

УДК 631.354

UDC 631.354

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)

ОПТИМИЗАЦИЯ АЛГОРИТМОВ SLAM ДЛЯ АВТОНОМНОЙ НАВИГАЦИИ АГРОПРОМЫШЛЕННЫХ РОБОТОВ

OPTIMIZATION OF SLAM ALGORITHMS FOR AUTONOMOUS NAVIGATION OF AGRO-INDUSTRIAL ROBOTS

Гапон Николай Валерьевич

Gapon Nikolay Valer'evich

SPIN-код: 8918-3047

RSCI SPIN-code: 8918-3047

nikolay-rt@mail.ru

nikolay-rt@mail.ru

Донской государственный технический университет, Ростов-на-Дону

Don State Technical University, Rostov-on-Do

Автономная навигация требует от сельскохозяйственных роботов локализации и создания глобально согласованной карты окрестностей в режиме реального времени. Однако точная и надежная локализация и картографирование по-прежнему являются сложной задачей для сельскохозяйственных роботов из-за неструктурированных, динамических и лишенных GPS условий окружающей среды. Одновременная локализация и картирование (SLAM) является современным подходом для этого. Для восприятия окружающей среды используются карты глубины, полученные с помощью различных сенсоров, такие как стереопары, камеры глубины и т.д. Из-за сложности среды, на картах глубины появляются потерянные области, приводящие к проблемам точности SLAM. В этом исследовании была представлена оптимизация современной системы SLAM в реальном времени, с помощью метода реконструкции карт глубины на основе поиска похожих блоков. Сопоставление блоков выполняется с помощью метода PatchMatch, с использованием нового критерия сходства. Представлены оценки производительности предлагаемого метода реконструкции карт глубины, такие как пиковое отношение сигнал/шум (PSNR), индекс структурного сходства (SSIM) и время выполнения алгоритма. Количественные результаты предложенного метода превосходят существующие современные методы реконструкции карт глубины

Autonomous navigation requires agricultural robots to localize and generate a globally consistent map of their surroundings in real-time. However, accurate and reliable localization and mapping are still challenging for agricultural robots due to unstructured, dynamic, and GPS-less environments. Simultaneous localization and mapping (SLAM) are a state-of-the-art approach for this. It uses depth maps obtained from various sensors, such as stereo pairs, depth cameras, etc., to perceive the environment. Due to the complexity of the environment, missing regions appear in the depth maps, leading to accuracy issues in SLAM. In this study, an optimization of a state-of-the-art real-time SLAM system using a similarity-based depth map reconstruction method was presented. Block matching is performed using the PatchMatch method using a novel similarity criterion. The performance evaluations of the proposed depth map reconstruction method, such as the peak signal-to-noise ratio (PSNR), structural similarity index (SSIM), and algorithm execution time, are presented. The quantitative results of the proposed method are superior to existing modern methods of depth map reconstruction

Ключевые слова: СЕЛЬСКОХОЗЯЙСТВЕННЫЙ РОБОТ, SLAM, КАРТА ГЛУБИНЫ, ПАТЧМАТЧ, РЕКОНСТРУКЦИЯ КАРТ ГЛУБИНЫ

Keywords: AGRICULTURAL ROBOT, SLAM, DEPTH MAP, PATCHMATCH, DEPTH MAPS RECONSTRUCTION

<http://dx.doi.org/10.21515/1990-4665-210-015>

Введение. В последнее время актуальна задача исследований и применения роботизированных решений для сельскохозяйственного сектора. В настоящее время роботы используются для различных задач, таких как посадка, сбор урожая, мониторинг окружающей среды, подача воды и питательных веществ и т.д. [1]. Разработка решений, которые позволяют роботам безопасно перемещаться в этих средах, имеет важное значение - это локализация роботов в сельскохозяйственных средах. Использование автономных решений на основе глобальной навигационной спутниковой системы (GNSS) [2] страдают от блокировки сигнала и множественных отражений в сельскохозяйственных и лесных районах, что делает использование GNSS ненадежным. Одновременная локализация и картирование (SLAM) [3] является современным подходом для этого. Этот метод заключается в оценке состояния робота с использованием входных данных датчиков и одновременном построении карты окружающей среды. Создание карты важно для предоставления информации об окружающей среде.

Локализация робота зависит от многих аспектов: окружение, в котором работает робот, качества бортовых датчиков и желаемой производительности системы локализации. SLAM в сложных условиях на открытом воздухе (таких как сельское, лесное хозяйство) по-прежнему является растущей темой исследований. Это высокодинамичные среды, которые резко меняются в течение года, что делает долгосрочное картирование сложной задачей. Кроме того, характеристики освещения и неровности рельефа приводят к более нестабильному движению и более сложному восприятию окружающей среды. Для восприятия окружающей среды используются карты глубины, полученные с помощью различных сенсоров, такие как стереопары, камеры глубины и т.д. Карты глубины представляют собой представление трехмерного пространства, созданное на основе измерений расстояния до различных точек сцены. Из-за

сложности среды, на картах глубины появляются потерянные области, приводящие к проблемам точности SLAM. В этой работе предложен метод реконструкции карт глубины на основе быстрого поиска похожих блоков.

Материалы и методы исследования. Современные методы реконструкции карт глубины используют похожие блоки, но фиксированный размер блока ухудшает качество и замедляет процесс. Новое решение адаптирует размер блока под особенности изображения и применяет быстрый поиск схожих фрагментов методом PatchMatch [4], что ускоряет реконструкцию и улучшает её точность. Как показано на рисунке 1, I представляет собой все неполное изображение, недостающая область (целевая область) представлена Ω , Φ – известная область, определяется как $\Phi = I - \Omega$. $\delta\Omega$ – внешняя граница Ω ($\delta\Omega \subset \Phi$).




Рисунок 1 – Модель карты глубины

Чтобы определить порядок заполнения, необходимо вычислить приоритет для всех пикселей вдоль границы заполнения $\delta\Omega$. Для пикселя p ($p \in \delta\Omega$) приоритет $P(p)$ определяется следующим образом [5]:

$$P(p) = C(p)D(p) \quad \forall p \in \delta\Omega, \quad (1)$$

$$C(p) = \frac{\sum_{q \in \Psi_p \cap \Phi} C(q)}{|\Psi_p|}, \quad (2)$$

$$D(p) = \frac{|\nabla I_p^\perp \cdot n_p|}{255}, \quad (3)$$

где $C(p)$ – коэффициент доверия; $D(p)$ – коэффициент градиент; Ψ_p представляет собой участок с центром в точке p , и $|\Psi_p|$ – площадь Ψ_p , ∇I_p представляет градиент в точке p , $\perp$ – ортогональный оператор, поэтому $\nabla I_p^\perp$ обозначает вектор изофоты. n_p – вектор, ортогональный фронту заполнения $\delta\Omega$ в точке p (Рисунок 1).

После определения целевого участка для заполнения находится наиболее подходящий участок Ψ_q из исходной области Φ для заполнения неизвестных пикселей целевого участка. $\Psi_{\hat{p}}$. Точность реконструкции карт глубины зависит от выбора размера блока. Предлагается использовать адаптивный размер блока [6], определяемый путём оценки неоднородности блока посредством вычисления среднего значения его яркости:

$$C_{avg} = \frac{1}{K \times K} * \sum(C_{i,j}), \quad (4)$$

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

Дисперсия блока вычисляется следующим образом:

$$Var = \frac{1}{K \times K} * \sum(C_{i,j} - C_{avg})^2 \quad (5)$$

Изображение делится на блоки только при значении Var , превышающем порог T . В противном случае ($Var \leq T$), блок считается однородным и остаётся без изменений. Рисунок 2 демонстрирует результат этого процесса для изображения «Виноградные ряды».




Рисунок 2 – Изображение, разбитое на блоки разного размера

Поиск похожих блоков ограничен предварительно выделенной областью, что повышает производительность. Алгоритм адаптируется к особенностям изображения, изменяя окно обработки. Радиусы r_1 и r_2 задают диапазон размеров блока. Оптимальное значение r_1 лежит в интервале $[1,3]$ для баланса между качеством и скоростью. Результат объединения разных элементов выражается формулой [7]:

$$R_f^{MC}(g, r_1, r_2) = \vee \{R_f^C(g)_{B_{r_1}}, R_f^C(g)_{B_{r_1+1}}, \dots, R_f^C(g)_{B_{r_2}}\} \quad (6)$$

Максимальный радиус r_2 определяется автоматически, задавая постоянный порог ошибки η :

$$\max\{R_f^{MC}(g, r_1, r_2) - R_f^{MC}(g, r_1, r_2 + 1)\} \leq \eta \quad (7)$$

Подбирая η , можно достичь компромисс между точностью и ресурсоемкостью. Когда $\eta \leq 10^{-4}$, значение r_2 остается неизменным.

Вычисление соответствий между областями изображения является ключевой проблемой во многих задачах компьютерного зрения. Предлагается использование алгоритм PatchMatch [4] – это эффективный метод для поиска ближайших совпадений между участками изображения (блоками) внутри одного изображения.

На первом этапе выполняется инициализация, каждому блоку в исходном изображении присваиваются случайные смещения. Эти смещения определяют позицию возможного совпадения блока в исходном изображении. После инициализации начинается процесс распространения информации о лучших совпадениях между соседними блоками. Идея состоит в том, что если блок $\Psi_{q(1)}$ имеет хорошее совпадение с блоком Ψ_p , то соседний блок $\Psi_{q(2)}$ с большой вероятностью найдёт хорошее совпадение рядом с блоком Ψ_p . Это помогает уменьшить количество ненужных поисков и ускорить процесс. Процесс распространения информации проходит по двум направлениям: горизонтально слева направо и справа налево; вертикально сверху вниз и снизу вверх.

Несмотря на эффективное распространение информации, некоторые полезные совпадения могут остаться незамеченными. Чтобы избежать этого, алгоритм использует случайный поиск. В ходе этой фазы PatchMatch пытается найти новые совпадения, проверяя случайные позиции в исходном изображении. Случайный поиск включает следующие шаги: проверяются случайные точки в радиусе R от текущего лучшего совпадения. Радиус поиска уменьшается экспоненциально с каждой последующей итерацией, чтобы сначала исследовать большие области, а потом сосредоточиться на детальном поиске.

Для оценки близости блоков используется метрика сходства. Метрика сходства очень важна для поиска наиболее похожего блока из исходной области. В предложенном методе используется новая метрика сходства градиентов, определяемая как:

$$G(I_r, I_{inp}) = \frac{2 \sum_{i=0}^{W-1} \sum_{j=0}^{H-1} G_r^{ij} G_{inp}^{ij} + K_2}{\sum_{i=0}^{W-1} \sum_{j=0}^{H-1} [G_r^{ij}]^2 + \sum_{i=0}^{W-1} \sum_{j=0}^{H-1} [G_{inp}^{ij}]^2 + K_2} \quad (8)$$

где $G(.)$ – величина градиента, K_2 –положительная константа.

После того, как блок $\Psi_{\hat{p}}$ был заполнен новыми значениями пикселей, коэффициент доверия $C(p)$ обновляется в области, ограниченной $\Psi_{\hat{p}}$, следующим образом:

$$C(p) = C(\hat{p}) \forall p \in \Psi_{\hat{p}} \cap \Omega \quad (9)$$

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 исследования и их обсуждение. На рисунке 3 показаны результаты реконструкции карт глубины на трех последовательностях набора данных Rosario [8]: а) исходное цветное изображение; б) поврежденная карта глубины; в) карта глубины, восстановленная методом CDD [9]; г) карта глубины, восстановленная

методом Criminisi [10]; д) карта глубины, восстановленная методом Zhou [11]; е) карта глубины, восстановленная предложенным методом;




Рисунок 3 – Результаты реконструкции карт глубины из набора Rosario

Объективная производительность алгоритмов будет оцениваться по двум аспектам: качество и эффективность. Пиковое отношение сигнал/шум (PSNR) и индекс структурного сходства (SSIM) используются для оценки сходства между готовым изображением и истинным. Время выполнения алгоритма используется для измерения эффективности реконструкции. Объективная оценка для вышеуказанных изображений карт глубины по каждому алгоритму показана в Таблице 1, Таблице 2 и Таблице 3:

Таблица 1 - Сравнение пикового отношения сигнал/шум (PSNR) (дБ).

Изображение	CDD [17]	Criminisi [13]	Zhou [18]	Предложенный
Rosario 01	37.8742	34.7881	34.5572	38.8445
Rosario 02	32.4788	33.0982	34.4566	39.3674
Rosario 03	22.6654	23.4575	22.3895	28.2469

Таблица 2 - Сравнение индекса структурного сходства (SSIM).

Изображение	CDD [17]	Criminisi [13]	Zhou [18]	Предложенный
Rosario 01	0,9873	0,9775	0,9752	0,9845
Rosario 02	0,9664	0,9807	0,9823	0,9856
Rosario 03	0,8976	0,8928	0,8808	0,9010

Таблица 3 - Сравнение времени выполнения (с).

Изображение	CDD [17]	Criminisi [13]	Zhou [18]	Предложенный
Rosario 01	113.66	306.49	574,85	81.02
Rosario 02	103,85	252.46	369.99	93.80
Rosario 03	44.38	24.02	39.70	9.56

С точки зрения объективной оценки качество реконструкции, отраженное PSNR и SSIM, в основном соответствует субъективному визуальному восприятию. Восстановленные области с более связными и естественными текстурами и структурами могут представлять лучшие визуальные эффекты, а также будут получать более высокие значения PSNR и SSIM. Что касается эффективности реконструкции, предложенный метод успешно сократил времени вычисления благодаря стратегиям поиска подобластей и сопоставления блоков.

Выводы. Проведённое исследование показало преимущество предложенного метода реконструкции карт глубины для обеспечения точного функционирования систем SLAM в условиях сельского хозяйства. Метод адаптации размера блока и быстрая процедура поиска подобных участков позволили сократить время вычислений и повысить качество карт глубины. Полученные результаты подтверждают успешность предложенного подхода, демонстрируя его способность восстанавливать утраченные фрагменты изображения с высокой степенью точности и реалистичности.

Благодарности: Исследование выполнено в рамках проекта, финансируемого Российским научным фондом (соглашение от 29.12.2023 года № 24-21-00465).

Литература

1. Roldán J.J., et al. Robots in Agriculture: State of Art and Practical Experiences. 67-90. 2018. DOI: 10.5772/intechopen.69874

2. Guo J., et al. Multi-GNSS precise point positioning for precision agriculture. Vol. 19. 895–911. 2018. <https://doi.org/10.1007/s11119-018-9563-8>
3. Zelenskii A., et al. Robot navigation using modified SLAM procedure based on depth image reconstruction. Vol. 11870, 73-82, 2021. <https://doi.org/10.1117/12.2600736>.
4. Barnes C., et al. A randomized correspondence algorithm for structural image editing. Vol. 28. No. 3. 1-12. 2009. DOI: 10.1145/1531326.1531330.
5. Gapon N., et al. Depth-map inpainting using learned patch-based propagation. Vol. 11433. 881-886. 2020. <https://doi.org/10.1117/12.2559452>.
6. Liu H., et al. Patch size adaptive image inpainting. Vol. 15. No. 10. 3642-3667. 2021. <https://doi.org/10.3837/tiis.2021.10.010>.
7. Lei T., et al. Superpixel-based fast fuzzy C-means clustering for color image segmentation. Vol. 27. No. 9. 1753-1766. 2018. DOI: 10.1109/TFUZZ.2018.2889018.
8. Pire T., et al. The Rosario dataset: Multisensor data for localization and mapping in agricultural environments. Vol. 38. No. 6. 633-641. 2019. <https://doi.org/10.1177/0278364919841437>.
9. Shen J.H., et al. Euler's Elastica and curvature-based inpainting. Vol. 63. 564–592. 2003. <https://doi.org/10.1137/S0036139901390088>.
10. Criminisi A., et al. Region filling and object removal by exemplar-based inpainting. Vol. 13. 1200–1212. 2004. DOI: 10.1109/CVPR.2003.1211538.
11. Zhou H.L., et al. Adaptive patch size determination for patch-based image completion. 421–424. 2010. DOI: 10.1109/ICIP.2010.5654120.

References

1. Roldán J.J., et al. Robots in Agriculture: State of Art and Practical Experiences. 67-90. 2018. DOI: 10.5772/intechopen.69874
2. Guo J., et al. Multi-GNSS precise point positioning for precision agriculture. Vol. 19. 895–911. 2018. <https://doi.org/10.1007/s11119-018-9563-8>
3. Zelenskii A., et al. Robot navigation using modified SLAM procedure based on depth image reconstruction. Vol. 11870, 73-82, 2021. <https://doi.org/10.1117/12.2600736>.
4. Barnes C., et al. A randomized correspondence algorithm for structural image editing. Vol. 28. No. 3. 1-12. 2009. DOI: 10.1145/1531326.1531330.
5. Gapon N., et al. Depth-map inpainting using learned patch-based propagation. Vol. 11433. 881-886. 2020. <https://doi.org/10.1117/12.2559452>.
6. Liu H., et al. Patch size adaptive image inpainting. Vol. 15. No. 10. 3642-3667. 2021. <https://doi.org/10.3837/tiis.2021.10.010>.
7. Lei T., et al. Superpixel-based fast fuzzy C-means clustering for color image segmentation. Vol. 27. No. 9. 1753-1766. 2018. DOI: 10.1109/TFUZZ.2018.2889018.
8. Pire T., et al. The Rosario dataset: Multisensor data for localization and mapping in agricultural environments. Vol. 38. No. 6. 633-641. 2019. <https://doi.org/10.1177/0278364919841437>.
9. Shen J.H., et al. Euler's Elastica and curvature-based inpainting. Vol. 63. 564–592. 2003. <https://doi.org/10.1137/S0036139901390088>.
10. Criminisi A., et al. Region filling and object removal by exemplar-based inpainting. Vol. 13. 1200–1212. 2004. DOI: 10.1109/CVPR.2003.1211538.
11. Zhou H.L., et al. Adaptive patch size determination for patch-based image completion. 421–424. 2010. DOI: 10.1109/ICIP.2010.5654120.