

20. Afanas'ev V.M. Elektroopticheskiy modulyator po skheme interferometra Makha–Tsendera [Electro-optical modulator based on the Mach-Zehnder interferometer scheme], *Prikladnaya fotonika* [Applied Photonics], 2016, Vol. 3, No. 4, pp. 341-369.
21. Mahmood H.A., Rummyantsev K.Y. Effect of FBG Compensated Dispersion on SCM/ASK Radio over Fiber System, *12th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*. IEEE, 2019, pp. 1-5.
22. Makhmud Kh.A.M., Rummyantsev K.E. Formirovanie odnopolosnoy kvadrurnoy fazovoy manipulyatsii radiosignalov na podnesushchikh chastotakh v kogerentnoy opticheskoy sisteme kommunikatsii [Formation of single-sideband quadrature phase shift keying of radio signals at subcarrier frequencies in a coherent optical communication system], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2022, No. 5, pp. 209-220. DOI: 10.18522/2311-3103-2022-5-209-220.

Румянцев Константин Евгеньевич – Южный федеральный университет; e-mail: rke2004@mail.ru; г. Таганрог, Россия; тел.: +79281827209. кафедра информационной безопасности телекоммуникационных систем; зав. кафедрой; д.т.н.; профессор.

Цыцорин Дмитрий Александрович – Южный федеральный университет; e-mail: cicorinda@mail.ru; г. Таганрог, Россия; тел.: +79381543393; военный учебный центр; начальник цикла – старший преподаватель.

Rummyantsev Konstantin Yevgenievich – Southern Federal University; e-mail: rke2004@mail.ru; Taganrog, Russia; phone: +79281827209; the Department of Information Security of Telecommunication Systems; head of department; dr. of eng. sc.; professor.

Tsytsorin Dmitry Alexandrovich – Southern Federal University; e-mail: cicorinda@mail.ru; Taganrog, Russia; phone: +79381543393; Military Training Center; head of the cycle – senior teacher.

УДК 681.5

DOI 10.18522/2311-3103-2026-1-77-86

А.Ю. Будко, Т.А. Гайда, З.А. Понимаш

ОЦЕНКА ПРОСТРАНСТВЕННОГО ПОЛОЖЕНИЯ БОРТОВОЙ КАМЕРЫ ПУТЕМ СОПОСТАВЛЕНИЯ АЭРОФОТОСНИМКОВ И ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ

Описан метод оценки пространственного положения бортовой камеры летательного аппарата, заключающийся в сопоставлении аэрофотоснимков и геопривязанных данных дистанционного зондирования Земли (ДДЗ) путем обнаружения нейросетевым детектором устойчивых в пространстве и времени реперных точек в обоих наборах данных и дальнейшим решением известной задачи Perspective-n-Point (PnP) для оценки матриц поворота и перемещения, минимизирующих ошибку перепроецирования, исходя из соответствий точек 3D мирового пространства и 2D точек их проекций на матрицу бортовой камеры, что может быть использовано для решения актуальной задачи локализации летательных аппаратов в условиях отсутствия сигналов глобальной навигационной спутниковой системы. В качестве устойчивых реперных точек, хорошо выделяемых на данных ДДЗ и аэрофотоснимках, в работе выбраны перекрестки дорог, альтернативным выбором могут являться другие локальные семантические паттерны изображений, характерные для конкретной местности. Поскольку прямое сопоставление снимков ДДЗ и бортовых снимков затруднено вследствие существенной разницы условий съемки, предлагается применение устойчивых детекторов реперных точек на основе алгоритмов искусственных нейронных сетей (ИНС). Для обучения устойчивого детектора создан смешанный датасет на основе спутниковых снимков и данных бортовой съемки. При разметке данных смешанного датасета использована функция нормализованного к единице 3D гауссиана с вершиной в центре перекрестка, график которой проецируется на 2D маску обучающего набора. Параметры функции гауссиана рассчитываются на основе радиуса окружности, описывающей перекресток. Использование функции нормализованного гауссиана с вершиной в геометрическом центре проекции перекрестка позволяет обучить сеть предсказывать вероятность принадлежности каждого пикселя изображения к перекрестку, с максимумом в центре перекрестка, что увеличивает точность позиционирования за счет более точной геопривязки реперной точки мирового 3D набора. В качестве детектора перекрестков в работе обучена ИНС архитектуры типа U-Net, в качестве метрики качества

обучения использован дифференцируемый аналог метрики *Dice*, в качестве оптимизатора использован *AdamW* в связке с косинусным планировщиком скорости обучения *CosineAnnealingLR*. В ключевой части работы приведены результаты сопоставления спутниковых данных и бортового снимка предложенным методом.

Локализация роботов; системы технического зрения; визуальная навигация; искусственные нейронные сети; ключевые точки; Perspective-n-Point.

A.Yu. Budko, T.A. Gayda, Z.A. Ponimash

ESTIMATION OF THE SPATIAL POSITION OF AN ON-BOARD CAMERA BY COMPARING AERIAL IMAGES AND SATELLITE IMAGE DATA

The article describes a method for estimating the spatial position of an onboard camera of an aircraft. This method involves comparing aerial photographs and georeferenced remote sensing (RSS) data by using a neural network detector to detect stable spatiotemporal reference points in both datasets. This method then solves the well-known Perspective-n-Point (PnP) problem for estimating rotation and translation matrices that minimize the reprojection error based on the correspondences between 3D world points and 2D points of their projections onto the onboard camera matrix. This approach can be used to solve the pressing problem of aircraft localization in the absence of global navigation satellite system signals. Road intersections are selected as stable spatiotemporal reference points that are clearly visible in RSS data and aerial photographs. Other local semantic image patterns characteristic of a particular area may serve as an alternative. Since direct comparison of remote sensing and airborne images is difficult due to significant differences in shooting conditions, the use of robust landmark detectors based on artificial neural network (ANN) algorithms is proposed. To train the robust detector, a mixed dataset was created using satellite and airborne imagery. The mixed dataset was labeled using a 3D Gaussian function normalized to unity with a apex at the intersection center, the graph of which is projected onto a 2D mask of the training set. The parameters of the Gaussian function are calculated based on the radius of the circle enclosing the intersection. Using a normalized 3D Gaussian function with a apex at the geometric center of the intersection projection allows the network to predict the probability of each image pixel belonging to the intersection, with a maximum at the intersection center, which increases positioning accuracy due to more precise georeferencing of the landmark point in the global 3D dataset. A U-Net-type artificial neural network was trained as an intersection detector. A differentiable analog of the Dice metric was used as a training quality metric. AdamW, coupled with a CosineAnnealingLR cosine learning rate planner, was used as an optimizer. The final section of the paper presents the results of comparing satellite data and airborne imagery using the proposed method.

Camera pose estimation; robot localization; machine vision systems; visual navigation; artificial neural networks; keypoints; Perspective-n-Point.

Введение. Задача оценки положения бортовой камеры (в зарубежной литературе, – «camera pose estimation», прим. авторов) тесно связана с задачами локализации и навигации роботов по визуальным данным. Наиболее актуальной областью применения данного класса задач является локализация и навигация беспилотных летательных аппаратов (БПЛА) в условиях отсутствия сигналов ГНСС, картографирование, разведка местности, охрана и мониторинг оперативной обстановки. Разновидность методов и подходов к визуальной навигации, основанных на сопоставлении информации с датчиков и электронной карты на борту робота получили название обзорно-сравнительных или корреляционно-экстремальных [1]. В данной работе рассматривается система локализации корреляционно-экстремального типа, основанная на сопоставлении геопривязанных спутниковых снимков и данных бортовой съемки в видимом диапазоне.

Традиционные алгоритмы (корреляция, SIFT, SURF) хорошо изучены, но имеют фундаментальные ограничения по устойчивости к изменениям условий съемки и требуют больших вычислительных ресурсов для обработки детальных карт. Анализ работ показывает смещение фокуса современных исследований в сторону методов искусственного интеллекта, которые радикально улучшают точность и надежность традиционных методов [2–9]. Сверточные нейронные сети (CNN) [10–13] и автоэнкодеры используются для сжатия изображений до компактных «дескрипторов» местности, что резко снижает объем хранимых данных и ускоряет поиск соответствий. Архитектуры типа PoseNet [14] учатся напрямую определять координаты и ориентацию БАС по одному кадру, минуя традиционные этапы поиска ключевых точек. В целом, нейросети лучше справляются с изменениями освещения, сезона, ракурса и погодных условий по сравнению с классическими

алгоритмами (SIFT, SURF). Среди передовых решений можно выделить следующие несколько архитектур. Сиамские сети специализированы для сравнения двух изображений и определения степени их схожести, идеальны для задач поиска эталона. Трансформеры (ViT) и гибриды CNN-Transformer показывают превосходство в задачах анализа изображений, включая локализацию и детекцию объектов, благодаря механизму внимания, улавливающему глобальный контекст сцены [15, 16]. Сети для плотного сопоставления (Neighbourhood Consensus Networks) обеспечивают точное, пиксельное соответствие между изображениями даже в слаботекстурированных сценах.

Формальная постановка задачи. Допустим имеется два набора данных к сопоставлению: карта местности на основе данных дистанционного зондирования Земли (ДДЗ) и снимки с бортовых камер летательного аппарата. Прямое сопоставление затруднено вследствие различных условий съемки, оборудования, погодных условий и прочих факторов. Для решения задачи предлагается введение промежуточного экстрактора опорных точек, обеспечивающего надежное извлечение координат и параметров таких точек из обоих наборов данных. Таким образом, после обработки опорной карты получается облако точек 3D (карта) в мировых координатах и соответствующий некоторой области облака (карты), 2D набор точек (шаблон) проекций локальной области карты на матрицу камеры с некоторыми (аффинными, сдвиговыми, нелинейными) искажениями в локальных координатах, а решение задачи сопоставления двух наборов данных переводится в область корреляционно-экстремального поиска соответствия между двумя облаками точек с минимизацией ошибки трансформации.

Таким образом задачу можно разбить на подзадачи: обнаружение ключевых точек, сопоставление облаков ключевых точек, минимизация ошибки трансформации между наборами точек и оценка положения камеры наблюдателя.

Подзадача обнаружения ключевых точек. Вначале была исследована возможность применения классических методов извлечения и сопоставления по ключевым точкам на базе дескрипторов. В качестве тестового набора изображений взяты фрагмент подложки на базе спутниковых снимков и ортофото на основе снимков БпЛА одного и того-же участка местности. В ходе исследования апробированы следующие алгоритмы поиска ключевых точек и дескрипторного описания: Harris Corner Detector; FAST (Features from Accelerated Segment Test); SIFT (Scale-Invariant Feature Transform); SURF (Speeded-Up Robust Features); ORB (Oriented FAST and Rotated BRIEF). Для сопоставления дескрипторов исследованы методы: Brute-Force Matcher (BFMatcher); FLANN (Fast Library for Approximate Nearest Neighbors); KNN Matching (k-Nearest Neighbors); SNN (Shared Nearest Neighbors). Наилучших результатов в прямом сопоставлении спутниковых снимков и снимков с бортовых камер дескрипторными методами удалось добиться, используя связку SSN + SOSNet (Second Order Similarity Regularization for Local Descriptor Learning), рис. 1.




Рис. 1. Результаты сопоставления спутниковых снимков и снимков с бортовых камер на основе связки методов SSN + SOSNet: а – фрагмент подложки на базе спутниковых снимков, б – ортофото на основе снимков с борта БпЛА

Анализ рис. 1 показывает, что даже при исключении геометрических и масштабных различий путем составления из бортовых снимков ортофотоснимка, дескрипторные методы не могут обеспечить надежного извлечения пар точек ввиду, в частности на рис. 1 произведено правильное сопоставление 3 пары из 6 пар, т.е. 50%. Таким образом, результаты экспериментов по сопоставлению изображений и поиску фрагментов на подложке показали, что при существенной разнице в разрешении и уровне детализации изображений корректное сопоставление классическими методами машинного зрения без использования дополнительных априорных данных (например, приблизительных координат расположения фрагмента) или вспомогательных контекстных элементов вызывает существенные затруднения.

Для решения данной проблемы принято решение использовать в качестве опорных точек на спутниковых снимках и изображениях с бортовых камер перекрестки дорог, как достаточно устойчивые во времени и пространстве паттерны местности. В качестве детектора перекрестков был разработан алгоритм на базе ИНС архитектуры U-net [17–19]. Для обучения детектора перекрестков был создан смешанный датасет на основе спутниковых снимков и данных бортовой съемки БПЛА. Разметка произведена нормализованными гауссианами с вершиной в центре перекрестка, рис. 2.


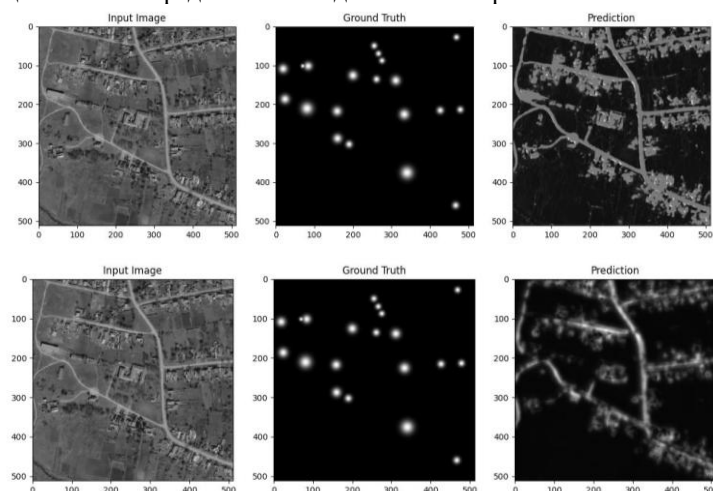


Рис. 2. Разметка датасета: а – фрагмент карты с размеченными перекрестками; б – 3D нормализованный гауссиан и его 2D проекция – в

Благодаря разметке с использованием функции нормализованных 3D гауссиан с вершиной в геометрическом центре проекции перекрестка сеть учится предсказывать вероятность принадлежности каждого пикселя к перекрестку, с максимумом в центре перекрестка, что увеличивает точность позиционирования. Далее была реализована архитектура U-Net на базе фреймворка torch, в качестве метрики качества разработан и реализован дифференцируемый аналог метрики Dice, в качестве оптимизатора использован AdamW в связке с косинусным планировщиком скорости обучения CosineAnnealingLR. На рис. 3 представлена наглядная эволюция качества предсказаний модели U-Net на различных эпохах.






Рис. 3. Эволюция качества предсказаний модели UNet при обучении:
 а – входное изображение, б – маска (учитель), в – результат работы ИНС

Примеры работы обученного детектора перекрестков на базе архитектуры UNet на данных из различных источников показаны на рис. 4.




Рис. 4. Примеры работы обученного детектора перекрестков на базе архитектуры U-Net на данных из различных источников: (а) спутниковые снимки ESRI и (б) BING область 4x4 км, ортофото собранное из бортовых снимков (в) на области 2x2 км и сырой бортовой снимок со значительными перспективными искажениями (г)

Анализ рис. 4 показывает, что детектор обрабатывает на снимках из различных источников данных с различными масштабами изображения.

Подзадачи сопоставления облаков ключевых точек, минимизации ошибки трансформации между наборами точек и оценки положения камеры наблюдателя. Чтобы определить местоположение камеры в мировых координатах, нужно выполнить следующие шаги:

1. Выполнить предварительные процедуры:
 - ◆ произвести калибровку камеру (получить внутренние параметры – матрицы камеры и коэффициентов искажения);
 - ◆ получить набор известных точек в мировых координатах и соответствующих им точек на изображении (2D-3D пары).
2. Произвести решение задачи solvePnP, – solvePnP вычисляет вектор поворота ($rvec$) и вектор перемещения ($tvec$), которые показывают положение и ориентацию объекта в системе координат камеры на основе следующих аргументов:
 - ◆ набор 3D точек в мировых координатах ($objectPoints$);
 - ◆ набор 2D точек в изображении ($imagePoints$);
 - ◆ проекционная матрица камеры ($cameraMatrix$);
 - ◆ коэффициенты искажения ($distCoeffs$).
3. Произвести расчет позиции камеры в мировых координатах: $rvec$ и $tvec$ описывают координаты системы мировых точек в системе координат камеры, чтобы получить позицию камеры в мировых координатах, нужно инвертировать это преобразование:
 - ◆ получить из вектора поворота $rvec$ матрицу поворота R с помощью преобразования Родригеса;
 - ◆ рассчитать позицию камеры $X, Y, Z = -R^T * tvec$.

Задача вычисления позы Perspective-n-Point (PnP) pose computation [20] заключается в решении задачи поворота и перемещения, минимизирующей ошибку перепроецирования, исходя из соответствий точек 3D и 2D. Наборы точек для сопоставления и связь координатных систем при решении задачи PnP показаны на рис. 5.




Рис. 5. Наборы точек для сопоставления и связь координатных систем при решении задачи PnP

Например, функция solvePnP библиотеки Open CV и связанные с ней функции оценивают позу объекта по набору точек объекта, соответствующим им проекциям изображения, а также собственной матрице камеры и коэффициентам искажения, рис. 6.

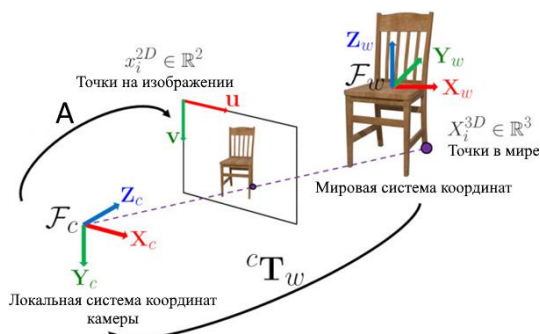


Рис. 6. Связь координатных систем при решении задачи PnP: ось X кадра камеры направлена вправо, ось Y – вниз, а ось Z – вперед


Точки, выраженные в мировой системе координат F_w проецируются на плоскость изображения $[u, v]$ с использованием модели перспективной проекции и матрицы внутренних параметров камеры (1):

$$\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_x \\ r_{21} & r_{22} & r_{23} & t_y \\ r_{31} & r_{32} & r_{33} & t_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} X_w \\ Y_w \\ Z_w \\ 1 \end{bmatrix}, \quad (1)$$

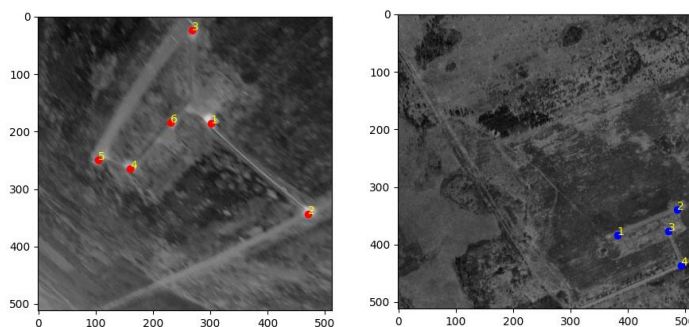
где f_x и f_y – эквивалентные фокусные расстояния по осям; c_x и c_y – пиксельные координаты центра кадра (точка на которую проецируется оптическая ось системы), r_{vec} и t_{vec} – векторы вращения и смещения.

Таким образом, расчетное положение описывается векторами вращения (r_{vec}) и смещения (t_{vec}), которые позволяют преобразовать трехмерную точку, выраженную в мировой системе координат, в кадр камеры.

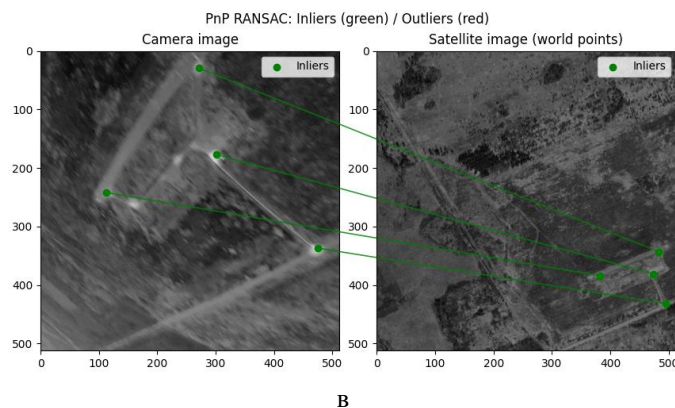
Пример сопоставления данных бортовой камеры и данных ДДЗ предложенным методом показан на рис. 7.



а



б



В

Рис. 7. Пример сопоставления данных бортовой камеры и данных ДДЗ:
 а – результаты работы детектора перекрестков, б – обнаруженные ключевые точки,
 в – результат работы алгоритма сопоставления

Анализ рис. 7 показывает, что предложенный подход позволяет уверенно сопоставить пару тестовых изображений с бортовой камеры даже с сильными проекционными и масштабными искажениями (левый ряд изображений) и фрагмента спутниковой карты (правый ряд изображений) при решении задачи PnP. Сопоставление и фильтрация ключевых точек произведены методом решения задачи PnP с оптимизацией RANSAC [21].

Заключение. В статье показан метод к оценке пространственного положения бортовой камеры летательного аппарата, основанный на выделении ключевых точек на спутниковой подложке и изображениях с бортовой камеры с помощью нейросетевого детектора и дальнейшим сопоставлением облаков точек с решением задачи PnP. В качестве детектора ключевых точек предложена архитектура архитектуры U-Net, обучаемая на смешанном датасете данных спутниковой и бортовой съемки с вероятностным пространственным распределением значений пикселей масок на основе нормализованных гауссиан, параметризуемых размерами окружности, описывающей область ключевой точки на изображении. Рассмотрены вопросы подготовки датасета и показаны примеры результатов работы нейросетевого детектора перекрестков и алгоритма сопоставления ключевых точек.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Степанов О.А., Носов А.С. Алгоритм коррекции навигационной системы по данным карты и измерителя, не требующий предварительного оценивания значений поля вдоль пройденной траектории // Гироскопия и навигация. – 2020. – Т. 28, № 2 (109). – С. 70-90.
2. Scaramuzza D., Fraundorfer F. Visual Odometry [A Survey] // IEEE Robotics and Automation Magazine. – 2011.
3. Reichenbach M., Damker H., Federrath H., and Rannenber K. Individual Management of Personal Reachability in Mobile Communication // Proc. of the 13th International Information Security Conference, Copenhagen, Denmark, May 1997. – P. 164-174.
4. Lowe D.G. Distinctive image features from scale invariant keypoints // International journal of computer vision. – 2004. – 60 (2). – P. 91-110.
5. Bay H., Ess A., Tuytelaars T., and Van Gool L. Speeded-up robust features (SURF) // Computer vision and image understanding. – 2008. – 110 (3). – P. 346-359.
6. Cadena C., Carlone L., Carrillo H., Latif Y., Scaramuzza D., Neira J., Reid I.D., Leonard J.J. Simultaneous Localization and Mapping: Present, Future, and the Robust-Perception Age // IEEE Transactions on Robotics (cond. Accepted). – 2016.
7. Ghouaiel N. and Lefevre S. Coupling ground-level panoramas and aerial imagery for change detection // Geo-spatial Information Science. – 2016. – 19 (3). – P. 222-232.
8. Shukla P., Goel S., Singh P., and Lohani B. Automatic geolocation of targets tracked by aerial imaging platforms using satellite imagery // The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences. – 2014. – 40 (1):381.

9. *Dunegan E.D., Luecke T.E.* Strapdown Inertial Navigation System Developments // Proceedings of the AIAA Guidance and Control Conference. – 1965.
10. *LeCun Y., Bottou L., Bengio Y., u Haffner P.* Gradient-based learning applied to document recognition // Proceedings of the IEEE. – 1998. – Vol. 86, No. 11. – P. 2278-2324.
11. *Krizhevsky A., Sutskever I., and Hinton G.E.* ImageNet Classification with Deep Convolutional Neural Networks // Advances in Neural Information Processing Systems. – 2012. – Vol. 25.
12. *Simonyan K. u Zisserman A.* Very Deep Convolutional Networks for Large-Scale Image Recognition // arXiv preprint arXiv:1409.1556. – 2015.
13. *He K., Zhang X., Ren S., u Sun J.* Deep Residual Learning for Image Recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 770-778.
14. *Kendall A., Grimes M., Cipolla R.* PoseNet: A Convolutional Network for Real-Time 6-DOF Camera Relocalization // Proceedings of the IEEE International Conference on Computer Vision (ICCV). – 2015.
15. *Dosovitskiy A., Beyer L., Kolesnikov A. et al.* An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale // arXiv preprint. – 2020.
16. *Arandjelović R., Gronat P., Torii A., Pajdla T., & Sivic J.* NetVLAD: CNN architecture for weakly supervised place recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 5297-5307.
17. *Ronneberger O., Fischer P., Brox T.* U-Net: Convolutional Networks for Biomedical Image Segmentation / In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) // Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science. – Vol. 9351. – Springer, Cham, 2015. – https://doi.org/10.1007/978-3-319-24574-4_28.
18. *Ulmas Priit & Liiv Innar.* (2020). Segmentation of Satellite Imagery using U-Net Models for Land Cover Classification // 10.48550/arXiv.2003.02899.
19. *Yadavendra S., Chand S.* Semantic segmentation and detection of satellite objects using U-Net model of deep learning // Multimed Tools Appl. – 2022. – 81. – P. 44291-44310. – <https://doi.org/10.1007/s11042-022-12892-2>.
20. *Eric Marchand, Hideaki Uchiyama, and Fabien Spindler.* Pose Estimation for Augmented Reality: A Hands-On Survey // IEEE Transactions on Visualization and Computer Graphics. – December 2016. – 22 (12). – P. 2633-2651.
21. *Martin A. Fischler and Robert C. Bolles.* Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography (англ.) // Comm. of the ACM: journal. – 1981. – June (Vol. 24). – P. 381-395. – doi: 10.1145/358669.358692.

REFERENCES

1. *Stepanov O.A., Nosov A.S.* Algoritm korrleksii navigatsionnoy sistemy po dannym karty i izmeritelya, ne trebuyushchiy predvaritel'nogo otsenivaniya znacheniy polya vdol' proydennoy traektorii [Algorithm for correcting a navigation system based on map and meter data that does not require preliminary estimation of field values along the trajectory], *Giroskopiya i navigatsiya* [Gyroscopy and Navigation], 2020, Vol. 28, No. 2 (109), pp. 70-90.
2. *Scaramuzza D., Fraundorfer F.* Visual Odometry [A Survey], *IEEE Robotics and Automation Magazine*, 2011.
3. *Reichenbach M., Damker H., Federrath H., and Rannenber K.* Individual management of personal reachability in mobile communication, *Proc. of the 13th International Information Security Conference, Copenhagen, Denmark, May 1997*, pp. 164-174.
4. *Lowe D.G.* Distinctive image features from scale invariant keypoints, *International journal of computer vision*, 2004, 60 (2), pp. 91-110.
5. *Bay H., Ess A., Tuytelaars T., and Van Gool L.* Speeded-up robust features (SURF), *Computer vision and image understanding*, 2008, 110 (3), pp. 346-359.
6. *Cadena C., Carlone L., Carrillo H., Latif Y., Scaramuzza D., Neira J., Reid I.D., Leonard J.J.* Simultaneous Localization and Mapping: Present, Future, and the Robust-Perception Age, *IEEE Transactions on Robotics (cond. Accepted)*, 2016.
7. *Ghouaiel N. and Lefevre S.* Coupling ground-level panoramas and aerial imagery for change detection, *Geo-spatial Information Science*, 2016, 19 (3), pp. 222-232.
8. *Shukla P., Goel S., Singh P., and Lohani B.* Automatic geolocation of targets tracked by aerial imaging platforms using satellite imagery, *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2014, 40 (1):381.
9. *Dunegan E.D., Luecke T.E.* Strapdown Inertial Navigation System Developments, *Proceedings of the AIAA Guidance and Control Conference*, 1965.
10. *LeCun Y., Bottou L., Bengio Y., u Haffner P.* Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 1998, Vol. 86, No. 11, pp. 2278-2324.

11. Krizhevsky A., Sutskever I., and Hinton G.E. ImageNet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems*, 2012, Vol. 25.
12. Simonyan K. u Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition, *arXiv preprint arXiv:1409.1556*, 2015.
13. He K., Zhang X., Ren S., u Sun J. Deep Residual Learning for Image Recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770-778.
14. Kendall A., Grimes M., Cipolla R. PoseNet: A Convolutional Network for Real-Time 6-DOF Camera Relocalization, *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2015.
15. Dosovitskiy A., Beyer L., Kolesnikov A. et al. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale, *arXiv preprint*, 2020.
16. Arandjelović R., Gronat P., Torii A., Pajdla T., & Sivic J. NetVLAD: CNN architecture for weakly supervised place recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 5297-5307.
17. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation / In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science*, Vol. 9351. Springer, Cham, 2015. Available at: https://doi.org/10.1007/978-3-319-24574-4_28.
18. Ulmas Priit & Liiv Innar. (2020). Segmentation of Satellite Imagery using U-Net Models for Land Cover Classification, *10.48550/arXiv.2003.02899*.
19. Yadavendra S., Chand S. Semantic segmentation and detection of satellite objects using U-Net model of deep learning, *Multimed Tools Appl.*, 2022, 81, pp. 44291-44310. Available at: <https://doi.org/10.1007/s11042-022-12892-2>.
20. Eric Marchand, Hideaki Uchiyama, and Fabien Spindler. Pose Estimation for Augmented Reality: A Hands-On Survey, *IEEE Transactions on Visualization and Computer Graphics*, December 2016, 22 (12), pp. 2633-2651.
21. Martin A. Fischler and Robert C. Bolles. Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography, *Comm. of the ACM: journal*, 1981, June (Vol. 24), pp. 381-395. doi: 10.1145/358669.358692.

Будко Артем Юрьевич – Южный федеральный университет; e-mail: abudko@sfedu.ru; г. Таганрог, Россия; тел.: +78634371694; с.н.с. НИИ РИПУ; доцент.

Гайда Татьяна Александровна – Южный федеральный университет; e-mail: gaidatat@mail.ru; г. Таганрог, Россия; инженер.

Понимаш Захар Алексеевич – Южный федеральный университет; e-mail: ponimashz@mail.ru; г. Таганрог, Россия; тел.: +79885464739; аспирант; генеральный директор ООО «ФракталТех».

Budko Artem Yuryevich – Southern Federal University; e-mail: abudko@sfedu.ru; Taganrog, Russia; senior researcher.

Gaida Tatyana Aleksandrovna – Southern Federal University; e-mail: gaidatat@mail.ru; Taganrog, Russia; engineer.

Ponimash Zahar Alekseevich – Southern Federal University; e-mail: ponimashz@mail.ru; Taganrog, Russia; phone: +79885464739; graduate student; general director of FractalTech LLC.

УДК 621.396

DOI 10.18522/2311-3103-2026-1-86-96

М.В. Грачев, Ю.Н. Паршин

ПРОПУСКНАЯ СПОСОБНОСТЬ МОБИЛЬНОЙ ММО СИСТЕМЫ ПЕРЕДАЧИ ИНФОРМАЦИИ В НЕОДНОРОДНОЙ СРЕДЕ

Рассматривается излучение и прием электромагнитной волны в сплошной неоднородной среде подвижным источником и приемником. На основе лучевой теории проведен расчет коэффициента передачи сигнала от источника к приемнику в зависимости от их положения в пространстве и параметров неоднородности среды. Совокупность коэффициентов передачи для нескольких передающих и приемных пунктов составляет матрицу канальных коэффициентов ММО системы передачи информации. Проведен спектральный анализ канальных коэффициентов в зависимости от параметров движения передающих и приемных пунктов. Установлено отличие спектра