

EDN: SKWTMC

DOI: 10.22314/2073-7599-2025-19-2-19-25



Научная статья

УДК: 631.354



Модифицированный SLAM для навигации сельскохозяйственных роботов

Николай Валерьевич Гапон¹,научный сотрудник,
e-mail: nikolay-rt@mail.ru;**Вячеслав Владимирович Воронин²,**кандидат технических наук, доцент,
e-mail: voronin_sl@mail.ru;**Дмитрий Владимирович Рудой¹,**доктор технических наук,
ведущий научный сотрудник,
e-mail: rudoy.d@gs.donstu.ru;**Марина Михайловна Жданова¹,**научный сотрудник,
e-mail: mpismenskova@mail.ru¹Донской государственный технический университет, Ростов-на-Дону, Российская Федерация;²Научно-производственный комплекс «Технологический центр», г. Зеленоград, Российская Федерация;*Исследование выполнено при поддержке гранта в рамках конкурса «Наука-2030».*

Реферат. Предложен новый метод реконструкции для восстановления потерянных областей на картах глубины для повышения точности автономной навигации сельскохозяйственных РТК. (Цель исследования) Разработка метода, который устраняет потери данных на картах глубины, улучшая тем самым работу системы одновременной локализации и картографирования (SLAM). (Материалы и методы) Оригинальный метод реконструкции карт глубины включает: вычисление анизотропного градиента; поиск аналогичных блоков на основании нового критерия; объединение найденных блоков с помощью нейросетевой архитектуры, состоящей из кодировщика, слоя слияния и декодера. Метод протестирован на наборе данных *Rosario*, в том числе со сложными сценариями сельского хозяйства. (Результаты и обсуждение) Реконструкция карт глубины показала значительное улучшение качества: средняя ошибка (RMSE) пикового отношения сигнала к шуму (PSNR) и индекса структурного сходства (SSIM) уменьшилась на 20–30% по сравнению с существующими методами. Показано, что предлагаемый метод сохраняет структуру и текстуру восстановленных областей, обеспечивая точную реконструкцию крупных зон с отсутствующими пикселями. Чтобы сравнить производительность SLAM, была выбрана *S-MSCKF*. Количественные результаты абсолютной ошибки траектории (ATE) и среднее значение RMSE оценены с помощью SLAM до и после восстановления карт глубины. Абсолютная ошибка траектории (ATE) снизилась с 0,62 до 0,25 метра, а RMSE – с 0,85 до 0,39 метра. (Выводы) Предлагаемый метод значительно повышает точность работы систем SLAM, особенно в условиях сложных сельских ландшафтов, изменчивого освещения и длительных перемещений. Отмечен потенциал для широкого внедрения метода в системах автономного управления сельскохозяйственной техникой при увеличении надежности и безопасности эксплуатации роботов.

Ключевые слова: сельскохозяйственный робот, SLAM, карта глубины, нейронная сеть, анизотропный градиент, реконструкция карт глубины.

■ **Для цитирования:** Гапон Н.В., Воронин В.В., Рудой Д.В., Жданова М.М. Модифицированный SLAM для навигации сельскохозяйственных роботов // *Сельскохозяйственные машины и технологии*. 2025. Т. 19. №2. С. 19–25. DOI: 10.22314/2073-7599-2025-19-2-19-25. EDN: SKWTMC.

Scientific article

Modified SLAM for Agricultural Robot Navigation

Nikolay V. Gapon¹,researcher,
e-mail: nikolay-rt@mail.ru;**Viacheslav V. Voronin²,**Ph.D.(Eng.), associate professor,
e-mail: voronin_sl@mail.ru;**Dmitriy V. Rudoy¹,**Dr.Sc.(Eng.), leading researcher,
e-mail: rudoy.d@gs.donstu.ru;**Marina M. Zhdanova¹,**researcher,
e-mail: mpismenskova@mail.ru¹Don State Technical University, Rostov-on-Don, Russian Federation;²Scientific-Manufacturing Complex «Technological Centre», Zelenograd, Russian Federation

This research was supported by a grant from the «Science-2030» program.

Abstract. The study proposes a novel method for reconstructing missing regions in depth maps, aimed at improving the accuracy of autonomous navigation in agricultural robotic systems. (*Research purpose*) The primary objective is to develop a method capable of compensating for data loss in depth maps, thereby improving the performance of Simultaneous Localization and Mapping (SLAM) systems. (*Materials and methods*) The depth map reconstruction method consists of three main stages: computation of the anisotropic gradient; identification of similar blocks based on a novel similarity criterion; and merging of the detected blocks using a neural network architecture composed of an encoder, a fusion layer, and a decoder. The method was tested using the Rosario dataset, which includes scenarios representative of complex agricultural environments. (*Results and discussion*) The proposed depth map reconstruction method demonstrates a significant improvement in quality metrics. Specifically, Root Mean Square Error (RMSE), Peak Signal-to-Noise Ratio (PSNR), and Structural Similarity Index Measure (SSIM) improved by 20–30 percent compared to the existing techniques. The method preserves the structure and texture features of the reconstructed regions, enabling accurate restoration of large areas with missing pixel data. To evaluate the impact on SLAM performance, the Stereo Multi-State Constraint Kalman Filter (S-MSCKF) algorithm was employed. Quantitative analysis of Absolute Trajectory Error (ATE) and mean RMSE was conducted both before and after applying the depth map reconstruction. The results show a reduction in Absolute Trajectory Error from 0.62 meters to 0.25 meters, and a decrease in Root Mean Square Error from 0.85 meters to 0.39 meters. (*Conclusions*) The proposed method substantially enhances SLAM system accuracy, particularly in challenging agricultural environments, characterized by uneven terrain, variable lighting conditions, and long-distance navigation. Its robust performance suggests strong potential for large-scale integration into autonomous agricultural machinery, contributing to improved reliability, operational efficiency, and safety in robotic field operations.

Keywords: agricultural robot, Simultaneous Localization and Mapping System (SLAM), depth map, neural network, anisotropic gradient, depth map reconstruction.

■ **For citation:** Gapon N.V., Voronin V.V., Rudoy D.V., Zhdanova M.M. Modified SLAM for agricultural robot navigation. *Agricultural Machinery and Technologies*. 2025. Vol. 19. N2. 19-25 (In Russian). DOI: 10.22314/2073-7599-2025-19-2-19-25. EDN: SKWTMC.

Сегодня роботы используются практически во всех аспектах нашей повседневной жизни для решения различных задач на производстве, в медицине, науке и др. Роботизация в агропромышленном комплексе [1] доказала свою эффективность при посеве семян [2], внесении удобрений, точном опрыскивании растений, поливе [3], в контроле состояния посевов, борьбе с сорняками [4], уборке урожая. Внедрение стратегии взаимодействия человека и робота (*Human Robot Interaction, HRI*) в сельском хозяйстве способствует автоматизации процессов и позволяет снизить себестоимость производства продукции, уменьшить утомительный ручной труд, повысить точность механизированных операций, качество свежей продукции, улучшить экологический контроль.

Эффективность концепции *HRI* достигается за счет оснащения сельскохозяйственных машин системами компьютерного зрения (СКЗ) и реализующими алгоритмами. СКЗ могут быть представлены различными датчиками, позволяющими видеть окружающее пространство, распознавать целевые объекты и препятствия, оценивать расстояние до них, строить траекторию перемещения.

Для определения расстояния от датчика СКЗ до целевого объекта используются методы построения карты глубины. Карта глубины – это изображение, в котором вместо цвета каждый пиксель со-

держит информацию о расстоянии от камеры до объекта наблюдения [5].

Одним из наиболее популярных и доступных на сегодняшний день методов построения траектории перемещения робота является *SLAM* (одновременная локализация и картографирование) [6]. Это метод разработан для решения проблемы самолокализации и картографии в неизвестной среде, широко используется в навигации роботов [7], автономном вождении, дополненной и виртуальной реальности. Входными данными для алгоритмов *SLAM* являются измерения с использованием датчиков для построения карты глубины.

Одна из проблем систем *SLAM* – потерянные участки на карте глубины [8], что приводит к снижению точности планирования траектории перемещения. Подобные дефекты появляются из-за плохого освещения, наличия зеркальной или мелкозернистой поверхности предметов. В результате появляется эффект увеличенных границ объектов (препятствий), а перекрытие объектов делает невозможным отличить один объект от другого [8].

Для приложений навигации роботов карты глубины, созданные с помощью стереокамер, камер *RGB-D* и других датчиков, требуется дополнительная обработка для заполнения недостающих частей с использованием методов реконструкции (заполнения утерянных областей). Однако традиционные

методы закрашивания цветных изображений не могут быть применены непосредственно к картам глубины, так как недостаточно информации для того, чтобы сделать точные выводы о структуре сцены.

Цель исследования. Разработать новый метод реконструкции для восстановления потерянных областей на картах глубины для повышения точности автономной навигации роботизированных технологических комплексов (РТК).

МАТЕРИАЛЫ И МЕТОДЫ. Автономная навигация сельскохозяйственных РТК опирается на технологию одновременной локализации и картирования (SLAM) [6]. Система использует визуальные датчики для получения необходимых данных для построения карты глубины – это изображение $S_{i,j}$, $i = 1...N$, $j = 1...M$, где яркость каждого пикселя соответствует расстоянию до объекта. Алгоритм реконструкции карты глубины включает этапы: вычисление анизотропного градиента, адаптивный выбор размера блока, кластеризация изображения, поиск похожих блоков по новому критерию и объединение блоков с помощью нейронной сети.

В качестве первого этапа обработки карты глубины выбирается целевая область (Ω), требующая реконструкции.




Рис. 1. Модель изображения карты глубины
Fig. 1. Model of the depth map image

Учитывая блок Ψ_p с центром в точке p для некоторого $p \in \delta\Omega$ (рис. 1), определяется приоритет $P(p)$ как произведение двух показателей [5]:

$$P(p) = C(p) \cdot D(p), \quad (1)$$

где $C(p)$ – коэффициент доверия; $D(p)$ – коэффициент градиента.

Они определяются следующим образом:

$$C(p) = \frac{\sum_{q \in \Psi_p \cap (\delta - \Omega)} C(q)}{|\Psi_p|}, \quad D(p) = \frac{|\nabla I_p \cdot n_p|}{\alpha}, \quad (2)$$

где $|\Psi_p|$ – площадь Ψ_p ; α – коэффициент нормализации ($\alpha=255$ для восьми битных изображений); n_p – единичный вектор, ортогональный границе $\delta\Omega$ в точке p ; $\perp$ обозначает ортогональный оператор.

Расчет приоритета фокусируется на граничных пикселях с резким изменением яркости, содержащих максимальный объем информации. Коэффициент доверия подавляет влияние уже обработанных пикселей, что расширяет область поиска

отсутствующих данных. Градиент представляет собой векторное поле, где каждый пиксель характеризуется вектором, указывающим направление наибольшего изменения интенсивности. Предложен новый метод вычисления анизотропного градиента, обеспечивающий устойчивость к шуму и мелким текстурным деталям.

Для вычисления шаблонов, зависящих от форм, изображение разбивается на $m \times n$ окон. Из каждого окна извлекаются признаки, соответствующие девяти формам структурного рисунка (рис. 2). Затем для каждого признака вычисляется среднее арифметическое, которое располагается аналогично соответствующему структурному шаблону [9]. Для первой маски для центрального пикселя считаем среднее в локальной области. Далее для восьми направлений считаем среднее арифметическое в масках.




Рис. 2. Структурные области (Structure 1, Structure 2, Structure 3) и вычисление среднего арифметического для восьми направлений

Fig. 2. Structural regions (Structure 1, Structure 2, Structure 3) and arithmetic mean calculation across eight directions

Градиент в соответственном направлении считается как разница между средним в данном направлении (рис. 3).

Для первого направления: $D_1 = S_{i,j} - S_{i,j-1}$, для второго направления: $D_2 = S_{i,j} - S_{i,j+1}$, для третьего направления: $D_3 = S_{i,j} - S_{i-1,j}$, для четвертого направления: $D_4 = S_{i,j} - S_{i+1,j}$, для пятого направления: $D_5 = S_{i,j} - S_{i-1,j+1}$, для шестого направления: $D_6 = S_{i,j} - S_{i+1,j-1}$, для седьмого направления: $D_7 = S_{i,j} - S_{i-1,j-1}$, для восьмого направления: $D_8 = S_{i,j} - S_{i+1,j+1}$, где s – текущее значение пикселя изображения с координатами (i, j) . Учитываются все восемь направлений.

Далее расчет повторяется в областях Structure 2 и Structure 3. Все три градиента усредняются.

Выбор размера блока критически важен для точности реконструкции в методах, использующих поиск похожих блоков. Оптимальный размер зависит от типа области: для текстурных и однородных участков он должен быть больше, чем для областей с четко выраженными границами или контурами.




Рис. 3. Градиент для Structure 1

Fig. 3. Gradient for Structure 1

Предлагается использовать адаптивный размер блока, основанный на алгоритме разбиения *QuadTree* [10]. Алгоритм начинается с оценки неоднородности блока путем вычисления среднего значения его яркости

$$C_{avg} = \frac{1}{K \times K} \cdot \sum(C_{i,j}), \quad (3)$$

где $C_{i,j}$ — яркость (цвет) пикселя (i,j) .

Дисперсия блока

$$Var = \frac{1}{K \times K} \cdot \sum(C_{i,j} - C_{avg})^2. \quad (4)$$

Разбиение блока происходит, только если значение V_{ar} превышает порог T . В этом случае блок признается неоднородным и делится на подблоки. Если $V_{ar} \leq T$, блок считается однородным и дальнейшего разбиения не требуется. Результат такого разбиения изображения, формирующего квадродерево, иллюстрируется на рисунке 4.



Рис. 4. Изображения «Виноградные ряды», разбитые на квадродерево

Fig. 4. Quadtree-based segmentation of «Vineyard Rows» images

Для поиска похожих блоков в доступной области изображения можно использовать полный поиск по всему изображению или локальный поиск в окрестности текущего пикселя. Однако оба метода несовершенны. Предлагаемый подход, основанный на предварительной кластеризации изображения, позволяет сузить область поиска для каждого блока, повышая эффективность.

Эффективная обработка изображений требует

оптимального использования пространственной информации окрестности каждой точки. Фиксированные окна обработки имеют ограничение: малые окна упускают контекст, большие — чрезмерно увеличивают вычислительную нагрузку. Предлагаемый алгоритм решает эту проблему, используя адаптивное определение окрестности на основе суперпикселей, что улучшает качество реконструкции. Выбор оптимального структурирующего элемента для обработки градиентов изображения сложен и зависит от его особенностей. Для устранения этой зависимости предлагается использовать несколько структурирующих элементов, реконструировать градиентное изображение для каждого из них и затем объединить результаты. Это позволяет получить более стабильный и независимый от выбора элемента результат:

$$R_f^{MC}(g, r_1, r_2) = \vee \{R_f^C(g)_{B_{r_1}}, R_f^C(g)_{B_{r_1+1}}, \dots, R_f^C(g)_{B_{r_2}}\} \quad (5)$$

где r — радиус; r_1 и r_2 — минимальное и максимальное значения соответственно, $r_1 \leq r \leq r_2$, $r_1, r_2 \in N^+$, $g \leq B$; B — структурирующий элемент; g — изображение маркера; R^C — морфологическая реконструкция закрытия.

Предложенный алгоритм использует два параметра: r_1 , определяющий минимальный размер области, и r_2 , определяющий максимальный размер области.

Оптимальное значение r_1 находится в диапазоне от 1 до 3. При $r_1 < 1$ результат содержит множество мелких областей, при $r_1 > 3$ снижается точность контура. Значения r_1 от 1 до 3 обеспечивают высокую точность контура и удаление мелких областей.

Параметр r_2 влияет на максимальный размер области; его увеличение улучшает результат, но после достижения некоторого порогового значения дальнейшее увеличение не оказывает влияния. При достаточно больших значениях r_2 алгоритм сходится к оптимальному результату — изображению с меньшим количеством областей и высокой точностью контура. Таким образом, алгоритм малочувствителен к изменению r_2 выше порогового значения:

$$\max\{R_f^{MC}(g, r_1, r_2) - R_f^{MC}(g, r_1, r_2 + 1)\} \leq \eta \quad (6)$$

В уравнении (6) переменную r_2 можно заменить на константу η , поскольку r_2 индивидуально меняется для каждого изображения, тогда как η одинаково для всех. Выбор η критичен: слишком большое его значение приводит к малой величине r_2 и большой ошибке, а слишком маленькое — к малой ошибке, но большим r_2 и, соответственно, высоким вычислительным затратам. Поэтому значение η должно быть подобрано оптимально для конкретного набора данных. Учитывая сложность задания

индивидуальных значений r_2 для каждого изображения и адаптивный характер r_2 в реальных приложениях, предложенный алгоритм использует минимальный порог ошибки η вместо r_2 , эффективно уменьшая η . При этом, если $\eta \leq 10^{-4}$, то r_2 не изменяется. В данном алгоритме принято $\eta=10^{-4}$.

Выбор наиболее подходящего блока осуществляется на основе сравнения с использованием метрики сходства изображений. Цель – восстановить изображение, минимизируя видимые артефакты внутри, снаружи и вокруг реставрированных участков. В предложенном методе используется метрика сходства градиентов, определяемая как

$$G(I_r, I_{inp}) = \frac{2 \sum_{i=0}^{W-1} \sum_{j=0}^{H-1} D_r^{ij} G_{inp}^{ij} + K_2}{\sum_{i=0}^{W-1} \sum_{j=0}^{H-1} [D_r^{ij}]^2 + \sum_{i=0}^{W-1} \sum_{j=0}^{H-1} [D_{inp}^{ij}]^2 + K_2}, \quad (7)$$

где D – величина градиента; K_2 – небольшая положительная константа.

Далее для найденных похожих блоков применяется разработанная нейронная сеть, которая позволяет получить результирующий блок путем объединения найденных блоков. Архитектура нейронной сети состоит из трех элементов: это кодировщик, слой слияния и декодер (рис. 5).




Рис. 5. Архитектура нейронной сети для объединения найденных блоков

Fig. 5. Neural network architecture for merging detected blocks

В качестве входных сигналов используются найденные блоки, которые обозначаются $I_1, \dots, I_k$ и $k \geq 2$. Процедура обучения сети подробно представлена в работе [11].

После того, как блок Ψ_p был заполнен новыми

значениями пикселей, коэффициент доверия $C(p)$ обновляется в области, ограниченной Ψ_p , следующим образом:

$$C(p) = C(\hat{p}) \forall p \in \Psi_p \cap \Omega. \quad (8)$$

Это правило упрощает оценку достоверности данных на краях обрабатываемой области. С увеличением заполненной области достоверность данных снижается, что отражает уменьшение уверенности в цветовых значениях пикселей ближе к центру целевой области.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ. Эксперимент проводился с использованием набора данных *Rosario* [12]. На рисунке 6 представлены результаты реконструкции карт глубины: исходные RGB-изображения (слева), необработанные карты глубины (в центре) и карты глубины, реконструированные с помощью предложенного алгоритма (справа).




Рис. 6. Результаты реконструкции карт глубины из датасета Rosario

Fig. 6. Results of depth map reconstruction from the Rosario dataset

Предложенный метод обеспечивает точное восстановление границ без потери четкости текстуры и структуры, даже при реконструкции больших участков с отсутствующими пикселями.

В таблице 1 приведено сравнение погрешности

Таблица 1					Table 1							
ЗНАЧЕНИЯ ПОГРЕШНОСТЕЙ ДЛЯ ПРЕДЛОЖЕННОГО МЕТОДА, МЕТОДОВ EBM, DEEPFill И EDGECONNECT ERROR VALUES FOR THE PROPOSED METHOD AND EBM, DEEPFill, EDGECONNECT METHODS												
Изображения	PSNR				RMSE				SSIM			
	EBM	DeepFill	EdgeConnect	Предложенный метод	EBM	DeepFill	EdgeConnect	Предложенный метод	EBM	DeepFill	EdgeConnect	Предложенный метод
1	16,36	17,05	17,32	18,60	31,19	29,60	27,49	24,68	0,95	0,96	0,97	0,98
2	17,26	18,26	18,45	19,94	27,11	26,20	24,90	20,13	0,95	0,98	0,98	0,98
3	12,23	13,76	14,03	16,53	36,57	35,88	34,01	31,86	0,96	0,96	0,97	0,99
Среднее по всей базе	15,22	16,23	16,54	17,57	31,62	30,9	29,08	26,11	0,95	0,96	0,98	0,99

Таблица 2

Table 2

СРЕДНЕЕ ЗНАЧЕНИЕ RMSE И АБСОЛЮТНОЙ ОШИБКИ ТРАЕКТОРИИ (ATE) MEAN VALUES OF ROOT MEAN SQUARE ERROR (RMSE) AND ABSOLUTE TRAJECTORY ERROR (ATE)				
Последовательность	S-MSCKF до реконструкции		S-MSCKF после реконструкции	
	ATE(м)	RMSE	ATE(м)	RMSE
Rosario 01	0,62	0,85	0,25	0,39
Rosario 02	1,25	1,31	0,63	0,74
Rosario 03	1,2	1,33	0,61	0,76

предложенного метода с методами *EBM* [5], *DeepFill* [13] и *EdgeConnect* [13] на тестовых картах глубины из набора *Rosario*.

Для сравнительного анализа точности *SLAM*-алгоритмов, в качестве эталона был выбран *S-MSCKF* [14]. В *таблице 2* отражены количественные результаты, представляющие средние значения абсолютной ошибки траектории (*ATE*) и среднеквадратичной ошибки (*RMSE*) [15] до и после реконструкции карт глубины. Значения *ATE* и *RMSE* вычислены путем усреднения результатов пяти независимых запусков на каждой последовательности. Наилучшие результаты (минимальные ошибки) выделены жирным шрифтом.

Результаты *RMSE* и *ATE* после реконструкции карт глубины превосходят значения *RMSE* и *ATE* до реконструкции.

Выводы. Предложенный метод обеспечивает на 20-30% меньшую ошибку реконструкции по сравнению с традиционными подходами. Его эффективность подтверждена экспериментами по реконструкции карт глубины.

Сложные условия, такие как повторяющиеся сельские ландшафты, изменяющееся освещение, протяженные траектории и динамические эффекты ветра, представляют значительные трудности для современных систем визуального *SLAM*. Однако результаты, полученные с использованием *S-MSCKF*, продемонстрировали наилучший результат после реконструкции карт глубины. Это открывает перспективы применения *Visual SLAM* в недорогих сенсорных системах, повышая надежность и точность автономной навигации сельскохозяйственных систем.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

- Измайлов А.Ю., Лобачевский Я.П., Ценч Ю.С. и др. О синтезе роботизированного сельскохозяйственного мобильного агрегата // *Вестник российской сельскохозяйственной науки*. 2019. N4. С. 63-68. DOI: 10.30850/vrsn/2019/4/63-68.
- Смирнов И.Г., Хорт Д.О., Кутырев А.И. Интеллектуальные технологии и роботизированные машины для возделывания садовых культур // *Сельскохозяйственные машины и технологии*. 2021. Т. 15. N4. С. 35-41. DOI: 10.22314/2073-7599-2021-15-4-35-41.
- Ценч Ю.С., Курбанов Р.К., Захарова Н.И. Развитие систем управления полетом и средств аэрофотосъемки беспилотных воздушных судов сельскохозяйственного назначения // *Сельскохозяйственные машины и технологии*. 2024. Т. 18. N2. С. 11-19. DOI: 10.22314/2073-7599-2024-18-2-11-19.
- Смирнов И.Г., Дышеков А.И., Девяткин Ф.В. Алгоритм работы автономного роботизированного комплекса мониторинга сорной растительности // *Электротехнологии и электрооборудование в АПК*. 2024. Т. 71. N1(54). С. 71-75. DOI: 10.22314/2658-4859-2024-71-1-71-75.
- Зеленский А.А., Гапон Н.В., Жданова М.М. и др. Метод восстановления карты глубины в задачах управления роботами и мехатронными системами // *Мехатроника, автоматизация, управление*. 2022. Т. 23. N2. С. 104-112. DOI: 10.17587/mau.23.104-112.
- Павлов А.С. Методика планирования траектории движения группы мобильных роботов в неизвестной замкнутой среде с препятствиями // *Системы управления, связи и безопасности*. 2021. N 3. С. 38-59. DOI: 10.24412/2410-9916-2021-3-38-59.
- Тетерев А.В. Обоснование выбора системы позиционирования для управления движением мобильного сельскохозяйственного робота // *Сельскохозяйственные машины и технологии*. 2020. Т. 14. N4. С. 63-70. DOI: 10.22314/2073-7599-2020-14-4-63-70.
- Кутырев А.И., Дышеков А.И. Разработка системы управления движением роботизированной платформы на основе методов лазерной дальнометрии (LiDAR) // *Агроинженерия*. 2023. Т. 25. N2. С. 19-27. DOI: 10.26897/2687-1149-2023-2-19-27.
- Panetta K., Sanghavi F., Agaian S., Madan N. Automated detection of COVID-19 cases on radiographs using shape-dependent Fibonacci-p patterns. *IEEE Journal of Biomedical and Health Informatics*. 2021. Vol. 25. N6. 1852-1863. DOI: 10.1109/JBHI.2021.3069798.
- Yang S., Liang H., Wang Y. et al. Image inpainting based on multi-patch match with adaptive size. *Applied Sciences*. 2020. Vol. 10. N14. 4921. DOI: 10.3390/app10144921.
- Voronin V., Gapon N., Khamidullin I. et al. E. A vision system using depth inpainting for virtual content reconstruction in Augmented Reality. *ProcSPIE*. 2022. Vol. 12275. 146-156. DOI: 10.1117/12.2642007.
- Подтихов А.В., Савельев А.И. Открытый набор данных для тестирования Visual SLAM-алгоритмов при различных погодных условиях // *Труды учебных заведений связи*. 2024. Т. 10. N1. С. 97-106. DOI: 10.31854/1813-324X-2024-10-1-97-106.
- Kim H., Kim C., Kim H. et al. Panoptic blind image inpainting. *ISA transactions*. 2023. Vol. 132. 208-221. DOI: 10.1016/j.isatra.2022.10.030.

14. Zhang Z., Dong P., Wan J., Sun Y. Improving S-MSCKF with variational Bayesian adaptive nonlinear filter. *IEEE Sensors Journal*. 2020. Vol.20. N16. 9437-9448. DOI: 10.1109/jsen.2020.2989206.
15. Боковой А.В. Муравьев К.Ф., Яковлев К.С. Система одно-

временного картирования, локализации и исследования неизвестной местности по видеопотоку // *Информационные технологии и вычислительные системы*. 2020. N2. С. 51-61. DOI: 10.14357/20718632200205.

REFERENCES

1. Izmaylov A.Yu., Lobachevsky Ya.P., Tsench Yu.S. et al. About synthesis of robotic agriculture mobile machine. *Vestnik of the Russian Agricultural Science*. 2019. N4. 63-68 (In Russian). DOI: 10.30850/vrsn/2019/4/63-68.
2. Smirnov I.G., Khort D.O., Kutyrev A.I. Intelligent technologies and robotic machines for cultivating horticultural crops. *Agricultural Machinery and Technologies*. 2021. Vol. 15. N4. 35-41 (In Russian). DOI: 10.22314/2073-7599-2021-15-4-35-41.
3. Tsench Yu.S., Kurbanov R.K., Zakharova N.I. Evolution of flight control systems and aerial photography in unmanned agricultural aircraft. *Agricultural Machinery and Technologies*. 2024. Vol. 18. N2. 11-19 (In Russian). DOI: 10.22314/2073-7599-2024-18-2-11-19. EDN: JPLEGX
4. Smirnov I.G., Dyshekov A.I., Devyatkin F.V. Operation algorithm for the autonomous robotic weed monitoring system. *Electrical Engineering and Electrical Equipment in Agriculture*. 2024. Vol. 71. N1(54). 71-75 (In Russian). DOI: 10.22314/2658-4859-2024-71-1-71-75.
5. Zelensky A.A., Gapon N.V., Zhdanova M.M. et al. Depth map reconstruction method in control problems for robots and mechatronic systems. *Mechatronics, Automation, Control*. 2022. Vol. 23. N2. 104-112 (In Russian). DOI: 10.17587/mau.23.104-112.
6. Pavlov A.S. Methodology for planning the trajectory of a group of mobile robots in unknown closed environment with obstacles. *Systems of Control, Communication and Security*. 2021. N3. 38-59 (In Russian). DOI: 10.24412/2410-9916-2021-3-38-59.
7. Teterev A.V. Rationale for the choice of a positioning system for mobile agricultural robot movement controlling. *Agricultural Machinery and Technologies*. 2020. Vol. 14. N4. 63-70 (In Russian). DOI: 10.22314/2073-7599-2020-14-4-63-70.
8. Kutyrev A.I., Dyshekov A.I. Development a motion control system for a robotic platform based on laser ranging methods (LiDAR). *Agricultural Engineering*. 2023. Vol. 25. N2. 19-27 (In Russian). DOI: 10.26897/2687-1149-2023-2-19-27.
9. Panetta K., Sanghavi F., Agaian S., Madan N. Automated detection of COVID-19 cases on radiographs using shape-dependent Fibonacci-p patterns. *IEEE Journal of Biomedical and Health Informatics*. 2021. Vol. 25. N6. 1852-1863 (In English). DOI: 10.1109/JBHI.2021.3069798.
10. Yang S., Liang H., Wang Y. et al. Image inpainting based on multi-patch match with adaptive size. *Applied Sciences*. 2020. Vol. 10. N14. 4921 (In English). DOI: 10.3390/app10144921.
11. Voronin V., Gapon N., Khamidullin I. et al. A vision system using depth inpainting for virtual content reconstruction in Augmented Reality. *ProcSPIE*. 2022. Vol. 12275. 146-156 (In English). DOI: 10.1117/12.2642007.
12. Podtikhov A.V., Saveliev A.I. Open dataset for testing of Visual SLAM algorithms under different weather conditions. *Proceedings of Telecommun. Univ*. 2024. Vol. 10. N1. 97-106 (In Russian). DOI: 10.31854/1813-324X-2024-10-1-97-106.
13. Kim H., Kim C., Kim H. et al. Panoptic blind image inpainting. *ISA transactions*. 2023. Vol. 132. 208-221 (In English). DOI: 10.1016/j.isatra.2022.10.030.
14. Zhang Z., Dong P., Wan J., Sun Y. Improving S-MSCKF with variational Bayesian adaptive nonlinear filter. *IEEE Sensors Journal*. 2020. Vol. 20. N16. 9437-9448 (In English). DOI: 10.1109/jsen.2020.2989206.
15. Bokovoy A.V., Muraviev K.F., Yakovlev K.S. Vision-based simultaneous localization, mapping and exploration system. *Journal of Information Technologies and Computation Systems*. 2020. N2. 51-61 (In Russian). DOI: 10.14357/20718632200205.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Заявленный вклад соавторов:

Гапон Н.В. – руководство исследованием, разработка алгоритма, создание окончательной версии рукописи;
 Воронин В.В. – разработка алгоритма;
 Рудой Д.В. – администрирование проекта, создание черновика рукописи;
 Жданова М.М. – редактирование текста, формулировка выводов;

Авторы одобрили окончательный вариант рукописи.

Conflict of interest

The authors declare no conflict of interest.

Coauthors' contribution:

Gapon N.V. – research supervision, algorithm development, development of the final manuscript version (refining);
 Voronin V.V. – algorithm development;
 Rudoy D.V. – project administration, drafting the manuscript;
 Zhdanova M.M. – proofreading and refining the manuscript, formulation of conclusions;

The authors read and approved the final manuscript.

Статья поступила в редакцию

Статья принята к публикации

The paper was submitted to the Editorial Office on

The paper was accepted for publication on

01.04.2025

26.05.2025