

УДК 629.7; 681.3; 004.42

DOI: [10.26102/2310-6018/2025.48.1.019](https://doi.org/10.26102/2310-6018/2025.48.1.019)

## Система комплексирования сенсорных данных в бортовых системах управления беспилотными авиационными системами

Н.Н. Гулютин✉, Н.А. Ермиенко, О.А. Антамошкин

*Сибирский федеральный университет, Красноярск, Российская Федерация*

**Резюме.** Современные беспилотные авиационные системы (БАС) играют ключевую роль в различных отраслях, включая мониторинг окружающей среды, геодезию, сельское и лесное хозяйство. Одним из важнейших факторов их успешного применения является интеграция данных от различных сенсоров, таких как глобальные навигационные спутниковые системы, инерциальные навигационные системы, лидары, камеры и тепловизоры. Комплексирование данных позволяет существенно повысить точность, надежность и функциональность систем управления. В статье рассматриваются методы интеграции данных, включающие традиционные алгоритмы, такие как фильтры Калмана и его расширенные версии, а также современные подходы, основанные на моделях глубокого обучения, включая FusionNet и Deep Sensor Fusion. Экспериментальные исследования показали, что обучаемые модели превосходят традиционные алгоритмы, обеспечивая увеличение точности навигации до 40 % и улучшение устойчивости к помехам и внешним воздействиям. Предложенные подходы демонстрируют потенциал для расширения применения БАС в задачах автономной навигации, картографии и мониторинга, особенно в сложных условиях эксплуатации. Перспективы дальнейшего развития включают использование гиперспектральных сенсоров и создание адаптивных методов интеграции для повышения эффективности работы беспилотных систем.

**Ключевые слова:** интеграция сенсорных данных, беспилотные авиационные системы, фильтр Калмана, FusionNet, Deep Sensor Fusion, автономная навигация, устойчивость к помехам.

**Для цитирования:** Гулютин Н.Н. Ермиенко Н.А. Антамошкин О.А. Система комплексирования сенсорных данных в бортовых системах управления беспилотными авиационными системами. *Моделирование, оптимизация и информационные технологии.* 2025;13(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1806> DOI: 10.26102/2310-6018/2025.48.1.019

## Sensor data integration system in onboard control systems of unmanned aerial systems

N.N. Gulyutin✉, N.A. Ermiyenko, O.A. Antamoshkin

*Siberian Federal University, Krasnoyarsk, the Russian Federation*

**Abstract.** Modern unmanned aerial systems (UAS) play a key role in various industries, including environmental monitoring, geodesy, agriculture, and forestry. One of the most critical factors for their successful application is the integration of data from various sensors, such as global navigation satellite systems, inertial navigation systems, lidars, cameras, and thermal imagers. Sensor data fusion significantly enhances the accuracy, reliability, and functionality of control systems. This paper explores data integration methods, including traditional algorithms like Kalman filters and their extended versions, as well as modern approaches based on deep learning models, such as FusionNet and Deep Sensor Fusion. Experimental studies have shown that learning-based models outperform traditional algorithms, achieving up to a 40 % improvement in navigation accuracy and enhanced resilience to noise and external disturbances. The proposed approaches demonstrate the potential to expand UAS applications in autonomous navigation, cartography, and monitoring, particularly in challenging operational environments. Future development prospects include the implementation of hyperspectral

sensors and the development of adaptive data integration methods to further improve the efficiency and effectiveness of unmanned systems.

**Keywords:** sensor data integration, unmanned aerial systems, Kalman filter, FusionNet, Deep Sensor Fusion, autonomous navigation, resilience to disturbances.

**For citation:** Gulyutin N.N., Ermiyenko N.A., Antamoshkin O.A. Sensor data integration system in onboard control systems of unmanned aerial systems. *Modeling, Optimization and Information Technology*. 2025;13(1). (In Russ.). URL: <https://moitvvt.ru/ru/journal/pdf?id=1806> DOI: 10.26102/2310-6018/2025.48.1.019

## Введение

Современные беспилотные авиационные системы (БАС) занимают все более значимое место в различных отраслях, таких как лесное хозяйство [1], сельское хозяйство, мониторинг окружающей среды, геодезия, строительство, транспорт и логистика [2]. Увеличение функциональных возможностей БАС связано с внедрением сложных систем управления, которые требуют интеграции данных от множества сенсоров для выполнения задач навигации, мониторинга и управления. Эти сенсоры, включая глобальные навигационные спутниковые системы (ГНСС, англ. Global Navigation Satellite System, GNSS), инерциальную навигационную систему (ИНС), устройства обнаружения и определения дальности с помощью света (лидар), камеры и тепловизоры, обеспечивают сбор данных, отражающих физическое состояние аппарата и окружающую среду. Каждый из этих сенсоров предоставляет уникальную информацию, которая дополняет данные других источников, что в совокупности позволяет создать полное и точное представление о текущей ситуации [3].

Интеграция сенсорных данных является критическим аспектом для обеспечения точности и надежности работы БАС. ГНСС обеспечивает абсолютное позиционирование, однако ее точность может снижаться в условиях плотной застройки, помех или отсутствия прямой видимости спутников. ИНС, в свою очередь, обеспечивают высокочастотные данные об ускорениях и угловых скоростях, что особенно полезно для краткосрочной стабилизации и управления. Однако ИНС подвержены накоплению ошибок (дрейфу), что требует периодической коррекции их данных. Обычно для этого используются данные ГНСС, а не наоборот: именно спутниковая навигация корректирует дрейф ИНС, обеспечивая долгосрочную точность. Лидар предоставляет трехмерные данные об окружающей среде, что особенно важно для задач картографирования, предотвращения столкновений и автономной навигации. Камеры обеспечивают визуальное восприятие, которое необходимо для распознавания объектов, идентификации местности и анализа окружающих условий. Тепловизоры добавляют данные о тепловом излучении объектов, что является ключевым для поиска и спасения или мониторинга инфраструктуры.

Однако процесс интеграции данных сталкивается с рядом сложностей. Во-первых, сенсоры имеют разные частоты обновления и точность. Во-вторых, объем данных, требующий обработки, зависит от типа и класса БАС. Для компактных дронов с ограниченной вычислительной мощностью основными задачами являются фильтрация шумов и коррекция траектории. В то же время, крупные автономные БАС, выполняющие длительные миссии (например, геодезические исследования или мониторинг), требуют интеграции данных от нескольких высокоточных сенсоров, что приводит к увеличению вычислительных затрат [4].

В данной работе рассматриваются методы интеграции, которые могут быть адаптированы для разных классов БАС – от небольших коптеров до крупных автономных систем, требующих сложной обработки данных в реальном времени.

Комплексирование сенсорных данных в реальном времени позволяет значительно улучшить работу систем управления. Она обеспечивает повышение надежности управления аппаратом за счет минимизации ошибок позиционирования и траектории, улучшает устойчивость к внешним помехам, таким как погодные условия или потеря сигнала, а также оптимизирует взаимодействие между системами навигации, контроля и мониторинга [5]. Например, объединение данных лидара и камер позволяет эффективно компенсировать недостатки каждого из сенсоров: лидар обеспечивает стабильные трехмерные данные, но не способен анализировать текстуры, тогда как камеры предоставляют визуальную информацию, но чувствительны к изменениям освещения.

В современных БАС одной из ключевых проблем является интеграция данных от различных сенсоров для обеспечения точной и устойчивой навигации. Разнородные сенсоры, такие как ГНСС, ИНС, лидары и камеры, имеют разные принципы работы, частоту обновления данных и точность, что затрудняет их комплексирование в единой системе. Классические методы интеграции (например, фильтр Калмана) позволяют объединять данные, но имеют ограничения в сложных условиях эксплуатации (помехи, отсутствие сигнала). Современные методы на основе нейросетей, такие как FusionNet и Deep Sensor Fusion, предлагают более гибкие подходы, но требуют больших вычислительных ресурсов.

Целью данной работы является разработка и сравнительный анализ традиционных и нейросетевых методов интеграции сенсорных данных в бортовых системах управления БАС. В рамках исследования рассматриваются алгоритмы фильтра Калмана, FusionNet и Deep Sensor Fusion, проводится экспериментальное тестирование их эффективности в различных условиях (городская застройка, лесная местность, открытые пространства), а также оценивается их влияние на точность навигации, вычислительные затраты и устойчивость к помехам.

### **Характеристика сенсорных данных**

Сенсорные данные, поступающие в бортовые системы управления БАС, представляют собой сложный и разнообразный массив информации, обеспечивающий детальное восприятие окружающей среды. Каждый тип сенсора имеет свои особенности, точность, частоту обновления и ограничения, которые необходимо учитывать для эффективной интеграции.

Таблица 1 систематизирует ключевые характеристики сенсоров, используемых в бортовых системах БАС, включая их точность, частоту обновления, преимущества и ограничения. Это позволяет лучше понять, какие данные могут быть интегрированы для повышения эффективности управления.

ГНСС предоставляют данные о местоположении аппарата, позволяя определять его координаты с точностью до нескольких метров и точнее. Эти данные играют ключевую роль в построении траекторий и глобальной навигации. Однако точность ГНСС существенно зависит от внешних условий. В городах сигналы часто отражаются от зданий, что приводит к ошибкам определения координат. В густой растительности или туннелях сигнал может ослабляться или полностью пропадать, что делает ГНСС ненадежным в сложных условиях эксплуатации.

Инерциальные навигационные системы, состоящие из акселерометров, гироскопов и магнитометров, предоставляют данные об ускорениях, угловых скоростях и ориентации аппарата. ИНС обеспечивают высокую частоту обновления данных, достигающую 200 Гц и выше, что делает их незаменимыми для задач краткосрочной стабилизации и мгновенного управления. Однако накопление погрешностей, известное как дрейф, ограничивает их точность в долгосрочной перспективе. Это делает

необходимой коррекцию данных ИНС с использованием внешних источников, таких как ГНСС или лидар.

Таблица 1 – Ключевые характеристики сенсоров в бортовых системах БАС  
Table 1 – Key characteristics of sensors in onboard systems of UAS

Сенсор	Точность	Частота обновления, Гц	Преимущества	Ограничения
ГНСС	До 3 м	1	Глобальное позиционирование	Уязвимость к затенению, помехам
ИНС	Высокая (в краткосрочном периоде)	200	Высокая частота данных	Накопление ошибок (дрейф)
Лидар	До 10 см	10–30	Точные трехмерные данные	Чувствительность к погодным условиям, объем данных
Камеры	До нескольких см	30	Визуальная информация	Зависимость от освещения
Тепловизоры	Низкая	10–30	Информация о тепловом излучении	Низкое разрешение, зависимость от условий

Лазерные дальномеры предоставляют трехмерную информацию об окружающей среде в виде облаков точек. Эти данные позволяют точно моделировать объекты, определять расстояния до препятствий и создавать цифровые карты местности. Лидар особенно эффективен для навигации в условиях ограниченной видимости и для предотвращения столкновений. Однако он генерирует большие объемы данных, что требует значительных вычислительных ресурсов. Точность лидара также может снижаться в условиях плохой погоды, таких как дождь, снег или пыль, которые мешают прохождению лазерных лучей.

Оптические камеры предоставляют визуальную информацию высокой детализации, которая используется для распознавания объектов, картографии и мониторинга. Камеры позволяют выделять ключевые визуальные характеристики объектов, такие как текстуры, цвета и формы. Однако их работа сильно зависит от освещения и погодных условий. В ночное время или при наличии бликов качество данных существенно снижается, что требует применения дополнительных методов обработки, таких как повышение контрастности или адаптивные фильтры.

Тепловизоры фиксируют инфракрасное излучение объектов, позволяя анализировать их тепловые характеристики. Эти данные полезны для задач поиска и спасения, мониторинга инфраструктуры и обнаружения тепловых аномалий. Например, тепловизоры эффективно используются для поиска людей в темное время суток или в густой растительности. Однако разрешение тепловизоров обычно ниже, чем у оптических камер, что ограничивает уровень детализации получаемых данных.

Эффективная работа с сенсорными данными требует их корректной интеграции, так как каждый сенсор имеет свои ограничения. Например, данные ГНСС могут теряться или содержать ошибки в условиях плотной застройки, но они могут быть скорректированы с использованием данных ИНС. Аналогично, интеграция данных лидара и камер позволяет объединить точное определение расстояний с визуальной идентификацией объектов, что повышает общую точность восприятия окружающей среды.

Одна из ключевых проблем интеграции данных заключается в необходимости синхронизации информации, поступающей с различной частотой. Например, данные

ГНСС обновляются с частотой 1 Гц, тогда как лидар и камеры могут предоставлять информацию с частотой 10–30 Гц, а ИНС – до 200 Гц. Для решения этой задачи применяются алгоритмы временной интерполяции и фильтры, такие как фильтр Калмана. Кроме того, данные от сенсоров часто содержат ошибки, которые необходимо минимизировать с помощью методов предобработки и коррекции.

Интеграция сенсорных данных позволяет объединить сильные стороны различных источников информации, компенсируя их недостатки. Например, комбинированное использование ГНСС и ИНС обеспечивает стабильное позиционирование даже при временной потере сигнала. Объединение данных лидаров и тепловизоров эффективно для обнаружения объектов в сложных условиях, таких как густая растительность или плохая видимость. Таким образом, характеристика сенсорных данных подчеркивает их важность для успешной работы БАС и необходимость разработки сложных алгоритмов интеграции, учитывающих особенности каждого сенсора.

### Методы интеграции сенсорных данных

Интеграция сенсорных данных в бортовые системы управления беспилотных авиационных систем является ключевым процессом для обеспечения точности, устойчивости и надежности их работы. Методы слияния данных направлены на объединение информации от различных сенсоров, таких как ГНСС, ИНС, лидар, камеры и тепловизоры, с целью создания целостного и точного представления окружающей среды. Эти подходы позволяют компенсировать недостатки каждого отдельного сенсора и минимизировать погрешности.

Алгоритмы слияния данных играют центральную роль в интеграции сенсорной информации. Одним из наиболее распространенных методов является фильтр Калмана. Этот метод представляет собой математический инструмент, который оптимально объединяет данные с учетом их погрешностей и временной последовательности. Например, фильтр Калмана часто используется для интеграции данных ГНСС и ИНС. ГНСС обеспечивает абсолютное позиционирование, но его данные подвержены помехам и потере сигнала. ИНС, в свою очередь, предоставляет данные с высокой частотой, но подвержена накоплению ошибок. Фильтр Калмана позволяет сглаживать временные выбросы ГНСС, одновременно компенсируя накопление дрейфа ИНС, что обеспечивает точное и надежное определение положения и ориентации БАС [6].

Для работы с более сложными и нелинейными системами используется расширенный фильтр Калмана (Extended Kalman Filter, EKF). EKF адаптирован для обработки данных, которые не подчиняются линейным зависимостям, и поэтому идеально подходит для интеграции ГНСС, ИНС и лидара. Например, в условиях динамического полета БАС данные ИНС и ГНСС могут содержать значительные нелинейности, связанные с ускорением, угловыми скоростями и изменениями траектории. EKF позволяет учитывать эти нелинейности и обеспечивает высокую точность в задачах позиционирования и навигации.

Байесовские методы интеграции данных предлагают другой подход к объединению информации. Они основаны на вероятностной модели, которая учитывает неопределенности и степень надежности данных от каждого сенсора. Например, при объединении данных лидара и камер байесовский подход позволяет учитывать различные уровни шума, связанные с внешними условиями, такими как освещение или наличие препятствий. Этот метод также используется для работы с мультимодальными данными, где источники информации предоставляют разные типы данных, такие как трехмерная структура (лидары) и визуальные изображения (камеры). Байесовские

методы обеспечивают адаптивное объединение информации, минимизируя влияние некорректных или некачественных данных.

Алгоритмы слияния данных требуют тщательной синхронизации информации, поступающей с различной частотой. Например, ГНСС может обновляться с частотой 1 Гц, тогда как лидар работает с частотой 10–30 Гц, а ИНС предоставляет данные с частотой до 200 Гц. Для корректного объединения данных применяются методы временной интерполяции, которые позволяют синхронизировать информацию в едином временном масштабе [7]. Этот процесс особенно важен для задач реального времени, где задержки или ошибки синхронизации могут существенно повлиять на точность системы. Нейронные сети в целом активно применяются в работе с беспилотными авиационными системами. Причем могут использоваться как широко распространенные модели, обученные под конкретные применения [8], так и узкоспециализированные модели [9]. Для повышения эффективности интеграции данных используются подходы на основе машинного обучения. Например, рекуррентные нейронные сети (RNN) и их производные, такие как LSTM (долгая краткосрочная память), позволяют обучать модели для обработки последовательностей данных с временной зависимостью. Такие подходы эффективно справляются с задачами прогнозирования и исправления ошибок сенсорных данных, что особенно важно для сложных динамических систем, таких как беспилотные аппараты.

Таким образом, методы интеграции сенсорных данных обеспечивают объединение различных источников информации в единую систему, способную адаптироваться к сложным и изменчивым условиям. Фильтры Калмана и его расширенные версии, байесовские подходы и алгоритмы машинного обучения позволяют создать устойчивую и точную модель окружающей среды, минимизируя влияние ошибок и недостатков отдельных сенсоров. Эти методы становятся основой для разработки современных бортовых систем управления, обеспечивающих высокую надежность и эффективность беспилотных авиационных систем.

Современные подходы к интеграции сенсорных данных все чаще включают использование глубоких нейронных сетей, которые способны обучаться на больших объемах данных для автоматического объединения информации от различных сенсоров [10]. В отличие от традиционных алгоритмов слияния, таких как фильтр Калмана или байесовские методы, обучаемые модели обладают способностью адаптироваться к сложным, нелинейным зависимостям и учитывать мультимодальность данных. Модель комплексирования и обработки данных представлена на Рисунке 1.




Рисунок 1 – Модель комплексирования и обработки данных в бортовом вычислительном комплексе

Figure – Model of data integration and processing in the onboard computing complex

Одной из ключевых архитектур в этой области является FusionNet, которая была разработана для объединения данных от камер и лидара. FusionNet использует двухпотокную структуру: один поток анализирует трехмерные данные лидара в виде облаков точек, а другой обрабатывает изображения с камер, извлекая текстурные и

визуальные особенности. Затем информация из двух потоков объединяется на уровне скрытых представлений с помощью многослойного перцептрона (MLP) или других механизмов слияния, таких как внимания (attention mechanisms). Такой подход позволяет не только эффективно распознавать объекты, но и учитывать их пространственное положение и геометрическую форму. Например, FusionNet успешно применяется для идентификации пешеходов и транспортных средств в автономных системах навигации, где требуется высокая точность в сложных условиях городской среды.

Еще одним передовым подходом являются модели Deep Sensor Fusion, разработанные для интеграции данных от ИНС, камер и лидаров. Эти модели используют рекуррентные нейронные сети (RNN) для анализа временной последовательности данных от ИНС, в то время как сверточные нейронные сети (CNN) обрабатывают визуальную информацию. Трехмерные данные от лидара включаются через специализированные слои, такие как PointNet или VoxelNet, которые преобразуют облака точек в структурированную форму для дальнейшей обработки. Затем данные объединяются в едином латентном пространстве, что позволяет учитывать как временные, так и пространственные зависимости. Deep Sensor Fusion демонстрирует высокую эффективность в задачах автономной навигации, где требуется предсказание траекторий движения, избегание препятствий и построение карты окружающей среды в реальном времени.

Основное преимущество обучаемых моделей заключается в их способности адаптироваться к изменяющимся условиям, таким как изменения освещения, погодные явления или наличие шума в данных. Для этого такие модели обучаются на разнообразных наборах данных, включающих сценарии с различными комбинациями сенсорных помех. Например, FusionNet может быть обучена на данных, где изображения камер содержат засветки или затемнения, а облака точек лидаров – частично отсутствующие сегменты. Это позволяет модели сохранять высокую точность даже в нестандартных условиях.

Интеграция обучаемых моделей в бортовые системы БАС требует значительных вычислительных ресурсов, однако современные достижения в области аппаратного обеспечения, такие как графические процессоры (GPU) и тензорные процессоры (TPU), делают возможным их использование в реальном времени. Кроме того, для повышения энергоэффективности и снижения задержек используются методы оптимизации, такие как квантизация и обрезка (pruning) весов модели, что позволяет выполнять сложные вычисления на устройствах с ограниченными ресурсами.

Таким образом, обучаемые модели, такие как FusionNet и Deep Sensor Fusion, становятся неотъемлемой частью современных подходов к интеграции сенсорных данных [11]. Их способность к обработке сложных, мультимодальных данных, учету временных зависимостей и адаптации к разнообразным условиям делает их важным инструментом для разработки высокоэффективных и надежных бортовых систем управления беспилотных авиационных систем.

Для реализации интеграции сенсорных данных в бортовых системах БАС разработан алгоритм, включающий сбор, синхронизацию, фильтрацию и объединение данных от различных сенсоров.

Алгоритм использует два подхода: FusionNet (анализ лидара и камер с помощью нейросетей) и Deep Sensor Fusion (комплексная обработка данных от ИНС, лидара и камер). Для повышения эффективности предусмотрена оптимизация моделей.

Ниже представлен алгоритм, обеспечивающий последовательное выполнение этих этапов в бортовой системе управления БАС.

НАЧАЛО

// 1. Сбор данных

```

ФУНКЦИЯ CollectSensorData()
    gps_data ← GetGPSData() // Получить данные ГНСС
    lidar_data ← GetLidarData() // Получить данные лидара
    imu_data ← GetIMUData() // Получить данные ИНС
    ВОЗВРАТ {gps_data, lidar_data, imu_data}
// 2. Синхронизация данных
ФУНКЦИЯ SynchronizeData(sensor_data, target_frequency)
    Для каждого sensor в sensor_data:
        timestamps ← sensor.timestamps
        values ← sensor.values
        common_timestamps ← GenerateTimestamps(min(timestamps), max(timestamps), 1 /
target_frequency)
        interpolated_values ← Interpolate(timestamps, values, common_timestamps)
        Сохранить {common_timestamps, interpolated_values} как sensor.synchronized
    ВОЗВРАТ sensor_data
// 3. Обработка данных: фильтрация и устранение шума
ФУНКЦИЯ ProcessData(sensor_data)
    Для каждого sensor в sensor_data:
        sensor.filtered ← KalmanFilter(sensor.synchronized)
    ВОЗВРАТ sensor_data
// 4. Интеграция данных с помощью FusionNet
ФУНКЦИЯ FusionNetIntegration(lidar_data, camera_data)
    lidar_features ← ExtractFeaturesFromLidar(lidar_data)
    camera_features ← ExtractFeaturesFromCamera(camera_data)
    combined_features ← CombineFeatures(lidar_features, camera_features)
    predictions ← NeuralNetworkPredict(combined_features)
    ВОЗВРАТ predictions
// 5. Интеграция данных с помощью Deep Sensor Fusion
ФУНКЦИЯ DeepSensorFusionIntegration(imu_data, lidar_data, camera_data)
    imu_features ← ProcessTemporalSequence(imu_data)
    lidar_features ← ProcessPointCloud(lidar_data)
    camera_features ← ProcessImageSequence(camera_data)
    combined_features ← CombineFeatures(imu_features, lidar_features, camera_features)
    predictions ← NeuralNetworkPredict(combined_features)
    ВОЗВРАТ predictions
// 6. Оптимизация моделей
ФУНКЦИЯ OptimizeModels(models)
    Для каждого model в models:
        model.optimized ← ApplyQuantization(model)
        model.optimized ← ApplyPruning(model.optimized)
    ВОЗВРАТ models
// Основной процесс
ФУНКЦИЯ Main()
// Сбор данных
    sensor_data ← CollectSensorData()
// Синхронизация данных
    synchronized_data ← SynchronizeData(sensor_data, target_frequency=100)
// Обработка данных
    processed_data ← ProcessData(synchronized_data)
// Интеграция с помощью FusionNet
    fusion_results ← FusionNetIntegration(processed_data.lidar, processed_data.camera)
// Интеграция с помощью Deep Sensor Fusion
    deep_fusion_results ← DeepSensorFusionIntegration(processed_data.imu, processed_data.lidar,
processed_data.camera)
    
```



```
// Оптимизация моделей
models ← {FusionNetModel, DeepSensorFusionModel}
optimized_models ← OptimizeModels(models)
// Результат
Вывести fusion_results
Вывести deep_fusion_results
КОНЕЦ
CollectSensorData() – Сбор данных с ГНСС, лидара и ИНС.
SynchronizeData() – Приведение данных сенсоров к единому временному масштабу.
ProcessData() – Очистка данных и фильтрация с помощью фильтра Калмана.
FusionNetIntegration() – Интеграция данных с использованием FusionNet.
DeepSensorFusionIntegration() – Обработка временных и пространственных зависимостей данных.
OptimizeModels() – Оптимизация моделей для повышения производительности.
```

Предлагаемый алгоритм представляет собой последовательность шагов для сбора, синхронизации, обработки и интеграции данных с разных сенсоров (ГНСС, лидара, ИНС и камеры) с использованием методов машинного обучения и фильтрации. Включает этапы синхронизации данных, их очистки с помощью фильтра Калмана, интеграции через FusionNet и Deep Sensor Fusion, а также оптимизации моделей для повышения их производительности.

### Преимущества интеграции данных

Интеграция сенсорных данных в бортовых системах управления беспилотников открывает широкий спектр преимуществ, существенно улучшая точность, надежность и эффективность работы систем. Она позволяет использовать сильные стороны каждого из сенсоров, компенсируя их индивидуальные недостатки, и тем самым обеспечивает более высокое качество выполнения задач, таких как навигация, мониторинг и предотвращение столкновений.

Одним из ключевых преимуществ является повышение точности навигации от 20 % до 40 % в зависимости от условий эксплуатации и используемых методов интеграции. Сенсоры, такие как ГНСС и ИНС, предоставляют данные о положении аппарата и его движении, однако каждый из них имеет ограничения. ГНСС может быть подвержен сбоям, например, в условиях плотной застройки, под густой растительностью или в туннелях, где сигнал спутников затруднен. С другой стороны, ИНС, хотя и предоставляет данные с высокой частотой обновления, подвержен накоплению ошибок (дрейфу) при длительном использовании. Интеграция этих сенсоров с помощью алгоритмов слияния, таких как фильтр Калмана или его расширенные версии, позволяет компенсировать недостатки каждого из них. ГНСС обеспечивает долгосрочную точность, а ИНС – стабилизацию в краткосрочной перспективе. Это особенно важно для задач, где требуется высокая точность позиционирования, например, при выполнении маневров в сложных условиях.

Устойчивость к внешним помехам – еще одно важное преимущество интеграции данных. Каждый сенсор обладает своими уязвимостями: камеры зависят от условий освещения и могут терять эффективность в условиях низкой освещенности или при наличии бликов, тогда как лидар, несмотря на высокую точность в трехмерной реконструкции, может испытывать трудности при работе в условиях дождя, снега или пыли [12]. Объединение данных от камер и лидара позволяет компенсировать эти недостатки. Например, визуальная информация с камер может быть использована для уточнения классификации объектов, зафиксированных лидаром, а трехмерные данные облаков точек помогают дополнить недостатки визуальной информации в условиях

сложной видимости. Такое сочетание значительно улучшает устойчивость системы к внешним воздействиям и позволяет успешно выполнять задачи даже в условиях переменных погодных условий.

Третий ключевой аспект интеграции данных – это эффективное использование вычислительных ресурсов. Современные алгоритмы слияния данных разработаны с учетом необходимости работы в условиях ограниченных вычислительных мощностей бортовых систем. Интеграция данных позволяет оптимизировать обработку за счет снижения объема данных, необходимых для анализа. Например, сжатие информации или ее фильтрация на этапе предварительной обработки позволяют уменьшить нагрузку на процессоры. Более того, методы машинного обучения, такие как нейронные сети, могут быть оптимизированы с использованием квантизации и обрезки (pruning), что снижает энергопотребление и время вычислений без значительной потери точности. Это особенно важно для беспилотных авиационных систем, где каждая единица энергии на борту имеет критическое значение.

Таким образом, интеграция сенсорных данных не только повышает точность навигации и устойчивость к внешним помехам, но и способствует оптимальному использованию ресурсов, что делает ее важнейшим элементом современных бортовых систем управления. Эти преимущества обеспечивают беспилотным авиационным системам надежность и эффективность в самых сложных условиях эксплуатации.

### Экспериментальная часть

Для оценки эффективности методов интеграции сенсорных данных была проведена серия экспериментов в различных условиях эксплуатации беспилотных авиационных систем [13]. В тестировании использовался БЛА класса малой авиации, оснащенный высокопроизводительной системой обработки данных. В эксперименте применялась беспилотная авиационная система miniSIGMA с вертикальным взлетом и посадкой (размах крыла 2,5 м, максимальная взлетная масса 16 кг, масса полезной нагрузки 2,5 кг), с установленным оборудованием: ГНСС с поддержкой RTK, обеспечивающей повышенную точность определения координат, ИНС на базе комбинированного акселерометра и гироскопа с частотой обновления 200 Гц, лидар с дальностью измерений до 100 м, оптической камерой Sony RX1 с матрицей высокого разрешения (4K, 30 FPS). Выбор данного типа БАС обусловлен тем, что он обладает достаточной грузоподъемностью для размещения различных сенсоров, а также высокой вычислительной мощностью бортового комплекса, работающего на базе Jetson Xavier NX, необходимой для выполнения алгоритмов интеграции данных в реальном времени.

Тестирование охватывало три типа местности: городскую застройку, лесные массивы и открытую местность. Эти среды были выбраны для анализа работы алгоритмов интеграции в условиях, предъявляющих разные требования к сенсорам и алгоритмам обработки данных. Беспилотные аппараты были оснащены сенсорами ГНСС, ИНС, лидаром и камерами, данные с которых обрабатывались двумя подходами: традиционными методами фильтрации, такими как фильтр Калмана, и обучаемыми моделями, включая FusionNet.

В ходе эксперимента в городской застройке основное внимание уделялось влиянию плотной инфраструктуры на точность позиционирования. Сигнал ГНСС подвергался искажениям и затенениям, что делало интеграцию с данными ИНС и лидара критически важной. Результаты показали, что использование расширенного фильтра Калмана позволило сократить среднеквадратическое отклонение позиционирования с 8 м при работе только с ГНСС до 2,5 м при интеграции данных. FusionNet, благодаря адаптивной обработке данных лидара и камер, обеспечил еще более высокую точность,

снижая отклонение до 1,8 м. Даже при наличии помех и низком освещении FusionNet демонстрировал точность до 95 %, тогда как традиционные алгоритмы снижали ее до 80 %.

Тестирование в лесных массивах выявило особые сложности, связанные с плотной растительностью, создающей шум в данных лидара и камер. FusionNet, интегрирующий информацию от всех сенсоров, позволил улучшить качество реконструкции окружающей среды на 15 % по сравнению с традиционными методами. Это выразилось в большей плотности облаков точек и лучшей детализации объектов. Методы традиционной фильтрации оказались менее устойчивыми к шумам, что приводило к пропускам данных и снижению качества реконструкции.

На Рисунке 2 представлены данные о точности позиционирования и успешности выполнения задач в различных условиях эксплуатации для методов EKF и FusionNet.

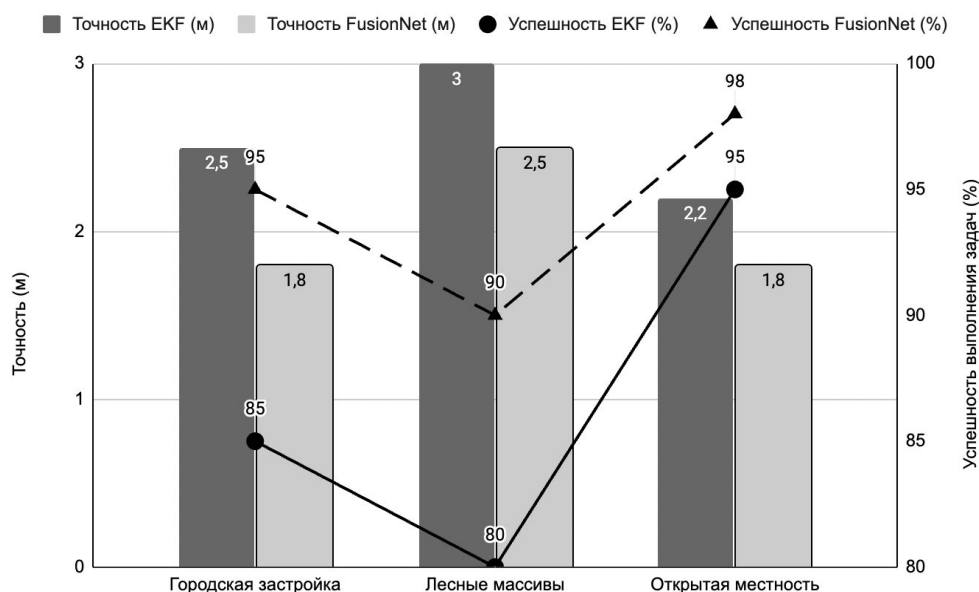


Рисунок 2 – Сравнение точности и успешности EKF и FusionNet  
 Figure 2 – Comparison of the accuracy and success rate of EKF and FusionNet

На открытой местности, где влияние внешних факторов минимально, различия между подходами оказались менее выраженными. Однако FusionNet показал преимущества в скорости обработки данных, сокращая время на 20 % за счет параллельной обработки на уровне нейронной сети. При этом энергопотребление FusionNet оказалось на 15 % ниже, чем у традиционных алгоритмов, благодаря эффективному использованию графических процессоров (GPU) и нейропроцессоров (NPU).

Результаты эксперимента подтвердили, что современные обучаемые модели превосходят традиционные подходы в сложных условиях эксплуатации, таких как городская застройка и лесные массивы. Они демонстрируют более высокую точность, устойчивость и производительность. В то же время традиционные методы фильтрации могут оставаться актуальными для задач, где важна низкая вычислительная сложность и стабильные условия работы. Таким образом, оптимальный подход к интеграции сенсорных данных может включать гибридное решение, комбинирующее преимущества обоих методов.

Для оценки эффективности различных методов интеграции сенсорных данных в реальных условиях были проведены эксперименты в городских, лесных и на открытых

местностях. Результаты, представленные в Таблице 2, демонстрируют, как традиционные и обучаемые методы работают в сложных и стабильных условиях эксплуатации.

Таблица 2 – Сравнение эффективности работы методов интеграции данных БАС  
Table 2 – Comparison of the efficiency of UAS data integration methods

Условия	Метод	Точность позиционирования, м	Процент успешного выполнения задач, %	Примечания
Городская застройка	EKF	2,5	85	Затенение ГНСС
	FusionNet	1,8	95	Высокая точность даже при помехах
Лесные массивы	EKF	3,0	80	Шумы лидара
	FusionNet	2,5	90	Лучшая работа с мультимодальными данными
Открытая местность	EKF	2,2	95	Минимум помех
	FusionNet	1,8	98	Более высокая скорость обработки

### Заключение

Интеграция сенсорных данных в бортовые системы управления беспилотных авиационных систем является важным элементом, обеспечивающим их надежность, точность и функциональную гибкость. Проведенное исследование продемонстрировало, что использование современных алгоритмов слияния данных, таких как фильтр Калмана и его расширенные версии, позволяет значительно улучшить точность позиционирования, даже в условиях затенения ГНСС или помех. Предлагаемый подход обеспечивает более устойчивую работу системы в сложных сценариях, таких как плотная городская застройка, густые лесные массивы или динамические внешние условия.

Обучаемые модели, такие как Deep Sensor Fusion и FusionNet, показали свою эффективность в объединении данных от различных сенсоров, включая ГНСС, ИНС, лидара и камеры. Эти модели не только повышают точность позиционирования и качества реконструкции окружающей среды, но и оптимизируют использование вычислительных ресурсов за счет параллельной обработки и адаптивных алгоритмов. Особую ценность такие подходы представляют в задачах автономной навигации, где высокая степень автономии систем критически важна для их успешного функционирования.

В работе проведен анализ традиционных и нейросетевых методов интеграции сенсорных данных в бортовых системах управления беспилотных авиационных систем. В ходе экспериментов с использованием БЛА малой авиации, оснащенного ГНСС, ИНС, лидаром и камерой, были получены следующие ключевые результаты:

Интеграция данных с использованием расширенного фильтра Калмана (EKF) позволила снизить среднеквадратическое отклонение позиционирования с 8 м (ГНСС без коррекции) до 2,5 м. Применение нейросетевой модели FusionNet дало еще более высокую точность (1,8 м), особенно в условиях городских помех и лесных массивов, увеличив долю успешных навигационных решений с 85 % до 95 %. Использование Deep Sensor Fusion позволило адаптировать интеграцию данных в зависимости от условий, улучшив устойчивость системы к шумам и внешним воздействиям. Нейросетевые

методы продемонстрировали снижение вычислительных затрат на 20 % за счет параллельной обработки данных, что особенно важно для автономных миссий.

Таким образом, нейросетевые методы FusionNet и Deep Sensor Fusion превосходят традиционные алгоритмы в сложных условиях эксплуатации, обеспечивая более точное и устойчивое позиционирование. Однако ЕKF остается актуальным для задач, требующих низкой вычислительной сложности.

Перспективы дальнейших исследований включают разработку адаптивных алгоритмов интеграции для автоматического подбора оптимального метода в зависимости от условий полета, а также внедрение гиперспектральных сенсоров для расширения возможностей беспилотных авиационных систем.

В рамках дальнейших исследований ключевыми направлениями являются разработка адаптивных методов интеграции, способных автоматически учитывать изменения условий эксплуатации, такие как погодные факторы, динамика полета и наличие помех [14]. Также важным шагом вперед станет внедрение гиперспектральных сенсоров в состав бортовых систем [15]. Эти сенсоры позволят расширить спектр анализируемых данных, предоставляя информацию о химическом составе объектов, биологическом состоянии растительности и других характеристиках, недоступных для традиционных сенсоров.

Перспективные направления исследований в области интеграции сенсорных данных направлены на повышение адаптивности методов, внедрение новых сенсоров и оптимизацию вычислительных ресурсов. Основные аспекты представлены в Таблице 3.

Таблица 3 – Перспективы дальнейших исследований  
Table 3 – Prospects for further research

Направление	Описание	Ожидаемый эффект
Адаптивные методы интеграции	Автоматическое учет изменений условий эксплуатации	Повышение надежности в изменчивых условиях
Гиперспектральные сенсоры	Внедрение сенсоров для анализа химического состава, состояния растительности и других характеристик	Расширение спектра решаемых задач
Ускорение алгоритмов слияния данных	Использование более эффективных методов оптимизации	Снижение энергопотребления и времени обработки

Таким образом, комплексирование сенсорных данных остается одной из самых перспективных и востребованных областей развития беспилотных авиационных систем. Дальнейшее совершенствование алгоритмов обработки данных и внедрение новых сенсорных технологий откроет возможности для их применения в еще более широком спектре задач, включая мониторинг окружающей среды, автономную логистику, сельское хозяйство и поисково-спасательная деятельность.

### СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Гулютин Н.Н. Применение беспилотных летательных аппаратов в задачах лесного здоровья. В сборнике: *Решетневские чтения: Материалы XXVI Международной научно-практической конференции, посвященной памяти генерального конструктора ракетно-космических систем академика М.Ф. Решетнева: Часть 2, 09–11 ноября 2022 года, Красноярск, Россия*. Красноярск: Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева; 2022. С. 305–307.

- Gulyutin N.N. Unmanned Aerial Vehicles in Forest Pathological Monitoring. In: *Reshetnevskie chteniya: Materialy XXVI Mezhdunarodnoi nauchno-prakticheskoi konferentsii, posvyashchennoi pamyati general'nogo konstruktora raketno-kosmicheskikh sistem akademika M.F. Reshetneva: Part 2, 09–11 November 2022, Krasnoyarsk, Russia*. Krasnoyarsk: Reshetnev Siberian State University of Science and Technology; 2022. pp. 305–307. (In Russ.).
2. Watts A.C., Ambrosia V.G., Hinkley E.A. Unmanned Aircraft Systems in Remote Sensing and Scientific Research: Classification and Considerations of Use. *Remote Sensing*. 2012;4(6):1671–1692. <https://doi.org/10.3390/rs4061671>
  3. Balestrieri E., Daponte P., De Vito L., Lamonaca F. Sensors and Measurements for Unmanned Systems: An Overview. *Sensors*. 2021;21(4). <https://doi.org/10.3390/s21041518>
  4. Антамошкин О.А. Проектирование высоконадежных систем реального времени. *Труды МАИ*. 2011;(45). URL: <https://trudymai.ru/published.php?ID=25347>  
Antamoshkin O.A. Designing of highly reliable real-time systems. *Trudy MAI*. 2011;(45). (In Russ.). URL: <https://trudymai.ru/published.php?ID=25347>
  5. Chekmarev S.A., Khanov V.Kh., Antamoshkin O.A. Modification of fault injection method via on-chip debugging for processor cores of systems-on-chip. In: *2015 International Siberian Conference on Control and Communications (SIBCON), 21–23 May 2015, Omsk, Russia*. IEEE; 2015. <https://doi.org/10.1109/SIBCON.2015.7147267>
  6. Montañez O.J., Suarez M.J., Fernandez E.A. Application of Data Sensor Fusion Using Extended Kalman Filter Algorithm for Identification and Tracking of Moving Targets from LiDAR–Radar Data. *Remote Sensing*. 2023;15(13). <https://doi.org/10.3390/rs15133396>
  7. Chen W., Zhou C., Shang G., Wang X., Li Z., Xu C., Hu K. SLAM Overview: From Single Sensor to Heterogeneous Fusion. *Remote Sensing*. 2022;14(23). <https://doi.org/10.3390/rs14236033>
  8. Guliutin N., Antamoshkin O. Enhancing unmanned aerial vehicle capabilities: integrating YOLO algorithms for diverse industrial applications. In: *Hybrid Methods of Modeling and Optimization in Complex Systems (HMMOCS-II 2023): Proceedings of the II International Workshop: Volume 59, 28–30 November 2023, Krasnoyarsk, Russia*. EDP Sciences; 2024. <https://doi.org/10.1051/itmconf/20245903012>
  9. Гулютин Н.Н., Ермиенко Н.А. Применение ансамблей деревьев решения в задачах дистанционного зондирования Земли с беспилотных летательных аппаратов. В сборнике: *Региональные проблемы дистанционного зондирования Земли: Материалы XI Международной научной конференции, 10–13 сентября 2024 года, Красноярск, Россия*. Красноярск: Сибирский федеральный университет; 2024. С. 77–80.  
Guliutin N.N., Ermienko N.A. Application of Decision Trees Ensembles in Earth Remote Sensing Problems from Unmanned Aerial Vehicles. In: *Regional'nye problemy distantsionnogo zondirovaniya Zemli: Materialy XI Mezhdunarodnoi nauchnoi konferentsii, 10–13 September 2024, Krasnoyarsk, Russia*. Krasnoyarsk: Siberian Federal University; 2024. pp. 77–80. (In Russ.).
  10. Wong C.-C., Feng H.-M., Kuo K.-L. Multi-Sensor Fusion Simultaneous Localization Mapping Based on Deep Reinforcement Learning and Multi-Model Adaptive Estimation. *Sensors*. 2024;24(1). <https://doi.org/10.3390/s24010048>
  11. Zhang R., Shao Z., Huang X., Wang J., Li D. Object Detection in UAV Images via Global Density Fused Convolutional Network. *Remote Sensing*. 2020;12(19). <https://doi.org/10.3390/rs12193140>

12. Caballero-Martin D., Lopez-Guede J.M., Estevez J., Graña M. Artificial Intelligence Applied to Drone Control: A State of the Art. *Drones*. 2024;8(7). <https://doi.org/10.3390/drones8070296>
13. Dudczyk J., Czyba R., Skrzypczyk K. Multi-Sensory Data Fusion in Terms of UAV Detection in 3D Space. *Sensors*. 2022;22(12). <https://doi.org/10.3390/s22124323>
14. Zhang Z., Zhu L. A Review on Unmanned Aerial Vehicle Remote Sensing: Platforms, Sensors, Data Processing Methods, and Applications. *Drones*. 2023;7(6). <https://doi.org/10.3390/drones7060398>
15. Stuart M.B., McGonigle A.J.S., Willmott J.R. Hyperspectral Imaging in Environmental Monitoring: A Review of Recent Developments and Technological Advances in Compact Field Deployable Systems. *Sensors*. 2019;19(14). <https://doi.org/10.3390/s19143071>

### ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

**Гулютин Николай Николаевич**, ассистент кафедры программной инженерии Института космических и информационных технологий, Сибирский федеральный университет, Красноярск, Российская Федерация.

*e-mail:* [gulyutin@gmail.com](mailto:gulyutin@gmail.com)

ORCID: [0009-0002-1048-3766](https://orcid.org/0009-0002-1048-3766)

**Nikolay N. Gulyutin**, Assistant of the Department of Software Engineering, Institute of Space and Information Technology, Siberian Federal University, Krasnoyarsk, the Russian Federation.

**Ермиенко Надежда Александровна**, аспирант Института космических и информационных технологий, Сибирский федеральный университет, Красноярск, Российская Федерация.

*e-mail:* [Nadukako@yandex.ru](mailto:Nadukako@yandex.ru)

ORCID: [0009-0004-5732-9971](https://orcid.org/0009-0004-5732-9971)

**Nadezhda A. Ermienko**, graduate student of the Institute of Space and Information Technology, Siberian Federal University, Krasnoyarsk, the Russian Federation.

**Антамошкин Олеся Александрович**, доктор технических наук, профессор, заведующий кафедрой программной инженерии Института космических и информационных технологий, Сибирский федеральный университет, Красноярск, Российская Федерация.

*e-mail:* [Oleslav@mail.ru](mailto:Oleslav@mail.ru)

ORCID: [0000-0002-5976-5847](https://orcid.org/0000-0002-5976-5847)

**Oleslav A. Antamoshkin**, Doctor of Engineering Sciences, Professor, Head of the Department of Software Engineering, Institute of Space and Information Technology, Siberian Federal University, Krasnoyarsk, the Russian Federation.

*Статья поступила в редакцию 22.01.2025; одобрена после рецензирования 06.02.2025; принята к публикации 10.02.2025.*

*The article was submitted 22.01.2025; approved after reviewing 06.02.2025; accepted for publication 10.02.2025.*