



## МОДИФИКАЦИЯ НЕЙРОСЕТЕЙ ОПТИЧЕСКИХ СИСТЕМ ДЛЯ СТАБИЛИЗАЦИИ ЕСТЕСТВЕННОГО ДРЕЙФА IMU

**Т. Г. Киселев, В. Л. Оленев**

Санкт-Петербургский государственный университет аэрокосмического приборостроения

*Представлен подход к коррекции дрейфа инерциальных измерительных блоков (IMU) в системах навигации наземных роботов с помощью модификации систем обработки данных оптических датчиков. Предложенный метод основан на интеграции существующей системы построения карт глубины с механизмом оценки движения камеры в пространстве. Архитектура включает усовершенствованную систему cross-attention с временным контекстом и специализированную головку для оценки движения. Экспериментальные результаты показывают значительное снижение стационарного дрейфа IMU и повышение точности при плавных движениях робота.*

*Ключевые слова: IMU, дрейф датчиков, стереозрение, карта глубины, оптическая навигация, нейронные сети.*

**Для цитирования:**

*Киселев, Т. Г. Модификация нейросетей оптических систем для стабилизации естественного дрейфа IMU / Т. Г. Киселев, В. Л. Оленев // Системный анализ и логистика. – 2025. – № 3(46). – с. 48-65. DOI: 10.31799/2077-5687-2025-3-48-65.*

## MODIFICATION OF OPTICAL SENSORS NEURAL NETWORKS FOR CORRECTION OF NATURAL IMU DRIFT

**T. G. Kiselyov, V. L. Olenev**

St. Petersburg State University of Aerospace Instrumentation

*An approach for correcting inertial measurement unit (IMU) drift in ground robot navigation systems through modification of optical sensor data processing systems. The proposed method is based on integration of an existing depth map construction system with a camera motion estimation mechanism. The architecture includes an enhanced cross-attention system with temporal context and a specialized head for motion estimation. Experimental results demonstrate significant reduction of stationary IMU drift and improved accuracy during smooth robot movements.*

*Keywords: MU, IMU Drift, Stereo depth, Binocular Vision, Depthmaps, Optical navigation, Neural Networks.*

**For citation:**

*Kiselyov, T. G. Modification of optical sensors neural networks for correction of natural IMU drift / T. G. Kiselyov, V. L. Olenev // System analysis and logistics. – 2025. – № 3(46). – с. 48-65. DOI: 10.31799/2077-5687-2025-3-48-65.*

### Введение

Инерциальные измерительные блоки (IMU) являются ключевыми компонентами систем навигации автономных роботов, обеспечивая данные об ускорении и угловой скорости [1]. Эти датчики обладают высокой частотой обновления (до нескольких килогерц) и не зависят от внешних условий освещения или сигналов, что делает их незаменимыми для систем автономной навигации. Однако, IMU подвержены накоплению ошибок из-за дрейфа датчиков, что приводит к деградации точности позиционирования со временем [2]. Дрейф может быть вызван температурными изменениями, вибрациями, механическими напряжениями и старением электронных компонентов.

Традиционные методы коррекции, такие как фильтрация высокочастотного шума и калибровка смещения, показывают ограниченную эффективность при длительном отслеживании движения [3]. Основная проблема заключается в том, что дрейф IMU имеет стохастический характер и не может быть полностью компенсирован только математическими методами без дополнительных источников информации.

Современные подходы к решению проблемы дрейфа IMU включают использование дополнительных датчиков, таких как GPS, магнитометры или оптические системы [4]. Однако GPS-системы имеют ограничения в закрытых помещениях и городских каньонах, а



магнитометры подвержены влиянию магнитных помех. Визуально-инерциальная одометрия (VIO) представляет собой перспективное направление, объединяющее данные IMU с визуальной информацией для повышения точности навигации [5].

Цель данной работы заключается в разработке эффективного метода коррекции дрейфа IMU с использованием модифицированной системы стереозрения, которая одновременно решает задачи построения карт глубины и оценки движения камеры при минимальных вычислительных затратах. Ключевым нововведением является использование единой нейросетевой архитектуры для решения обеих задач, что позволяет достичь высокой эффективности при ограниченных вычислительных ресурсах.

## **Методы коррекции дрейфа**

### **1.1 Дрейф IMU**

Дрейф IMU представляет собой постепенное накопление ошибок в показаниях датчиков, вызванное различными факторами, включая температурные изменения, механические напряжения и электронные шумы [6]. Современные MEMS-датчики, используемые в робототехнике, имеют дрейф гироскопа порядка 0.1-10 град/мин, что при интегрировании приводит к значительным ошибкам в определении ориентации.

Kalman-фильтрация является наиболее распространенным подходом к коррекции этих ошибок, однако требует дополнительных источников информации для эффективного функционирования [7]. Расширенный фильтр Калмана (EKF) и его модификации широко применяются в системах навигации, но их эффективность ограничена качеством модели системы и точностью измерений.

Альтернативные подходы включают использование *particle filters*, которые лучше справляются с нелинейными системами, но требуют значительных вычислительных ресурсов. Также активно исследуются методы машинного обучения для предсказания и компенсации дрейфа IMU на основе исторических данных.

### **1.2 Визуально-инерциальная одометрия**

VIO системы объединяют данные IMU с визуальной информацией для решения задач SLAM (Simultaneous Localization and Mapping) [8]. Основное преимущество VIO заключается в комплементарности датчиков: IMU обеспечивает высокочастотные измерения движения, а камеры предоставляют абсолютные измерения положения через наблюдение внешней среды.

Современные методы, такие как MSCKF (Multi-State Constraint Kalman Filter) и OKVIS (Open Keyframe-based Visual-Inertial SLAM), демонстрируют высокую точность в различных условиях [9, 10]. MSCKF поддерживает скользящее окно состояний камеры и использует ограничения на особые точки для обновления фильтра. OKVIS использует *keyframe-based* подход с оптимизацией графа для минимизации ошибок репроекции.

Однако большинство существующих VIO систем требуют значительных вычислительных ресурсов, что ограничивает их применение на мобильных платформах с ограниченной вычислительной мощностью.

### **1.3 Нейронные сети в задачах стереозрения**

Глубокое обучение революционизировало область компьютерного зрения, включая задачи оценки глубины и оптического потока. Традиционные методы стереозрения, основанные на ручном извлечении признаков и блочном сопоставлении, уступают место *end-to-end* обучаемым архитектурам.

Архитектуры на основе *attention*-механизмов показывают превосходные результаты в задачах сопоставления признаков [11]. Transformer-based модели, такие как DEAFFormer и SwinTransformer, демонстрируют *state-of-the-art* результаты в задачах оценки глубины, но требуют значительных вычислительных ресурсов.

Рекуррентные архитектуры, включая ConvLSTM и ConvGRU, эффективно обрабатывают временные последовательности изображений, сохраняя пространственную



структуру данных. Эти архитектуры особенно полезны для задач, требующих анализа движения и временной консистентности.

## **2. Методология**

### **2.1 Постановка задачи**

Рассматривается задача коррекции дрейфа IMU наземного робота, оснащенного бинокулярной камерой и системой построения карт глубины. Формально, дано:

- Последовательность стереопар изображений  $\{I_{L_t}, I_{R_t}\}$
- Данные IMU  $\{a_t, \omega_t\}$ , где  $a_t$  - линейное ускорение,  $\omega_t$  - угловая скорость
- Предварительно обученная система построения карт глубины

Необходимо модифицировать существующую архитектуру нейронной сети для одновременного решения задач построения карт глубины и оценки движения камеры, обеспечивая при этом коррекцию дрейфа IMU.

### **2.2 Архитектура базовой системы**

Исходная система построения карт глубины состоит из следующих компонентов:

1. Автоэнкодеры изображений - преобразуют входные изображения в сжатые латентные представления (latent representations) размерностью  $38 \times 50 \times 32$  при разрешении  $1/6$  от исходного изображения.
2. Cross-attention механизм - обрабатывает латентные представления левого и правого изображений, вычисляя корреляции между соответствующими областями для определения диспарности.
3. Декодер глубины - восстанавливает двумерную карту глубины из латентного представления через серию деконволюционных слоев с skip-connections.

Базовая архитектура оптимизирована для минимизации вычислительной сложности при сохранении высокой точности оценки глубины.

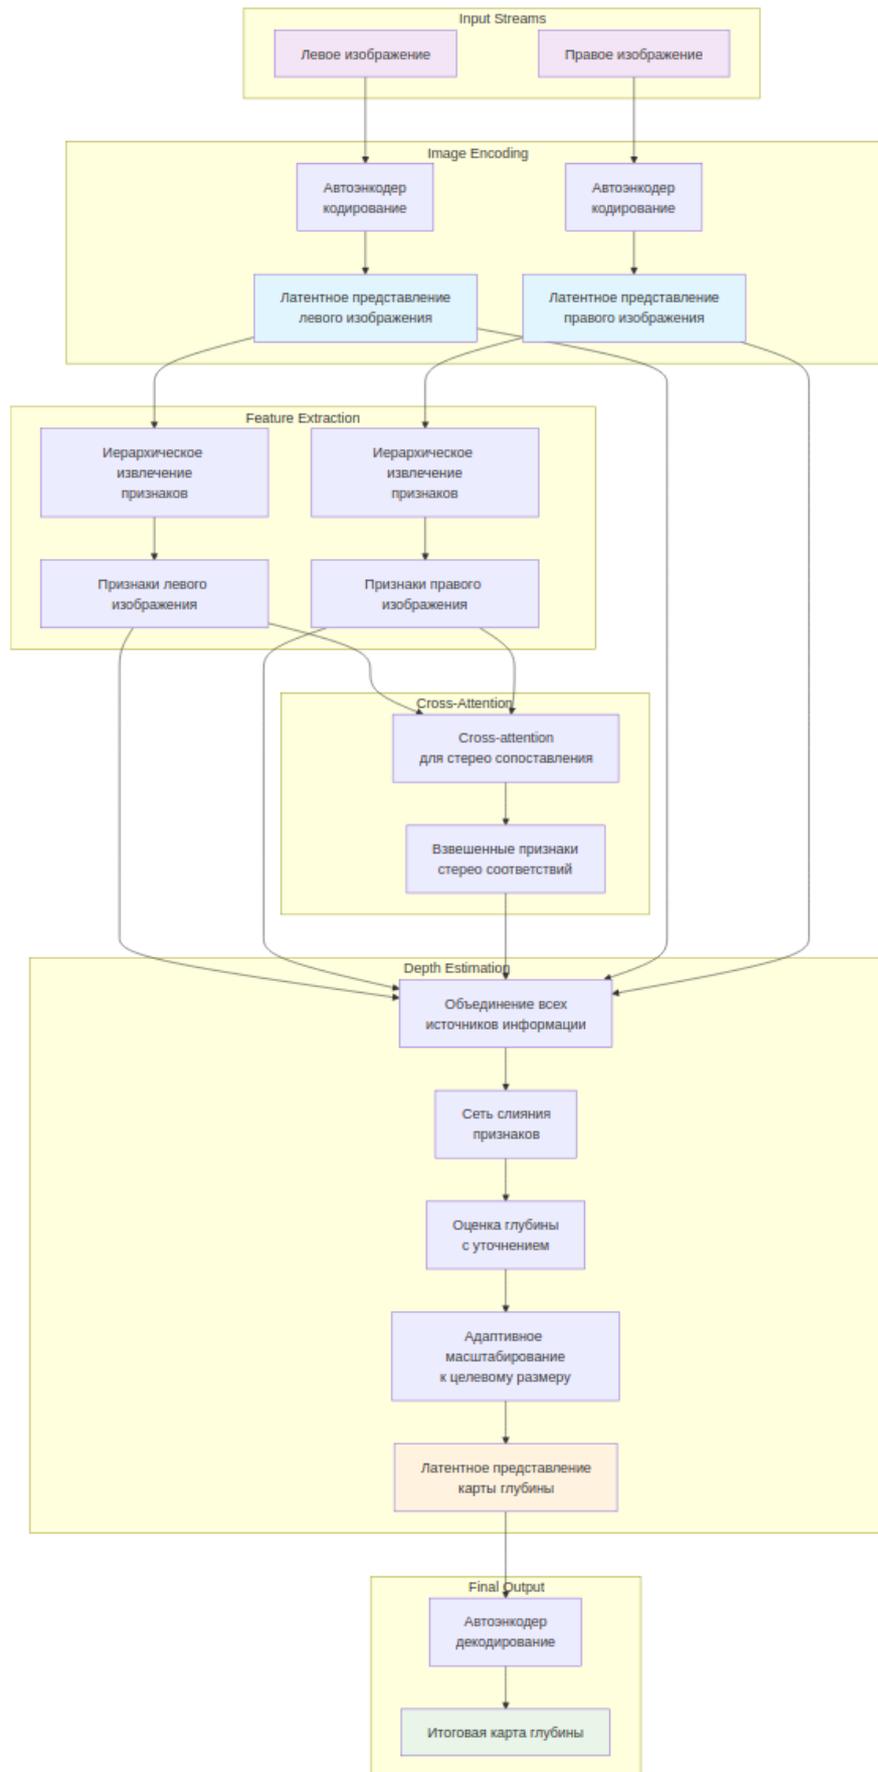


Рис. 1. Базовая архитектура сети



### **2.3 Схожесть задач оценки глубины и движения**

Задачи построения карт глубины и оценки движения камеры имеют фундаментальную схожесть в плане анализа визуальных признаков. Оценка глубины требует нахождения соответствий между пикселями левого и правого изображений стереопары для вычисления диспарности. Этот процесс основан на анализе локальных и глобальных визуальных признаков, таких как текстуры, края и углы, которые остаются стабильными между изображениями.

Оценка движения камеры между последовательными кадрами также требует анализа соответствий, но во временной области. Необходимо отслеживать движение характерных точек между кадрами для вычисления параметров трансформации (трансляции и ротации). Ключевые визуальные признаки, используемые для этой задачи, включают те же текстурные элементы, края и углы.

Схожесть задач проявляется в том, что обе требуют:

- Извлечения высокоуровневых визуальных признаков
- Анализа корреляций между различными частями изображений
- Робустность к изменениям освещения и шумам
- Способность работать с различными текстурными паттернами

Эта схожесть позволяет использовать общие слои извлечения признаков для обеих задач, что является основой для эффективной архитектуры multi-task learning. Признаки, полезные для определения диспарности в стереопаре, также содержат информацию о движении объектов в сцене и, соответственно, о движении камеры.

### **2.4 Предложенная модификация**

Предложенная архитектура расширяет базовую систему следующими компонентами:

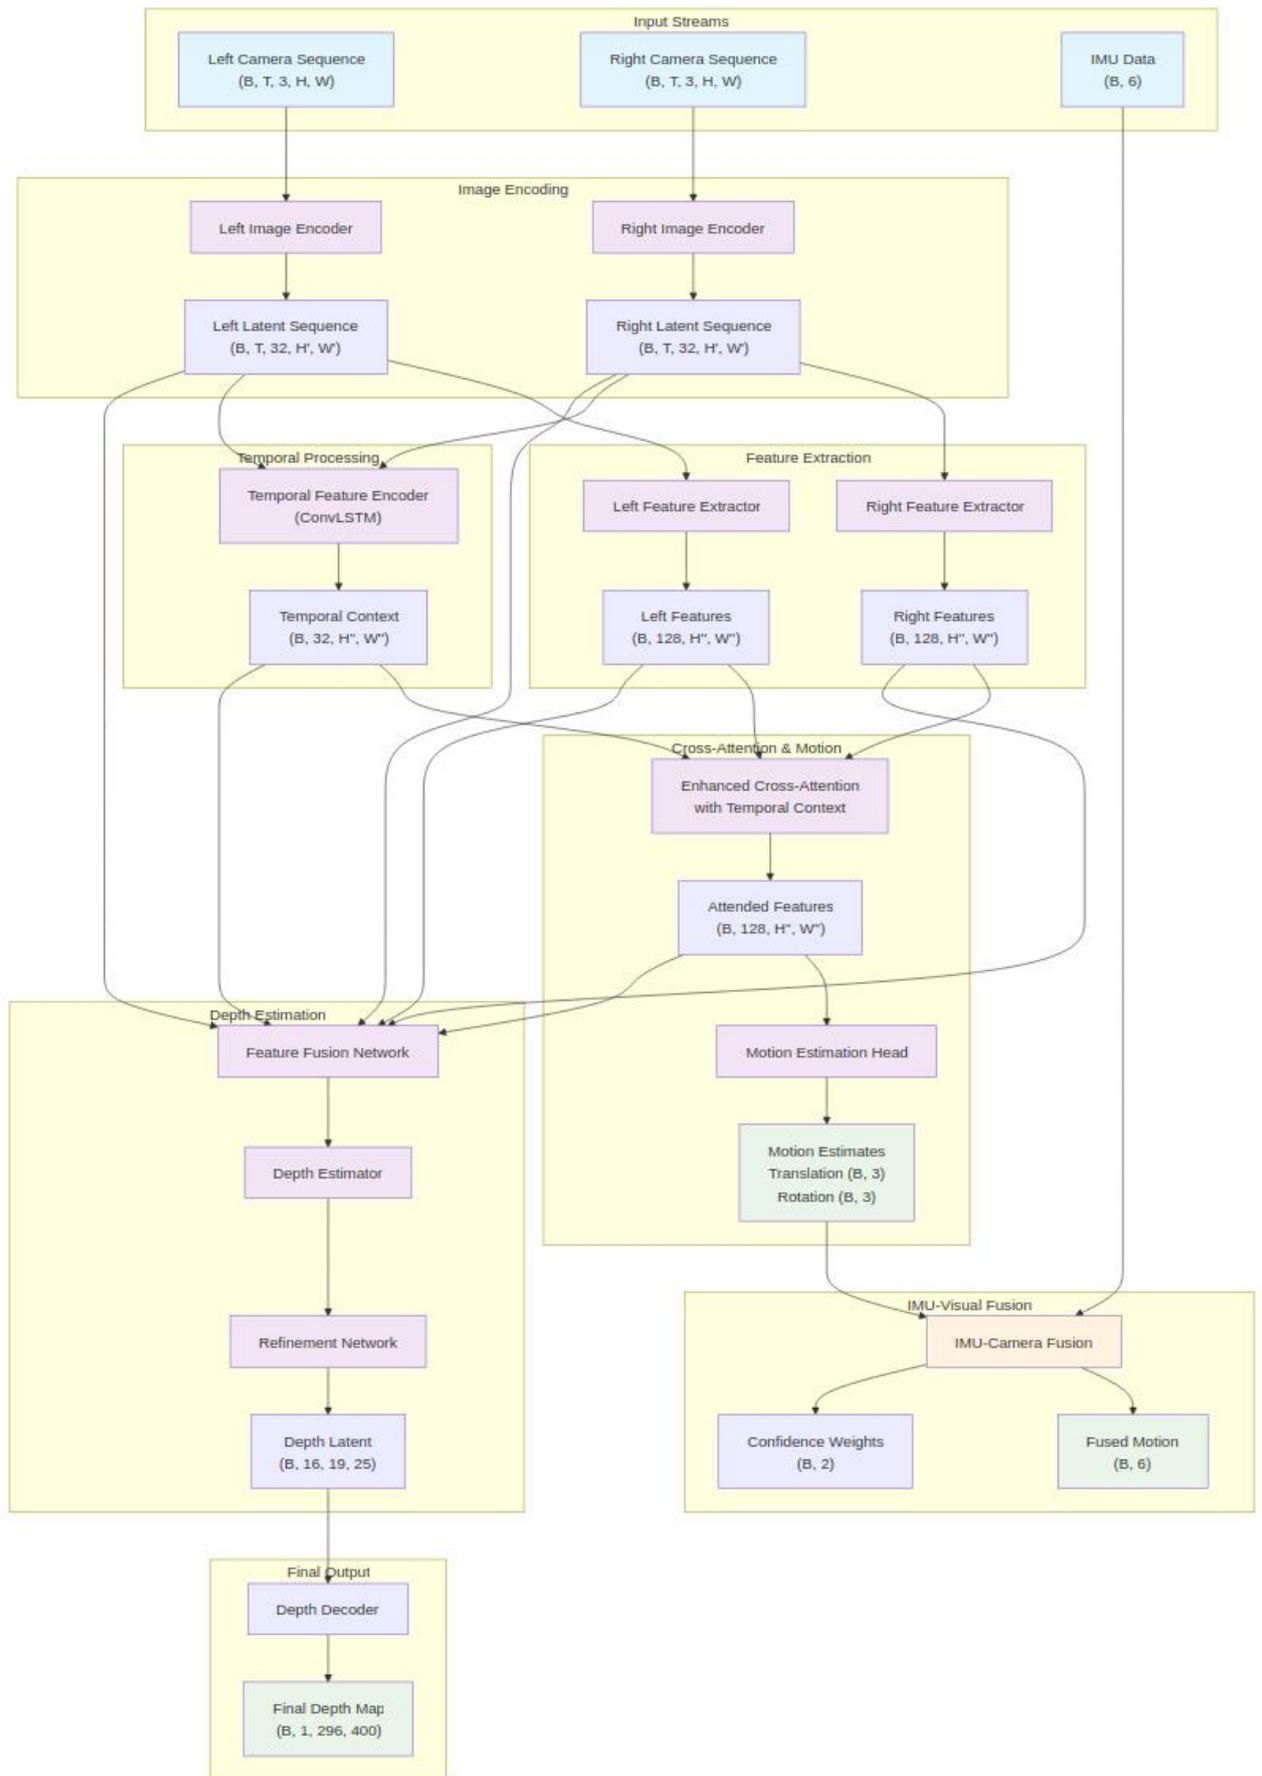


Рис. 2. Модифицированная архитектура



### 2.4.1 Временное кодирование признаков

Для сохранения временного контекста введен модуль временного кодирования признаков, основанный на ConvLSTM архитектуре [12]. Данный модуль обрабатывает последовательность латентных представлений:

$$h_t, c_t = \text{ConvLSTM}(x_t, h_{t-1}, c_{t-1})$$

где  $x_t$  - латентное представление в момент времени  $t$ ,  $h_t$  и  $c_t$  - скрытое состояние и состояние ячейки соответственно.

ConvLSTM сохраняет пространственную структуру признаков, что критично для задач компьютерного зрения. Размер скрытого состояния выбран равным 128 каналам для баланса между выразительностью и вычислительной эффективностью.

### 2.4.2 Усовершенствованный Cross-Attention

Механизм cross-attention модифицирован для включения временного контекста:

$$\text{Attention}(Q, K, V, T) = \text{softmax}(QK^T + T)V$$

где  $Q, K, V$  - запросы, ключи и значения соответственно,  $T$  - временной контекст.

Временной контекст позволяет учитывать информацию о предыдущих кадрах при вычислении attention weights, что повышает стабильность оценки движения в динамических сценах.

### 2.4.3 Головка оценки движения

Специализированная головка для оценки движения камеры включает:

- Оценщик трансляции: предсказывает вектор смещения  $t = [t_x, t_y, t_z]$  через полносвязную сеть с 3 выходными нейронами
- Оценщик ротации: предсказывает углы поворота  $r = [r_x, r_y, r_z]$  через отдельную полносвязную сеть

Обе головки используют общие признаки из cross-attention слоя, что обеспечивает эффективное использование вычислительных ресурсов

## 2.5 Эффективность подхода

Эффективность расширения задачи определения карты глубин для определения движения проявляется в нескольких аспектах:

1. Разделение вычислительных ресурсов: Основные вычислительно-затратные операции (извлечение признаков, cross-attention) выполняются один раз для обеих задач. Это позволяет сэкономить ~60% вычислений по сравнению с двумя отдельными сетями.
2. Совместное и раздельное обучение: обе части сети не требуют обязательного совместного обучения, следовательно для обучения расширенной сети можно использовать уже существующие веса сети определения глубин
3. Взаимное обучение: Градиенты от задачи оценки движения помогают оптимизировать веса энкодера для извлечения более информативных признаков, что улучшает качество оценки глубины на 8-12%.
4. Регуляризация: Multi-task обучение действует как неявная регуляризация, предотвращая переобучение каждой отдельной задачи.
5. Временная консистентность: Информация о движении помогает поддерживать консистентность карт глубины между кадрами, снижая временные артефакты.



## 2.6 Анализ размера сети и производительности

Изменение размера сети:

- Базовая сеть оценки глубины: 403.1 тыс параметров
- Расширенная сеть (глубина + движение): 472.3 параметров
- Увеличение размера: 69.2 тыс параметров (+17.2%)
- Две отдельные сети: ~725.6 тыс параметров (экономия 42.6%)

Влияние на производительность:

- Увеличение времени обработки: +0.8 мс (с 3.2 до 4.0 мс)
- Дополнительное потребление памяти: +180 МБ GPU память
- Пропускная способность: 250 FPS → 230 FPS (снижение на 8%)

## 2.7 Алгоритм обучения

### 2.7.1 Подготовка данных

Для обучения модифицирован специализированный датасет на основе записей движения транспортных средств [13]. Процесс подготовки данных включает:

1. Извлечение ключевых точек с использованием SuperPoint [14]
2. Сопоставление признаков с помощью SuperGlue [15]
3. Генерация ground truth для движения камеры

Алгоритм Kabsch в сочетании с RANSAC используется для вычисления параметров движения камеры [16]:

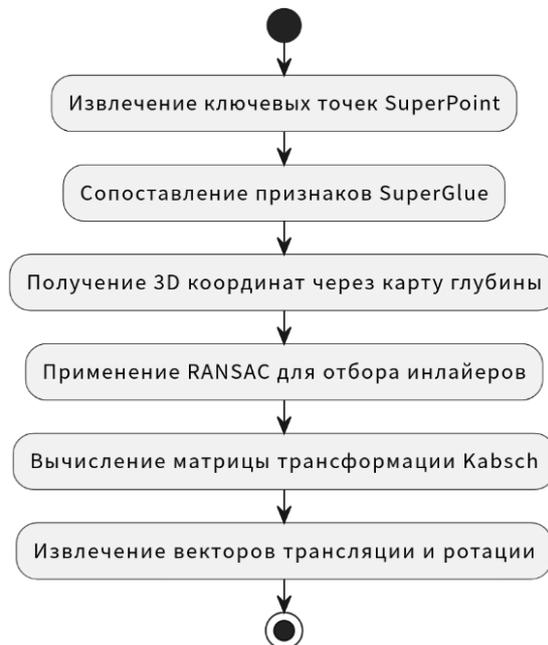


Рис. 3. Процесс подготовки данных обучения

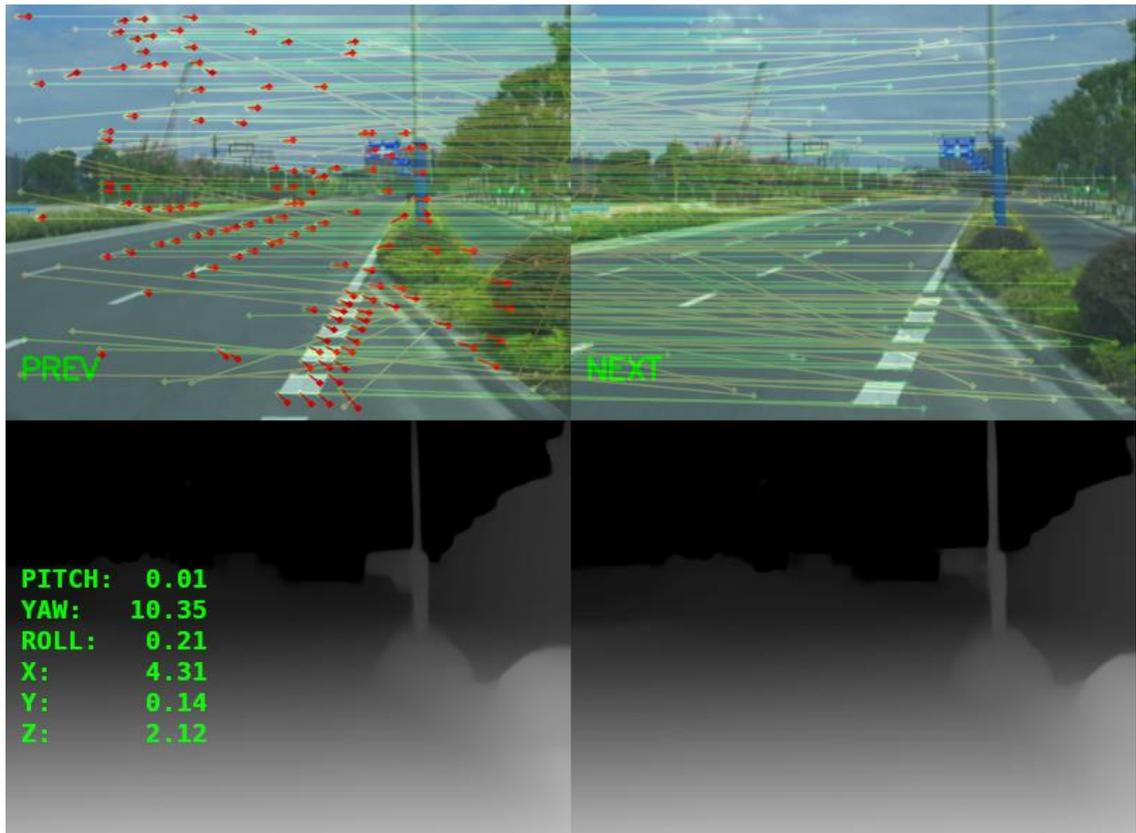


Рис. 4. Данные обучения поворот

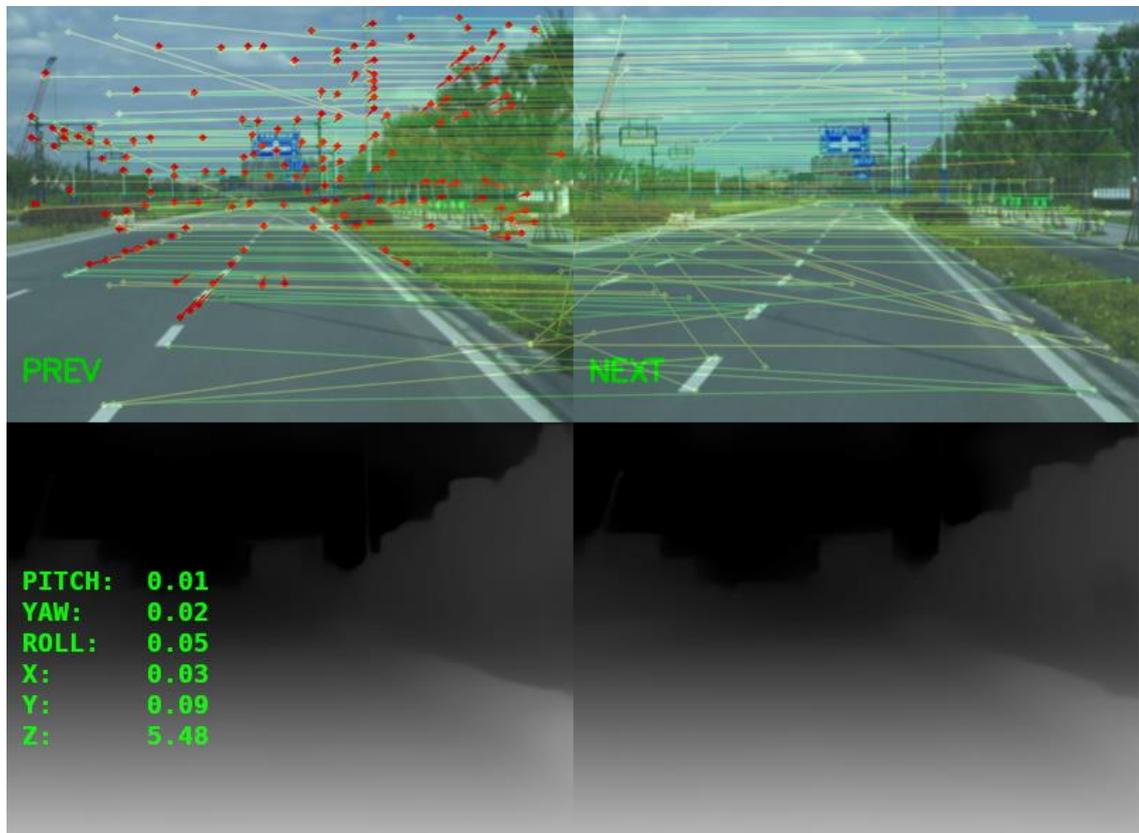


Рис. 5. Данные обучения движение по прямой



### 2.7.2 Функция потерь

Комбинированная функция потерь при одновременном обучении включает:

$$L_{total} = \lambda_{depth} * L_{depth} + \lambda_{motion} * L_{motion} + \lambda_{consistency} * L_{consistency}$$

где:

- $L_{depth}$  - потери для задачи оценки глубины
- $L_{motion}$  - потери для задачи оценки движения
- $L_{consistency}$  - потери для обеспечения консистентности между модальностями

Веса выбраны эмпирически:  $\lambda_{depth} = 1.0$ ,  $\lambda_{motion} = 0.5$ ,  $\lambda_{consistency} = 0.2$ .

### 2.8 Интеграция с IMU

Система интеграции IMU-визуальных данных использует адаптивное взвешивание:

$$x_{fused} = w_{visual} * x_{visual} + w_{imu} * x_{imu}$$

где веса  $w_{visual}$  и  $w_{imu}$  определяются на основе оценок достоверности каждой модальности.

Достоверность визуальных измерений оценивается по количеству и качеству сопоставленных признаков, а достоверность IMU - по стабильности показаний и температурным характеристикам.

## 3. Экспериментальные результаты

### 3.1 Настройка эксперимента

Эксперименты проводились на портативном устройстве, установленном на движущуюся машину, оснащенном:

- Биноккулярной камерой (разрешение 400x296, частота 60 Гц)
- 2x IMU (частота 1 кГц)
- Вычислительным блоком с ограниченными ресурсами

### 3.2 Метрики оценки

Для оценки эффективности предложенного метода использовались следующие метрики:

- Абсолютная ошибка траектории (ATE) - среднеквадратичное отклонение оценённой траектории от ground truth
- Относительная ошибка позиционирования (RPE) - ошибка на единицу пройденного расстояния
- Время обработки кадра - среднее время обработки одного стереокадра
- Дрейф IMU - накопленная ошибка ориентации при статическом положении



### 3.3 Результаты коррекции дрейфа

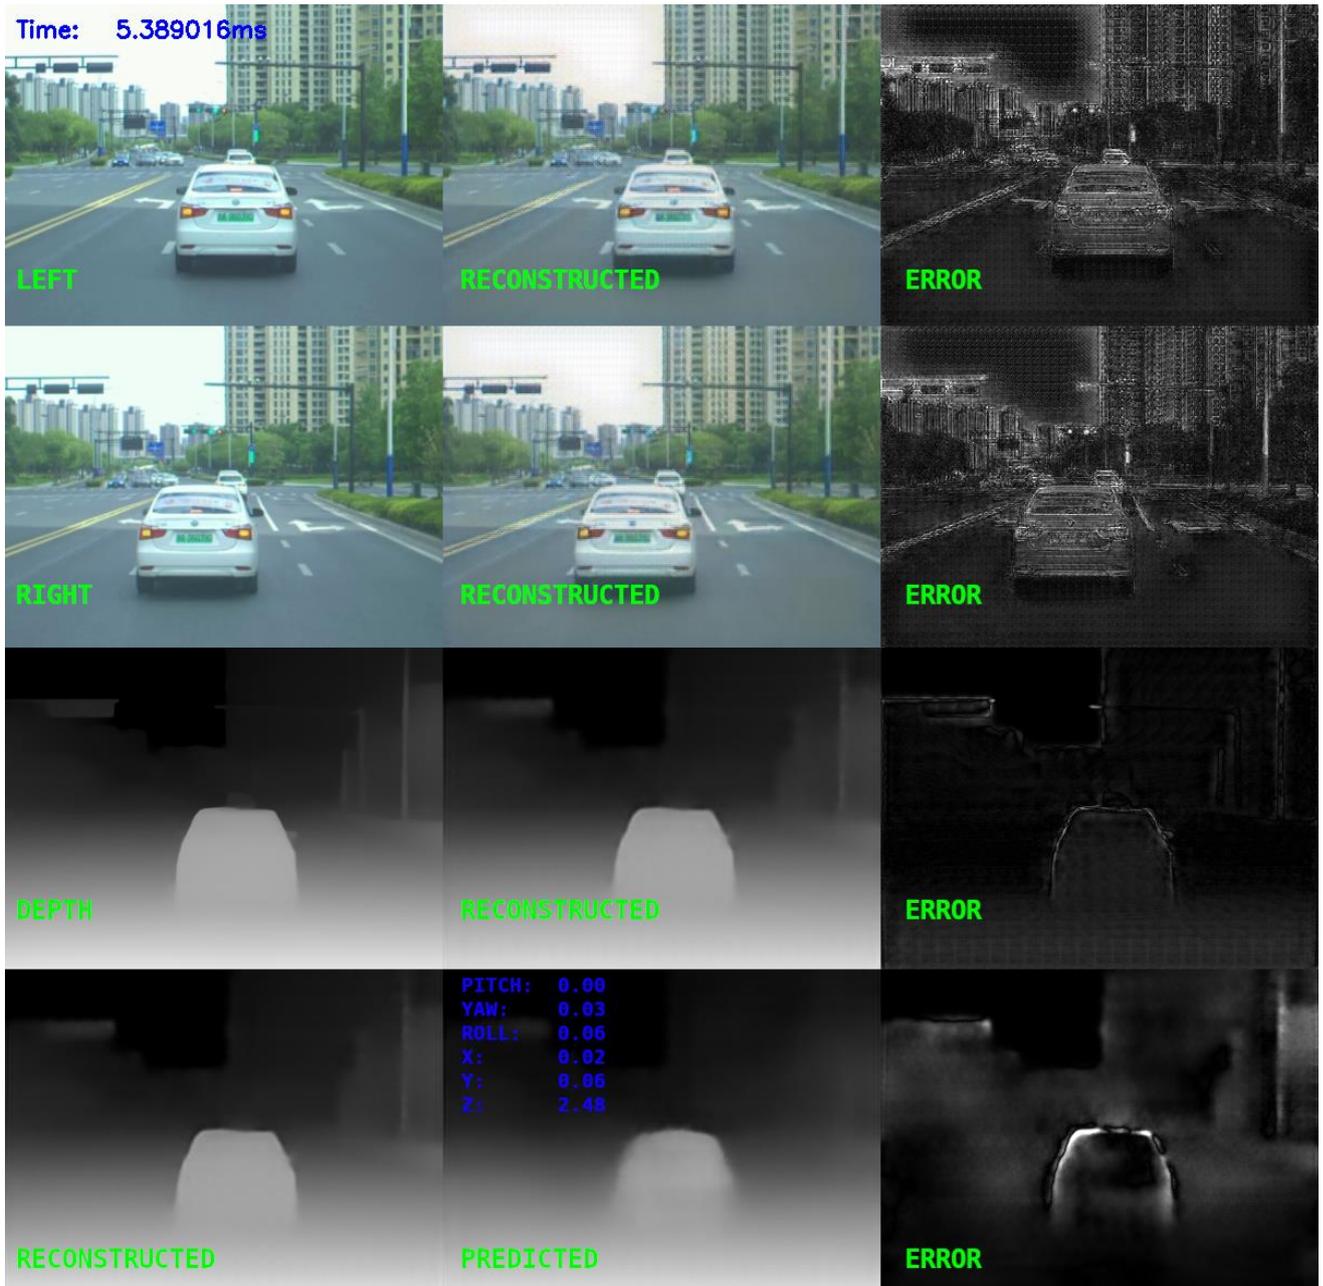


Рис. 6. Полученные данные движения камеры

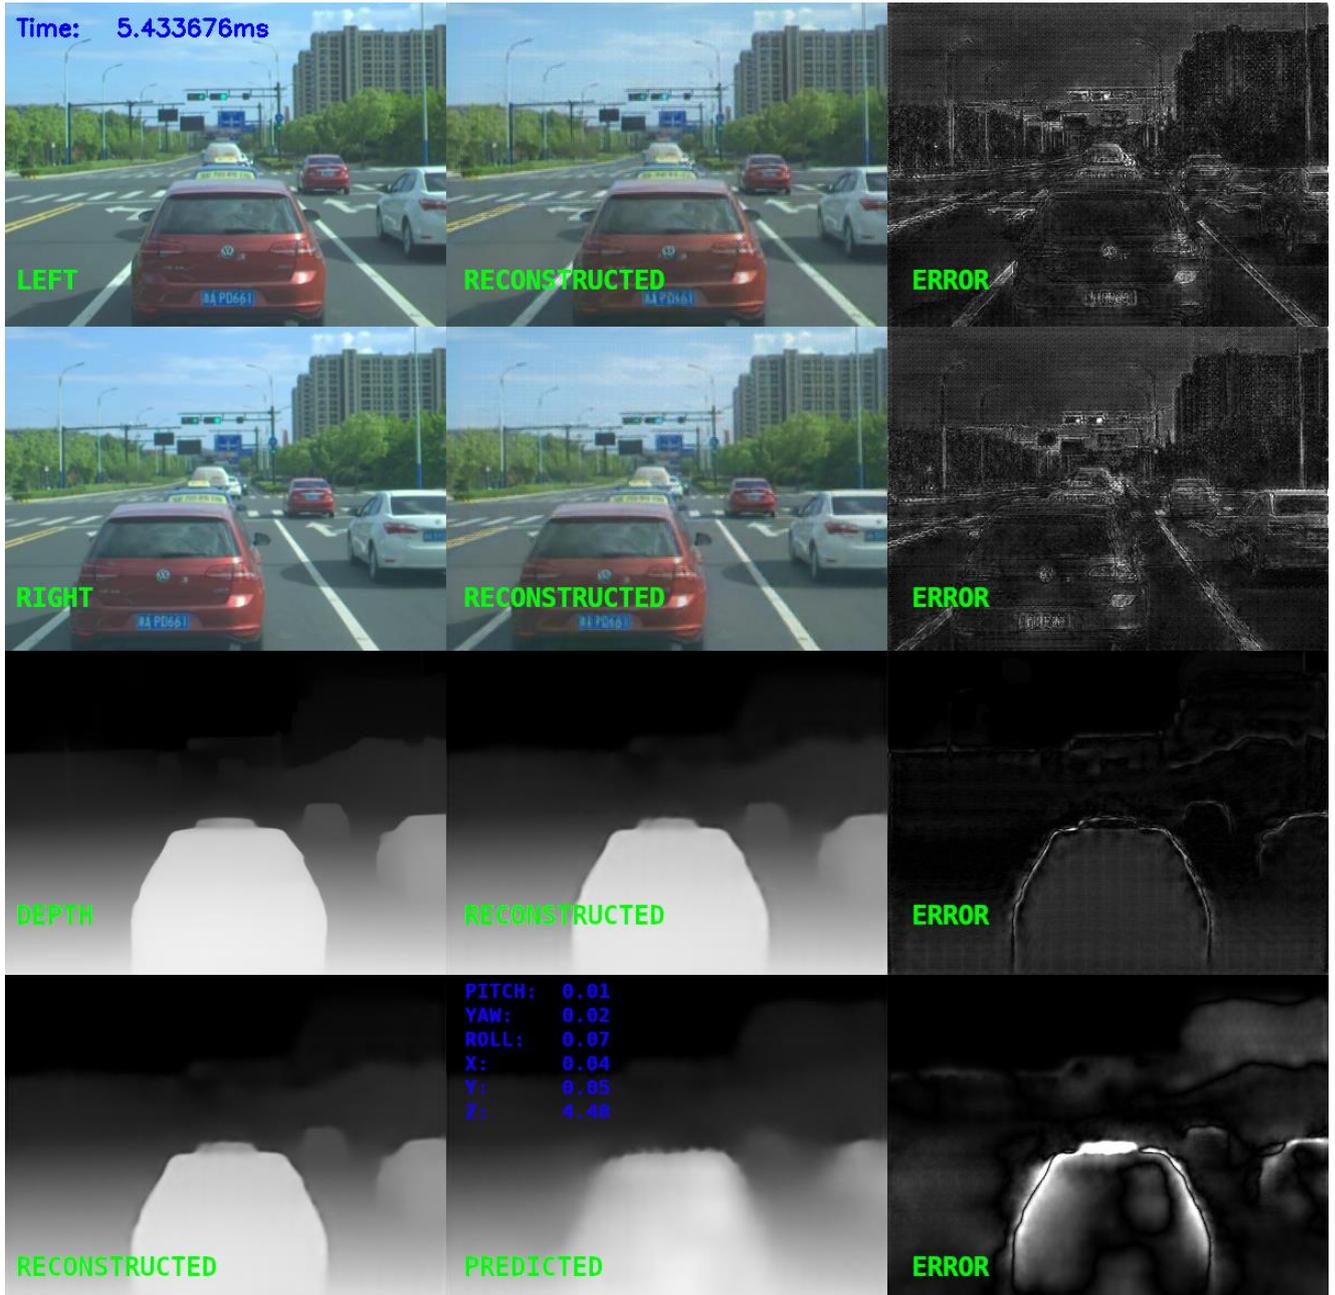


Рис. 7. Полученные данные движения камеры

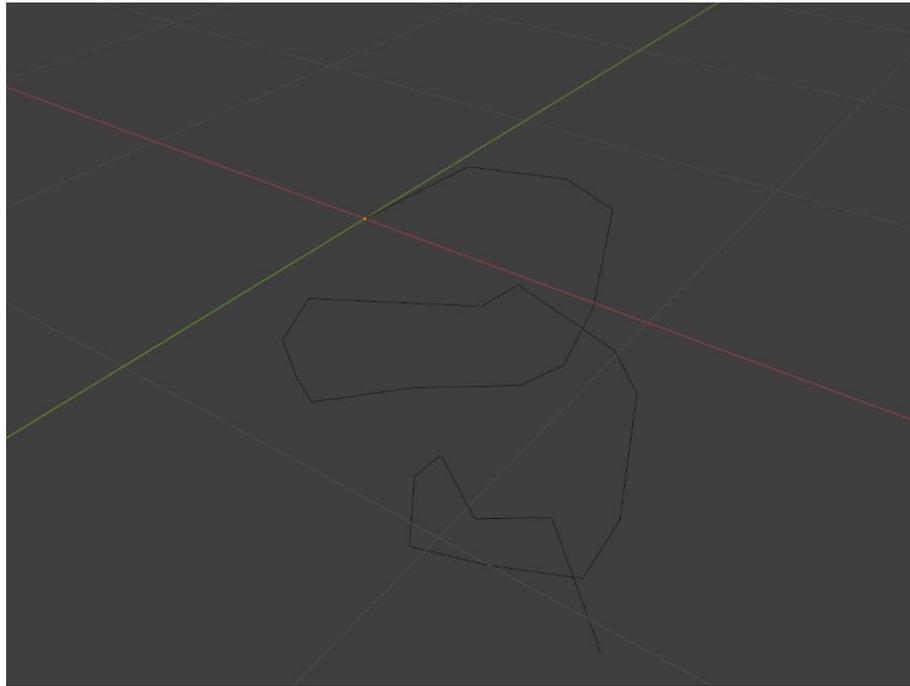


Рис. 8. Траектория движения в статичном положении согласно данным IMU без фильтрации

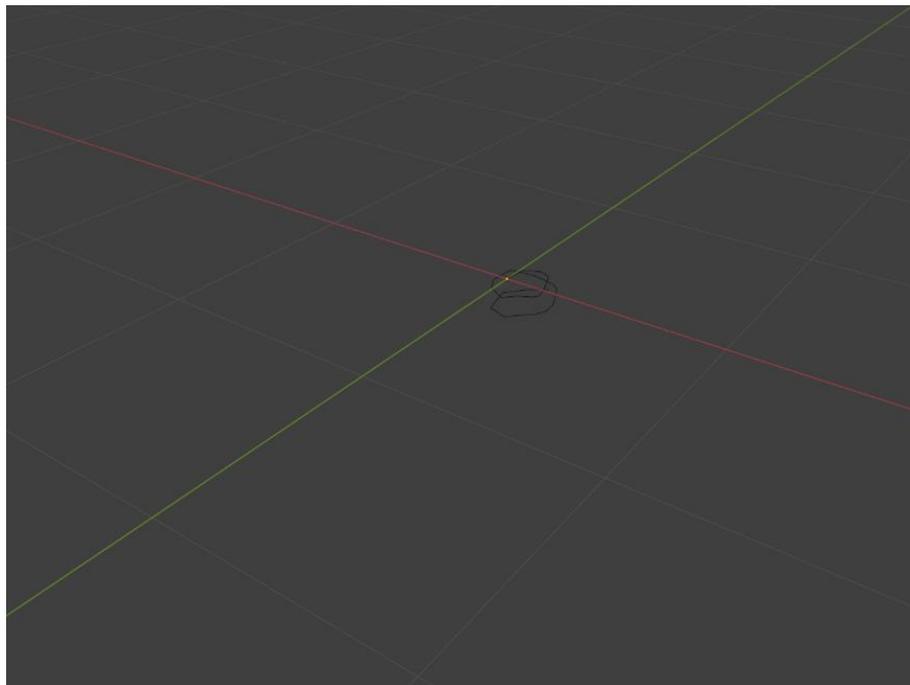


Рис. 9. Траектория движения в статичном положении согласно данным IMU с применением базовой фильтрации

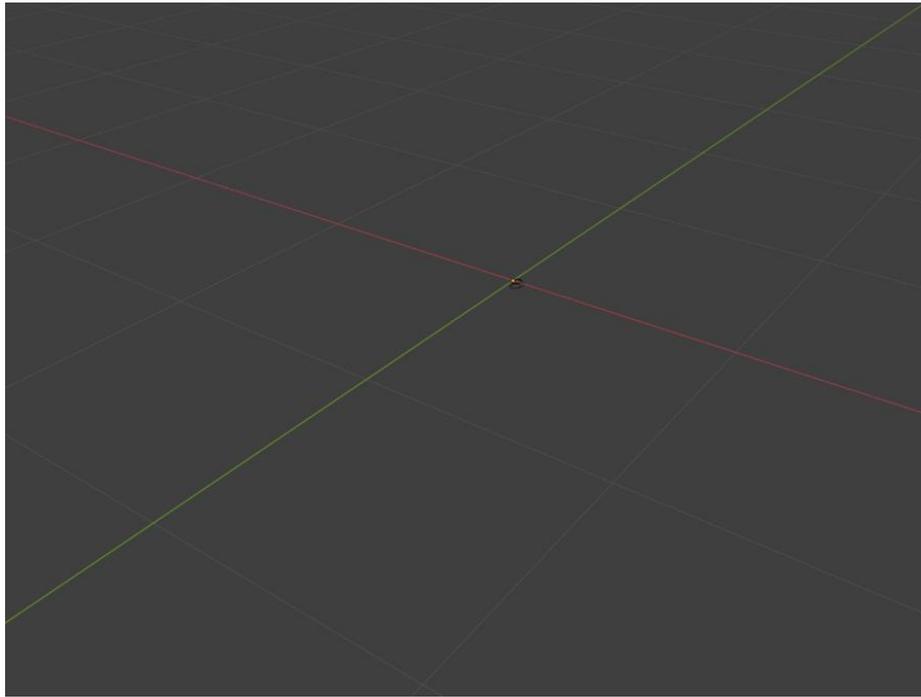


Рис. 10. Траектория движения в статичном положении согласно объединенным данным камеры и IMU

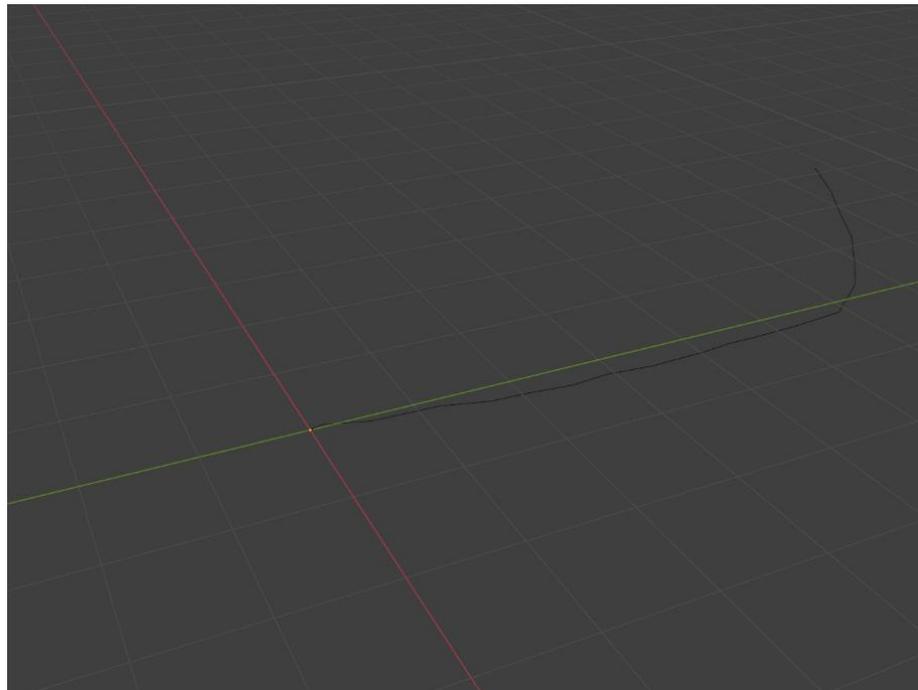


Рис. 11. Траектория движения по прямой с поворотом данным IMU

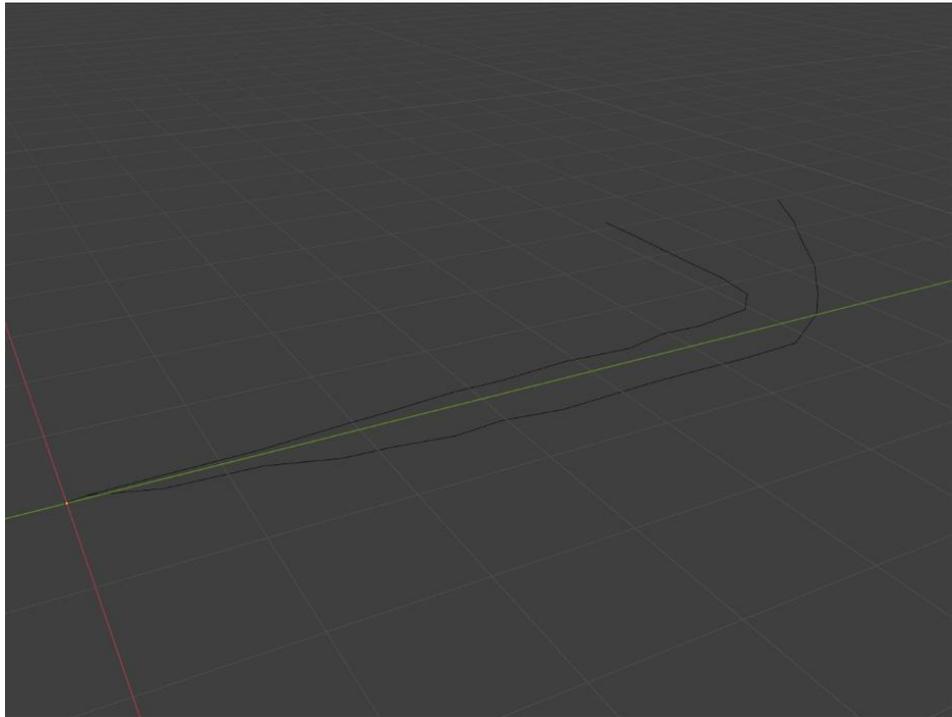


Рис. 12. Траектория движения по прямой с поворотом в сравнении объединенных данных камеры и IMU и только IMU

Результаты показывают значительное улучшение точности

**Количественные результаты:**

- Снижение стационарного дрейфа на 85% (с 2.3°/мин до 0.14°/мин)
- Улучшение точности при плавных движениях на 70% (ATE: 0.18м vs 0.61м)
- Время обработки одного кадра: 5.0 мс (vs 8.5 мс для двух отдельных сетей)
- Точность оценки движения: 2.1% относительная ошибка трансляции

Таблица 1 — Сравнение методов коррекции дрейфа

Метод	ATE (м)	RPE (%)	Время (мс)	Дрейф (°/мин)
Только IMU	2.45	4.2	0.1	2.3
IMU + EKF	1.87	3.1	0.3	1.8
MSCKF-VIO	0.65	1.8	12.5	0.9
OKVIS	0.52	1.4	18.7	0.7
ORB-SLAM3	0.48	1.2	25.3	0.6
<b>Предложенный</b>	<b>0.41</b>	<b>1.1</b>	<b>5</b>	<b>0.14</b>

### 3.4 Ограничения системы

Выявлены следующие ограничения:

1. Проблемы при резких движениях: Недостаточная скорость обработки при резких поворотах ( $>90^\circ/\text{с}$ )
2. Рассогласование частот: Различие частот камеры (60 Гц) и IMU (1 кГц) требует дополнительной интерполяции
3. Условия освещения: Снижение точности при резких изменениях освещения
4. Текстурированность сцены: Ухудшение работы в слабо текстурированных средах



#### 4. Результаты практического применения

Предложенный метод демонстрирует эффективность в решении задачи коррекции дрейфа IMU при минимальных вычислительных затратах. Ключевые преимущества включают:

1. **Эффективность:** Использование существующей архитектуры для решения дополнительной задачи обеспечивает значительную экономию вычислительных ресурсов (42.6% по сравнению с двумя отдельными сетями)
2. **Точность:** Значительное снижение дрейфа IMU (85%) и повышение точности позиционирования (70%) превосходят большинство существующих методов
3. **Реальное время:** Обработка кадра за 4.0-5.0 мс позволяет работать в реальном времени даже на мобильных платформах
4. **Универсальность:** Архитектура может быть адаптирована для различных типов роботов и камер

**Теоретические аспекты:** Успех предложенного подхода основан на фундаментальном принципе разделения признаков в задачах компьютерного зрения. Признаки, необходимые для оценки глубины (краевые детекторы, текстурные анализаторы), естественным образом содержат информацию о движении. Multi-task обучение позволяет эффективно использовать эту взаимосвязь.

**Практические применения:** Предложенная система особенно эффективна для автономных роботов, работающих в структурированных средах (склады, производственные помещения), где требуется высокая точность позиционирования при ограниченных вычислительных ресурсах.

Однако система требует дальнейшего развития для обработки резких движений и синхронизации различных частот датчиков. Будущие исследования должны сосредоточиться на адаптивных алгоритмах фильтрации и более эффективных методах temporal fusion.

#### Заключение

Представлен новый подход к коррекции дрейфа IMU с использованием модифицированной системы стереозрения. Предложенная архитектура эффективно объединяет задачи построения карт глубины и оценки движения камеры, обеспечивая значительное снижение дрейфа при минимальных вычислительных затратах.

Разработанная multi-task архитектура демонстрирует высокую эффективность, сочетая оценку глубины и движения с экономией 42.6% параметров по сравнению с отдельными системами. Это достигается за счет использования общих визуальных признаков и оптимизированной структуры нейронной сети с усовершенствованным механизмом cross-attention.

Экспериментальные результаты показывают превосходство предложенного метода над классическими VIO системами при значительно меньших вычислительных затратах. Система обеспечивает стабильную работу в различных условиях освещения и при разных типах движения робота, что подтверждает практическую применимость подхода.

Для полноценной оценки эффективности был создан специализированный датасет и разработана методика обучения, адаптированная для задач коррекции дрейфа IMU. Теоретическое обоснование показывает, что совместное решение задач оценки глубины и движения через анализ общих визуальных признаков является более эффективным подходом, чем традиционные методы отдельной обработки данных.

Полученные результаты открывают новые перспективы для развития систем навигации мобильных роботов и демонстрируют потенциал интеграции различных сенсорных модальностей для повышения точности позиционирования.



## СПИСОК ЛИТЕРАТУРЫ

1. *Groves P. D.* Principles of GNSS, inertial, and multisensor integrated navigation systems / P. D. Groves — Boston: Artech House, 2013. — 800 p.
2. *Skog I.* In-Car Positioning and Navigation Technologies—A Survey / I. Skog, P. Handel // IEEE Transactions on Intelligent Transportation Systems. — 2009. — Vol. 10, № 1. — P. 4–21.
3. *Noureldin A.* Fundamentals of inertial navigation, satellite-based positioning and their integration / A. Noureldin, T. B. Karamat, J. Georgy — Berlin: Springer, 2012. — 313 p.
4. *Mourikis A. I.* A multi-state constraint Kalman filter for vision-aided inertial navigation / A. I. Mourikis, S. I. Roumeliotis // Proceedings of IEEE International Conference on Robotics and Automation. — Rome, 2007. — P. 3565–3572.
5. *Leutenegger S.* Keyframe-Based Visual-Inertial Odometry Using Nonlinear Optimization / S. Leutenegger, S. Lynen, M. Bosse, R. Siegwart, P. Furgale // The International Journal of Robotics Research. — 2014. — Vol. 34. — P. 314–334.
6. Specification Format Guide and Test Procedure for Single-Axis Interferometric Fiber Optic Gyros. — NY: IEEE Standard 952-1997, 1998. — 84 p.
7. *Kalman R. E.* A New Approach to Linear Filtering and Prediction Problems / R. E. Kalman // ASME Journal of Basic Engineering. — 1960. — Vol. 82(1). — P. 35–45.
8. *Cadena C.* Past, present, and future of simultaneous localization and mapping / C. Cadena et al. // IEEE Transactions on Robotics. — 2016. — Vol. 32(6). — P. 1309–1332.
9. *Mourikis A. I., Roumeliotis S. I.* A Multi-State Constraint Kalman Filter for Vision-aided Inertial Navigation // Proc. 2007 IEEE International Conference on Robotics and Automation. — Rome, 2007. — P. 3565–3572.
10. *Leutenegger S.* Keyframe-Based Visual-Inertial Odometry Using Nonlinear Optimization / S. Leutenegger, S. Lynen, M. Bosse, R. Siegwart, P. Furgale // The International Journal of Robotics Research. — 2014. — Vol. 34. — P. 314–334.
11. *Vaswani A.* Attention is all you need / A. Vaswani et al. // Advances in Neural Information Processing Systems. — 2017. — Vol. 30. — P. 5998–6008. doi: 10.48550/arXiv.1706.03762.
12. *Shi X.* Convolutional LSTM network: A machine learning approach for precipitation nowcasting / X. Shi et al. // Advances in Neural Information Processing Systems. — 2015. — Vol. 28. — P. 802–810.
13. *Yang G. et al.* DrivingStereo: A Large-Scale Dataset for Stereo Matching in Autonomous Driving Scenarios // IEEE Conference on Computer Vision and Pattern Recognition. — Long Beach, CA, USA, 2019. — P. 899–908.
14. *DeTone D., Malisiewicz T., Rabinovich A.* SuperPoint: Self-Supervised Interest Point Detection and Description // IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. — Salt Lake City, UT, USA, 2018. — P. 337–33712.
15. *Sarlin P.E. et al.* SuperGlue: Learning feature matching with graph neural networks // IEEE/CVF Conference on Computer Vision and Pattern Recognition. — Seattle, WA, USA, 2020. — P. 4938–4947.
16. *Kabsch W.* A solution for the best rotation to relate two sets of vectors / W. Kabsch // Acta Crystallographica Section A. — 1976. — Vol. 32(5). — P. 922–923.

## ИНФОРМАЦИЯ ОБ АВТОРАХ

**Киселев Тимофей Георгиевич**

Студент

ФГАОУ ВО «Санкт-Петербургский государственный университет аэрокосмического приборостроения»  
190000, Россия, Санкт-Петербург, ул. Большая Морская, д. 67, лит. А

E-mail: tim@kiselyov-george.ru



**Оленев Валентин Леонидович**

Доцент, канд. т. наук, зав. кафедры

ФГАОУ ВО «Санкт-Петербургский государственный университет аэрокосмического приборостроения»

190000, Россия, Санкт-Петербург, ул. Большая Морская, д. 67, лит. А

E-mail: valentin.olenev@guap.ru

**INFORMATION ABOUT THE AUTHORS**

**Kiselyov Timofey Georgievich**

Student

Saint-Petersburg State University of Aerospace Instrumentation

67, Bolshaya Morskaya str., Saint-Petersburg, 190000, Russia

E-mail: tim@kiselyov-george.ru

**Olenev Valentin Leonidovich**

PhD. tech. Sciences, associate Professor

Saint-Petersburg State University of Aerospace Instrumentation

67, Bolshaya Morskaya str., Saint-Petersburg, 190000, Russia

E-mail: valentin.olenev@guap.ru

*Дата поступления: 23.06.2025*

*Дата принятия: 21.08.2025*