

УДК 631.354

UDC 631&amp;354

4.3.1 Технологии машины и оборудование для агропромышленного комплекса (технические науки)

4.3.1 Technologies machines and equipment for the agro-industrial complex (technical sciences)

### **НАВИГАЦИЯ АГРОПРОМЫШЛЕННЫХ РОБОТОВ С ИСПОЛЬЗОВАНИЕМ МОДИФИЦИРОВАННОЙ ТЕХНОЛОГИИ SLAM НА ОСНОВЕ РЕКОНСТРУКЦИИ КАРТ ГЛУБИНЫ**

### **NAVIGATION OF AGRICULTURAL ROBOTS USING MODIFIED SLAM TECHNOLOGY BASED ON RECONSTRUCTION OF DEPTH MAPS**

Гапон Николай Валерьевич  
РИНЦ SPIN-код: 8918-3047  
[nikolay-rt@mail.ru](mailto:nikolay-rt@mail.ru)

Gapon Nikolay Valerievich  
RSCI SPIN-code: 8918-3047  
[nikolay-rt@mail.ru](mailto:nikolay-rt@mail.ru)

*Донской государственный технический университет, Ростов-на-Дону*

*Don State Technical University, Rostov-on-Don*

Важными целями применения различных технологий, предназначенных для повышения урожайности сельскохозяйственных культур, являются снижение затрат и снижение воздействия на окружающую среду. Появление сельскохозяйственных роботов может снизить производственные затраты, уменьшить тяжелую работу ручного труда. В современных РТК применяются алгоритмы построения оптимального пути его перемещения. При этом используются методы одновременной локализации и построения карт окружающей среды (SLAM), которые используют в своей работе карты глубины. Методы создания карт глубины сталкиваются с проблемой отсутствующих данных из-за плохого освещения, отражающих или мелкозернистых поверхностей, которые приводят к потере информации о глубине. Это ведет к перекрытию объектов, затрудняя их различимость и вызывая расширение видимых границ. Решение заключается в применении методов реконструкции карт глубины, которые заполняют недостающие участки и повышают точность карт. В данной статье представлен подход, основанный на модифицированном алгоритме поиска похожих блоков с помощью нейронной сети. Предложенный алгоритм также использует концепцию разреженного представления кватернионов, новый градиент для вычисления функции приоритета путем интеграции структуры кватернионов с картой значимости. Результаты предлагаемого метода Visual SLAM, использующего восстановленные карты глубины, сравниваются с VINS-Fusion, PL-SLAM и ORB-SLAM2 на наборе KITTI. Восстановление карт глубины, позволяет улучшить текущее состояние систем SLAM на основе машинного зрения, чтобы сделать их более надежными и точными, особенно для решения задач, связанных с сельскохозяйственными территориями

Important goals of using various technologies designed to increase crop yields are to reduce costs and reduce the impact on the environment. The advent of agricultural robots can reduce production costs and reduce manual labor. Modern RTKs use algorithms to build the optimal path of its movement. In this case, simultaneous localization and environment mapping (SLAM) methods are used, which use depth maps in their work. Depth map creation methods face the problem of missing data due to poor lighting, reflective or fine-grained surfaces, which lead to the loss of depth information. This leads to the overlap of objects, making them difficult to distinguish and causing the expansion of visible boundaries. The solution lies in the use of depth map reconstruction methods that fill in the missing areas and improve the accuracy of the maps. This paper presents an approach based on a modified algorithm for finding similar blocks using a neural network. The proposed algorithm also uses the concept of sparse quaternion representation, a new gradient for calculating the priority function by integrating the quaternion structure with the importance map. The results of the proposed Visual SLAM method using reconstructed depth maps are compared with VINS-Fusion, PL-SLAM and ORB-SLAM2 on the KITTI dataset. Depth map reconstruction can improve the current state of the art of computer vision-based SLAM systems to make them more robust and accurate, especially for solving problems related to agricultural areas

Ключевые слова: СЕЛЬСКОХОЗЯЙСТВЕННЫЙ

Keywords: AGRICULTURAL ROBOT, SLAM,

РОБОТ, SLAM, КАРТА ГЛУБИНЫ, НЕЙРОННАЯ  
СЕТЬ, КВАТЕРНИОН, КАРТА ЗНАЧИМОСТИ,  
АНИЗОТРОПНЫЙ ГРАДИЕНТ

DEPTH MAP, NEURAL NETWORK,  
QUATERNION, SALIENCY MAP, ANISOTROPIC  
GRADIENT

<http://dx.doi.org/10.21515/1990-4665-204-059>

## **Введение.**

В настоящее время большинство сельскохозяйственных процессов выполняются машинами, управляемыми человеком, а также некоторыми автономными роботами, которые успешно применяются для выполнения повторяющихся задач, такие как подготовка земли, орошение и опрыскивание водой, обрезка, сбор урожая, мониторинг и инспекция, картографирование. Чтобы решить представленные задачи, не врезаясь в препятствия, робот должен иметь возможность видеть окружающую среду. Еще одним требованием для независимого передвижения является способность роботов определять, где они находятся в текущей среде. Эти навыки позволяют роботу обходить видимые препятствия и демонстрировать автономность перемещения. Чтобы робот переместился к месту назначения и выполнил заданную операцию, он должен «запомнить» окружающую среду и спланировать траекторию пути от места своего положения до целевого пункта назначения. В сфере робототехники при определении расстояния от робота до цели применяются эффективные методы, обеспечивающие точность измерения. Одним из таких методов является построение карты глубины. Карта глубины представляет собой изображение, где каждый пиксель содержит данные о расстоянии от камеры до наблюдаемого объекта, заменяя собой цветовые значения. Одним из недостатков большинства методов построения карты глубины является то, что величина диспаратности достоверно определяется только в местах, где яркость быстро меняется, что приводит к проблеме потерянных областей, случайного шума и перекрывающихся объектов.

<http://ej.kubagro.ru/2024/10/pdf/59.pdf>



Рисунок 1 - Цветное изображение и карта глубины с потерянными областями

Создание карты глубины имеет существенный недостаток: невозможно определить глубину для материалов с мелкозернистой структурой. Это приводит к ошибкам в построении траектории движения сельскохозяйственных РТК, что, в свою очередь, снижает эффективность автоматизации процесса. Решить эти проблемы возможно с помощью использования методов реконструкции карт глубины, восстанавливая потерянные пиксели. Данный факт делает актуальной задачу восстановления карт глубины. В этой работе предложен подход навигации робота на основе модифицированной технологии SLAM посредством реконструкции карт глубины.

**Материалы и методы исследования.** На рисунке 2 показана схема навигации сельскохозяйственных РТК. Она опирается на технологию одновременной локализации и картирования (SLAM) – алгоритм для локализации робота в пространстве и построения карты окружающей среды.

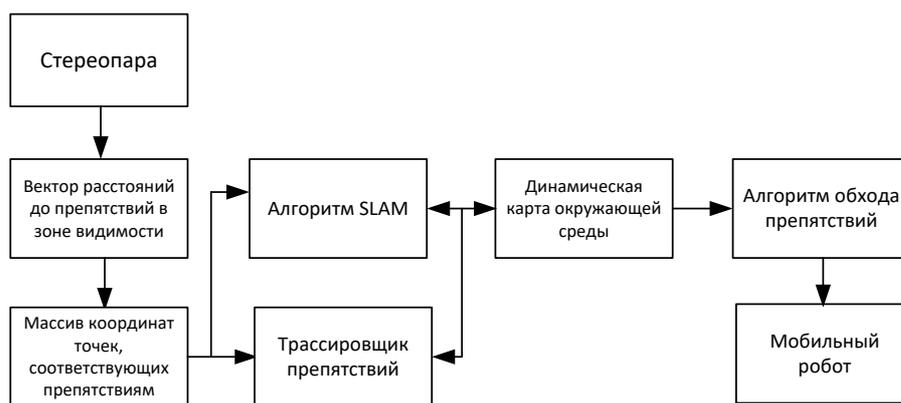


Рисунок 2 - Схема навигации сельскохозяйственных РТК

Визуальные датчики в этой схеме служат для сбора данных, необходимых для построения карты глубины. Карта глубины представляет собой двумерный сигнал  $S_{i,j}, i=1..N, j=1..M$ , где значение пикселей определяет расстояние до объекта. Схема предложенного метода восстановления карты глубины показана на рисунке 3.

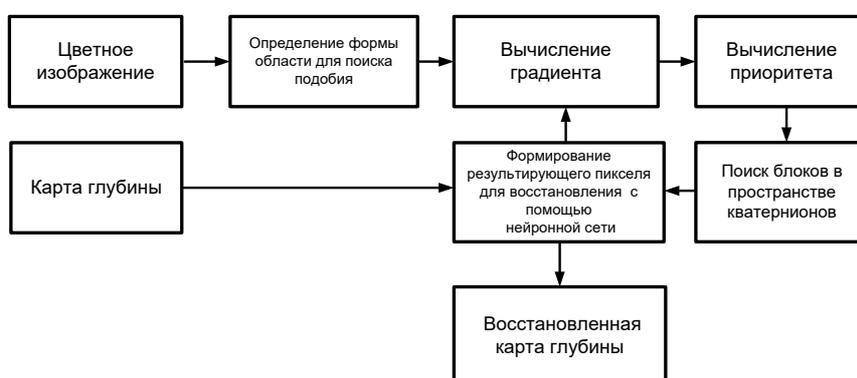


Рисунок 3 - Схема метода восстановления карт глубины.

Алгоритм объединения данных RGB-изображения и карты глубины обеспечивает реконструкцию поврежденных участков карты глубины и коррекцию искаженных границ объектов.

На начальном этапе алгоритм определяет для каждого граничного пикселя область поиска похожих блоков. Для этого используется метод LPI-ICI [1]. Область поиска создается путем объединения двух смежных

однородных подобластей, которые расположены в направлении максимального градиента (как показано на рисунке 4).

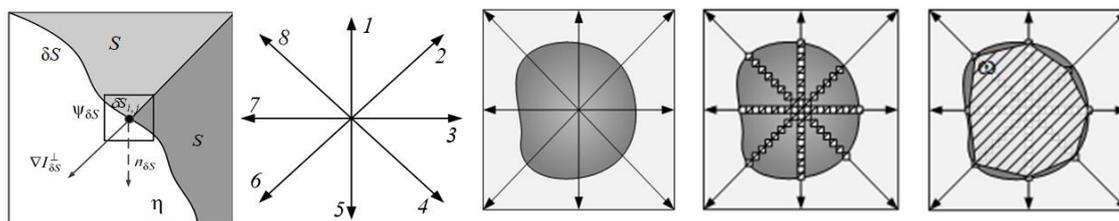


Рисунок 4 - Формирования адаптивной области для поиска похожих блоков

На втором шаге вычисляется приоритет  $P(\delta S)$  (1) для всех значений пикселей границы [1]:

$$P(\delta S) = C(\delta S) \cdot D(\delta S) \cdot T(\delta S), \quad (1)$$

$$C(\delta S) = \frac{\sum_{l \in \Psi_{\delta S}} C(l)}{|\Psi_{\delta S}|}, \quad D(\delta S) = \frac{|\nabla I_{\delta S}^{\perp} \cdot n_{\delta S}|}{\alpha}, \quad T(\delta S) = g \cdot \|q'(t)\|^2 \quad (2)$$

где:  $\delta S_{i,j}$  - текущий пиксель на границе доступных пикселей;  $C(\delta S)$  - коэффициент доверия;  $D(\delta S)$  - коэффициент градиента;  $T(\delta S)$  – карта внимания;  $\Psi_{\delta S}$  - адаптивный блок с центром в пикселе  $\delta S_{i,j}$ ;  $|\Psi_{\delta S}|$  - количество пикселей адаптивного блока,  $\nabla I_{\delta S}^{\perp}$  - вектор, ортогональный градиенту в точке  $\delta S_{i,j}$ ;  $n_{\delta S}$  - вектор, ортогональный границе  $\delta S$  в точке  $\delta S_{i,j}$ ;  $\alpha$  – нормализованный коэффициент, равный 255 для восьмибитных изображений;  $q'(t) = a(t) + b(t)\mu_1 + c(t)\mu_2 + d(t)\mu_3$ ;  $g$  – двумерный фильтр Гаусса;  $\mu_i, i = 1, 2, 3$  удовлетворяет  $\mu_i^2 = -1, \mu_1 \perp \mu_2, \mu_2 \perp \mu_3, \mu_1 \perp \mu_3, \mu_1 = \mu_1 \mu_2$ .

При расчете приоритета акцент делается на пикселях, расположенных на границах перепада яркостей. Это позволяет эффективнее восстанавливать эти пиксели, поскольку они несут в себе больше информации. Коэффициент доверия, в свою очередь, снижает значимость

уже восстановленных пикселей, способствуя расширению области поиска недостающих пикселей, обозначенной как  $S$ . Анализ линейной структуры и резких изменений яркости, ключевых признаков для выявления объектов, более эффективен на цветных изображениях, чем на картах глубины. Чтобы сохранить эти характеристики на картах глубины и избежать появления блочной структуры на границах объектов, мы применяем карты внимания (как показано на рисунок 5: а) цветное изображение; б) карта внимания карты глубины).

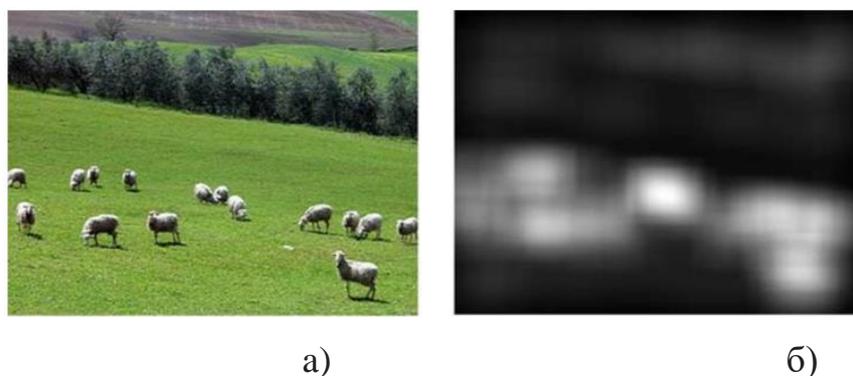


Рисунок 5 - Пример карты внимания

Для точного восстановления карт глубины алгоритм выбирает пиксель с наивысшим приоритетом на границе изображения и определяет связанную с ним область [1]. Этот подход обеспечивает корректную форму восстанавливаемой области и предотвращает искажения, которые могут возникнуть из-за использования произвольных границ. Чтобы сохранить корреляцию между цветовыми каналами RGB и обеспечить более естественные результаты, изображение RGB преобразуется в пространство кватернионов (рисунок 6) [1]. Такой подход позволяет избежать потери межканальной корреляции, которая может ухудшить восстановление цвета.

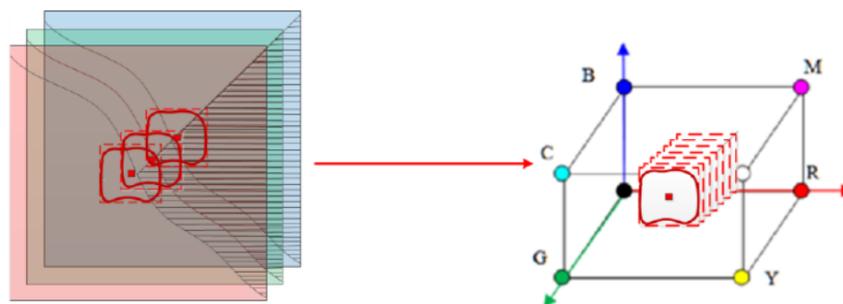


Рисунок 6 - Пример обработки цвета для поиска похожего блока в пространстве кватернионов

Компоненты RGB-изображения можно представить в виде кватерниона  $Q$  [1]. Для оптимизации поиска схожих блоков в пространстве RGB используется кватернионная методология, объединяющая поиск по всем цветовым компонентам. Дискретное преобразование Фурье рассчитывается в адаптивной области кватернионного пространства для повышения точности [1]. Далее находятся блоки  $\psi_{q(h)}$ ,  $h = \overline{1, R}$  в области  $S_{i,j}$ , для которых евклидова метрика минимальна [1].

Для заполнения недостающих значений пикселей карты глубины в окрестности пикселя с наивысшим приоритетом применяется нейронная сеть. Эта сеть вычисляет наиболее похожий блок, путем усреднения значения соответствующих пикселей, взятых из найденных блоков. После этого происходит циклический процесс, включающий пересчет приоритета, поиск похожих участков и замену пикселей [1].

**Результаты исследования и их обсуждение.** Результаты предлагаемого метода V-SLAM, использующего восстановленные карты глубины, сравниваются с VINS-Fusion [2], PL-SLAM [3] и ORB-SLAM2 [4] на наборе KITTI [5]. Набор данных KITTI включает в себя цветные изображения и стереопоследовательности высокого разрешения, снятые в окрестностях сельской местности. Сравнение оцененных траекторий

предложенным методом и другими методами показано на рисунке 7 для последовательностей KITTI 01, 08 и 09.

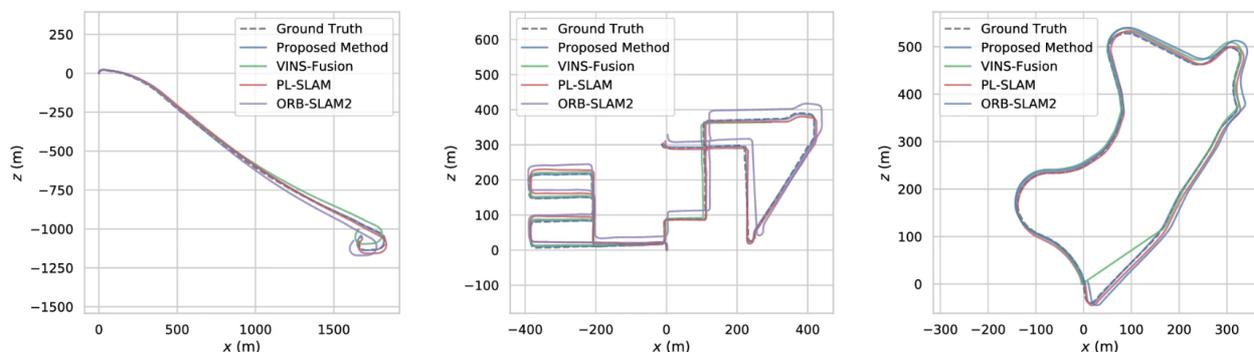


Рисунок 7 - Сравнение расчетных траекторий предлагаемого метода, VINS-Fusion, PL-SLAM и ORB-SLAM2 с фактическими данными в последовательностях KITTI а) 01, б) 08 и в) 09

Метод ORB-SLAM2, очень подвержен ошибкам, когда замыкание цикла не обнаружено. Ошибки накапливаются до тех пор, пока не будут обнаружены замыкания цикла, что в конечном итоге приводит к большой ошибке оценки. Также заметно, что базовые методы подвержены ошибкам в точках резкого поворота. Однако предложенный метод обеспечивает превосходную оценку траектории с наименьшим среднеквадратическим отклонением в таких сложных условиях. В таблице 1 показана относительная ошибка положения (RPE) предлагаемого метода и базовых методов V-SLAM в наборе данных. Жирные значения выделяют метод с наименьшей ошибкой.

Таблица 1. Точность предлагаемого метода сравнивается с VINS-fusion, PL-SLAM и ORB-SLAM2 в наборе данных KITTI.

Seq.	Предложенный метод V-SLAM	VINS-Fusion	PL-SLAM	ORB-SLAM2
	$t_{rel}$	$t_{rel}$	$t_{rel}$	$t_{rel}$
00	<b>1.104</b>	1.556	1.456	2.346
01	<b>1.421</b>	1.706	2.633	1.786
02	1.142	1.124	<b>1.121</b>	1.129
03	1.832	1.950	2.123	<b>1.627</b>
04	<b>1.242</b>	1.793	1.842	1.798
05	<b>0.011</b>	0.025	0.020	0.027
06	1.227	<b>0.989</b>	1.082	0.595
07	<b>0.634</b>	1.086	1.193	1.678
08	<b>1.218</b>	1.895	1.798	2.277
09	<b>0.875</b>	1.122	1.120	1.224
10	<b>0.880</b>	1.426	1.054	1.703

Из представленного RMSE можно заметить, что методы ORB-SLAM2 и VINS-Fusion, дают худший результат.

**Выводы.** В статье описывается новый метод поиска похожих блоков, основанный на модифицированном алгоритме с использованием нейронной сети. Этот метод использует концепцию разреженного представления кватернионов, которая позволяет вычислить функцию приоритета с помощью нового градиента. В основе этого подхода лежит интеграция структуры кватернионов с картой значимости. По сравнению с существующими технологиями предложенный метод обеспечивает надежное восстановление карты глубины по мультимодальным изображениям, что делает его перспективным инструментом для применения в навигации роботов. Алгоритмы SLAM широко используются в различных аспектах нашей жизни, включая автономную робототехнику. Примечательно, что использование алгоритмов SLAM в сельскохозяйственной среде становится все более популярным. Высоко

визуальные повторяющиеся сцены сельской местности, изменения условий освещения, крупномасштабные траектории и постоянные динамические изменения, вызванные ветром, создают серьезные проблемы для современных систем SLAM на основе машинного зрения. Восстановление карт глубины, позволяет улучшить текущее состояние систем SLAM на основе машинного зрения, чтобы сделать их более надежными и точными, особенно для решения задач, связанных с сельскохозяйственными территориями. Исследования показывают, что относительная ошибка положения (RPE) методов ORB-SLAM2 и VINS-Fusion, дают худший результат в сравнении с предлагаемым методом.

**Благодарности.** Исследование выполнено при поддержке гранта в рамках конкурса «Наука-2030».

### **Литература**

1. Зеленский, А. А. и др. Мехатроника, автоматизация, управление, 23(2), 104-112 (2022). <https://doi.org/10.17587/mau.23.104-112>
2. Qin, T. et al. Computer Vision and Pattern Recognition. 1901.03638. (2019). <https://doi.org/10.48550/arXiv.1901.03638>
3. Gomez-Ojeda, R. et al. IEEE Transactions on Robotics, 35(3), 734-746. (2019). <https://doi.org/10.1109/tro.2019.2899783>
4. Mur-Artal, R., Tardós, J. D. IEEE transactions on robotics, 33(5), 1255-1262 (2017). <https://doi.org/10.1109/tro.2017.2705103>
5. Geiger, A. et al. The International Journal of Robotics Research, 32(11), 1231-1237 (2013). <https://doi.org/10.1177/0278364913491297>

### **References**

1. Zelenskij, A. A. i dr. Mehatronika, avtomatizacija, upravljenje, 23(2), 104-112 (2022). <https://doi.org/10.17587/mau.23.104-112>
2. Qin, T. et al. Computer Vision and Pattern Recognition. 1901.03638. (2019). <https://doi.org/10.48550/arXiv.1901.03638>
3. Gomez-Ojeda, R. et al. IEEE Transactions on Robotics, 35(3), 734-746. (2019). <https://doi.org/10.1109/tro.2019.2899783>
4. Mur-Artal, R., Tardós, J. D. IEEE transactions on robotics, 33(5), 1255-1262 (2017). <https://doi.org/10.1109/tro.2017.2705103>

5. Geiger, A. et al. The International Journal of Robotics Research, 32(11), 1231-1237 (2013). <https://doi.org/10.1177/0278364913491297>