAV, descriptor, autonomous navigation, keypoint, computer vision, artificial intelligence.

Поступила: 15 июня 2026 года

Рецензирована: 18 июня 2026 года

Принята: 22 июня 2026 года