

А. П. ТАНЧЕНКО, А. М. ФЕДУЛИН, Р. Р. БИКМАЕВ, Р. Н. САДЕКОВ

АЛГОРИТМ АВТОНОМНОЙ КОРРЕКЦИИ НАВИГАЦИОННОЙ СИСТЕМЫ БЕСПИЛОТНОГО ЛЕТАТЕЛЬНОГО АППАРАТА НА ОСНОВЕ РАСПОЗНАВАНИЯ ДОРОЖНОЙ И РЕЧНОЙ СЕТИ

Рассматривается оригинальный алгоритм автономной коррекции навигационной системы БПЛА, основанный на сопоставлении изображений местности, снятых с борта системой технического зрения и представляемых векторной топографической картой. Сопоставление осуществляется путем вычисления гомографии изображений системы технического зрения, сегментированных с применением сверточной нейронной сети, и векторной карты. Приводятся результаты математического и летного экспериментов, подтверждающие эффективность использования предложенного алгоритма для навигационных приложений.

Ключевые слова: беспилотный летательный аппарат, коррекция по карте местности, нейронная сеть, сегментация изображения, сопоставление векторной и растровой карты, система технического зрения.

Введение

В основе систем навигации современных БПЛА лежит комплексирование информации глобальных спутниковых систем (ГНСС) и бесплатформенных инерциальных навигационных систем (БИНС) [1]. Кратковременное пропадание сигналов ГНСС в таком случае компенсируется работой БИНС. При восстановлении сигнала ГНСС появляется возможность скорректировать БИНС для устранения накопленной за время автономной работы погрешности. При полетах по заранее известной территории стабильность работы ГНСС повышается за счет установки на маршруте наземных станций, выступающих в роли псевдоспутников [2]. В случае полетов по произвольным маршрутам на значительные расстояния периодическая коррекция БИНС выполняется с использованием методов автономного определения координат.

К таковым относится, в частности, распознавание на изображениях, получаемых с использованием систем технического зрения БПЛА, ориентиров (неизменных во времени топографических объектов с известными координатами) и сравнении их с базой данных объектов. Ориентиры могут быть как точечными, так и линейными [3]. Названный подход требует проведения предварительных работ по выявлению и геодезической привязке таких ориентиров для каждого района полетов.

Танченко Александр Петрович. Кандидат физико-математических наук, ведущий инженер-программист, АО «КТ Беспилотные системы» (С.-Петербург).

Федулин Андрей Михайлович. Директор центра разработки, АО «КТ Беспилотные системы».

Бикмаев Рамиль Равильевич. Начальник отдела специального программного обеспечения Управления навигационно-геодезических систем, МОУ «Институт инженерной физики» (Серпухов, Московская обл.).

Садеков Ринат Наилевич. Доктор технических наук, начальник научно-исследовательского отдела, Военный инновационный технополис «ЭРА» (Анапа); профессор, доцент, НИТУ «МИСиС» (Москва).

Другая большая группа методов основана на сопоставлении автономно измеряемых на борту БПЛА геофизических параметров с предварительно записанными в память значениями аналогичных параметров, образующих навигационное поле. Построенные по такому принципу навигационные системы называются корреляционно-экстремальными (КЭНС), они могут работать с различными полями: рельефа, гравитационными, магнитными, оптическими и др. [4, 5, 6]. В качестве сенсоров обычно используются высотомеры, гравиметры, магнитометры, видеокамеры, радиолокаторы. Общими недостатками КЭНС являются зависимость алгоритма сопоставления от градиента поля и сложность подготовки эталонных баз данных. Наиболее значимые результаты были получены при создании КЭНС, основанных на сравнении полей оптического контраста. В настоящее время это наиболее перспективное направление исследований в области навигации БПЛА.

В связи с этим в работе описываются алгоритмы коррекции навигационной системы БПЛА на основе анализа оптических изображений, формируемых системой технического зрения, и данных цифровых векторных карт, выступающих в качестве эталона.

Анализ существующих работ

Развитие технологий дистанционного зондирования Земли позволяет получать снимки высокого разрешения практически для любой точки земного шара, поэтому наибольшей популярностью стала пользоваться группа методов, основанных на сравнении изображения местности, снятого с БПЛА в надири, с эталонными спутниковыми снимками, заранее загруженными в бортовую память. Так, в [7, 8] описаны методы, в основу которых положен расчет кросс-корреляции. В [9] сравнение изображений осуществляется посредством компьютерного зрения, а в [10] – с дополнительной оценкой относительного перемещения БПЛА на базе визуальной одометрии. Анализ представленных работ показывает, что в реальности возможно сопоставить только снимки, не имеющие значительных различий; в результате на практике данные методы становятся неустойчивыми, особенно в условиях плотной городской застройки, когда спутниковые снимки быстро устаревают. Кроме того, полеты на значительные расстояния требуют хранения на борту больших объемов эталонных спутниковых данных (изображений), измеряемых терабайтами.

Отдельно следует отметить группу методов, основанных на сопоставлении изображений местности, снятых с фронтальной (горизонтальной) камеры БПЛА с небольшой высоты, и фотоснимков, выполненных с земли. В качестве эталонных данных могут использоваться геопривязанные фотоснимки Google street view [11]. Поиск соответствия производится на основе сравнения дескрипторов изображений [12, 13, 14] или областей, определяемых нейронными сетями [15, 16], а также на основе комбинированных методов [17]. Разработанные алгоритмы могут учитывать специфику местности: горная [18], плотная городская застройка [19]. Эти методы являются вычислительно трудоемкими и требуют доступа к огромной базе изображений. Их реализация пока невозможна даже на самых мощных из современных бортовых вычислителей.

Методы одновременной локализации и картографирования (SLAM) также нашли широкое применение в автономной навигации БПЛА, их суть заключается в динамическом формировании карты окружающего пространства для последующего ис-

пользования ее в качестве эталона. В качестве детекторов точек выступают алгоритмы SIFT [20] или SURF [21], которые позволяют найти аффинные преобразования между изображениями [13, 22]. При оценке положения БПЛА применяется также глубокое обучение [23]. SLAM эффективен при многократном пролете над одной местностью. На практике это потребует значительного предварительного облета одних и тех же районов.

Появившиеся к настоящему моменту публичные картографические сервисы, такие как Open Street Maps, позволяют получить векторную карту местности на любой район, которая по объему гораздо меньше спутниковых снимков.

В предлагаемой работе описан алгоритм коррекции навигационной системы, использующий технологии глубокого обучения и фотограмметрической обработки. В отличие от других известных алгоритмов он содержит этап сегментации изображений местности на топографические слои дорожной и гидрографической сети, хорошо распознаваемые в широком спектре условий аэросъемки.

В первом разделе статьи осуществляется постановка задачи и описывается алгоритм ее решения, далее раскрываются вопросы обучения нейросети, используемой для сегментации векторной карты. В заключительной части приводятся результаты математического моделирования и натурального эксперимента, даются рекомендации по применению предложенного подхода на практике.

Постановка задачи и алгоритм ее решения

Математическая постановка задачи: по оптическому изображению местности I_t с разрешением $W \times H$, снятому в наadir (вертикально вниз за счет применения гиросtabilизированной платформы) с БПЛА в момент времени t , необходимо определить истинные географические координаты БПЛА B_U , L_U и его курс C_U . В качестве эталона используется векторная топографическая цифровая карта со слоями дорожной и гидрографической сети (см. рис. 1).




Рис. 1. Общая схема работы КЭНС на основе цифровой карты

Предложенный алгоритм представлен на рис. 2. Из рисунка видно, что входной информацией алгоритма является оптическое изображение, формируемое системой

технического зрения (СТЗ), установленной на гиросtabilизированной платформе, а выходной – координаты БПЛА, полученные на основе анализа снимка.

Шаг №1 «Получение исходного изображения». На данном этапе происходит загрузка исходного изображения I_t .

Шаг №2 «Сегментация изображения». Заключается в том, что на изображении выделяется дорожный и гидрографический слой. На выходе сети формируется черно-белое изображение S_t , на котором белым цветом отмечены пиксели дороги или реки, а черным – остальной фон.

Сегментация выполняется с использованием нейросетей [24]. Применяемая модель строится на базе сверточной нейронной сети U-Net, которая широко применяется для сегментации биомедицинских изображений [25]. Ключевой особенностью U-Net по сравнению с другими аналогичным образом применяемыми сетями является небольшое количество коэффициентов, подлежащих оптимизации при обучении [26].

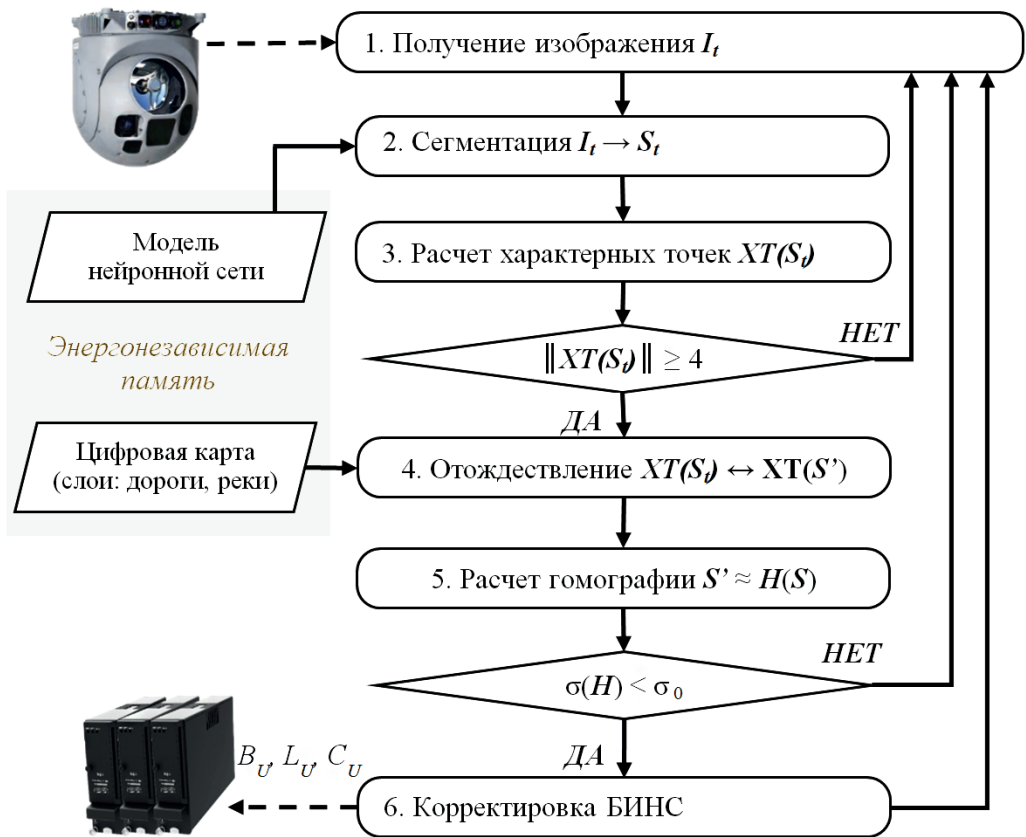


Рис. 2. Блок-схема алгоритма

Приведенная на рис. 3 архитектура данной сети очертаниями напоминает букву U, за счет чего сеть и получила свое название. Изображение каждого прямоугольника на рисунке сформировано по результатам выполнения математических операций. Количество каналов (слоев) изображения указано сверху над прямоугольником, а размерность – слева от него. Цветными стрелками обозначены различные типовые операции.




Рис. 3. Графическая схема сети U-Net

Сеть обучена методом стохастического градиентного спуска на основе входных данных изображений и соответствующих им сегментированных карт. Разметка выборки для обучения состоит в формировании для каждого изображения маски, значение ячейки которой равно единице, если соответствующий пиксель исходного изображения относится к дороге, или нулю, если нет.

Для определения схожести эталонной P^1 и выходной P^2 масок используется функция бинарной перекрестной энтропии E , которая рассчитывается по формуле

$$E(P^1, P^2) = -\sum_{i=1}^W \sum_{j=1}^H P_{ij}^1 \log(P_{ij}^2).$$

При полном совпадении двух масок $E(P^1, P^2) = 0$, а по мере уменьшения их схожести (корреляции) возрастает значение функции $E(P^1, P^2)$. Процесс обучения сводится к минимизации E между эталонными классами и гипотезами модели.

Шаг №3 «Расчет характерных точек». Производится на сегментированном изображении с использованием метода Scale Invariant Feature Transform (SIFT) [27], выделяющего характерные точки (ХТ), т.е. точки изображения, которые находятся указанным выше способом, описываются с помощью 128-мерного вектора (дескриптора) и устойчивы к относительному повороту и масштабированию. Локальные координаты ХТ – это смещения в пикселях относительно центра изображения (точки визирования системы технического зрения) с координатами (0,0). Линия визирования – ось оптической системы технического зрения. Оси выбраны таким образом, чтобы курс БПЛА был сонаправлен с осью ординат.

Аналогичные процедуры выполняются и с цифровой картой (на этапе предобработки). Локальные координаты ХТ – это смещения в пикселях относительно точки привязки карты (центр карты или левый нижний угол), географические координаты

которой известны. Таким образом, выходными данными этого шага алгоритма является набор ХТ и их дескрипторов.

Шаг №4 «Отождествление точек». Процедура выполняется методом полного перебора. Для каждой ХТ сегментированного изображения путем сравнения дескрипторов находится ближайшая к ней ХТ на сегментированной карте.

Выходом алгоритма является набор точек

$$P\{p_i = (u_p, v_p, x_p, y_p)\},$$

где $i = 1..M$, (u_p, v_p) – локальные координаты ХТ на сегментированном изображении, а (x_p, y_p) – локальные координаты ближайшей по дескриптору ХТ на сегментированной карте.

Шаг №5 «Расчет гомографии». Находится матрица перспективной трансформации (гомографии) $HP_{uv} \rightarrow P_{xy}$ между парами ХТ, отождествленными на предыдущем шаге:

$$\begin{bmatrix} x_i \\ y_i \\ 1 \end{bmatrix} \approx H \begin{bmatrix} u_i \\ v_i \\ 1 \end{bmatrix}, \quad H = \begin{bmatrix} r_{11} & r_{12} & d_1 \\ r_{21} & r_{22} & d_2 \\ p_1 & p_2 & 1 \end{bmatrix},$$

где r_{11}, r_{22} – параметры, отвечающие за масштабирование по осям x и y соответственно; r_{12}, r_{21} – сдвиг по осям (влияют на поворот); d_1, d_2 – смещение по осям; p_1, p_2 – изменение перспективы.

Расчет матрицы выполняется с использованием алгоритма RANSAC [28], выбор которого обусловлен эффективностью фильтрации выбросов (ошибочно отождествленных ХТ). Теоретически для расчета H достаточно иметь лишь четыре сопоставленные точки, но на практике с учетом выбросов число точек обычно выбирается от 6 до 10.

В процессе работы алгоритма минимизируется величина σ (пиксели):

$$\sigma(H) = \sqrt{\frac{1}{K} \sum_{k=1}^K \left[\begin{bmatrix} x_{i_k} \\ y_{i_k} \\ 1 \end{bmatrix} - H \begin{bmatrix} u_{i_k} \\ v_{i_k} \\ 1 \end{bmatrix} \right]^2},$$

где i_k – номера корректных ХТ, K – количество корректных ХТ, \vec{v} – евклидова норма.

Шаг №6 «Корректировка показаний БИНС». С помощью полученной матрицы H легко установить локальные координаты точки визирования и курс БПЛА на сегментированной карте:

$$\overline{POS} = H \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}, \quad \overline{DIR} = H \begin{bmatrix} 0 \\ 1 \\ 1 \end{bmatrix} - H \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}.$$

Зная локальные координаты точки визирования на географически привязанной сегментированной карте, можно рассчитать и географические координаты точки визирования B_U, L_U (в предположении, что точка размещения СТЗ совпадает с точкой размещения БИНС) и курс БПЛА C_U .

Для принятия решения о корректировке параметров БИНС по полученным данным используется значение $\sigma(H)$, которое для положительного решения должно быть меньше заданного порога σ_0 .

Ниже с помощью математического моделирования и летных натурных данных будет показана корреляция между $\sigma(H)$ и точностью вычисления координат точки визирования.

Реализация алгоритма и обучение нейронной сети

Описанный выше алгоритм был реализован в виде программы для ЭВМ. Используемые при этом библиотека PyTorch для выполнения шага №2 и функции OpenCV для выполнения шагов №3–5 позволили распараллелить операции на вычислителе для встраиваемых систем nVidia Jetson и тем самым поддержать аппаратное ускорение. В перспективе это обеспечит функционирование программы на российской элементной базе с вычислительной производительностью до 512 ГФлопс и работу алгоритма с частотой не менее 30 Гц.

Обучение нейронной сети «с учителем» производилось по двум классам изображений: рек и дорог. Для этого были размечены вручную 100 изображений с типичным европейским ландшафтом. Из них путем различных геометрических и цветовых трансформаций было сгенерировано более 100 000 изображений, 70% из которых использовались в качестве обучающей выборки, а 30% – в качестве проверочной. Цикл обучения состоит в оптимизации среднеквадратического значения функции ошибки на обучающей выборке.

Обучение проводилось на ЭВМ с процессором Intel Core i7-6800K 3,4 ГГц, 32 Гб оперативной памяти, накопителем SSD 2Тб и видеокартой GeForce GTX TITAN X, оснащенной 12 Гб видеопамяти. Всего было проведено 500 циклов обучения, длительность каждого из них составила порядка 10 мин. После каждого полного цикла обучения вычислялись среднеквадратичные значения функции ошибки на обучающей и проверочной выборках, которые приведены на графике (см. рис. 4). Оптимальное количество эпох, когда дальнейшая оптимизация функции ошибки на обучающей выборке уже не изменяет существенным образом функцию потерь на проверочной, составляет порядка 300.

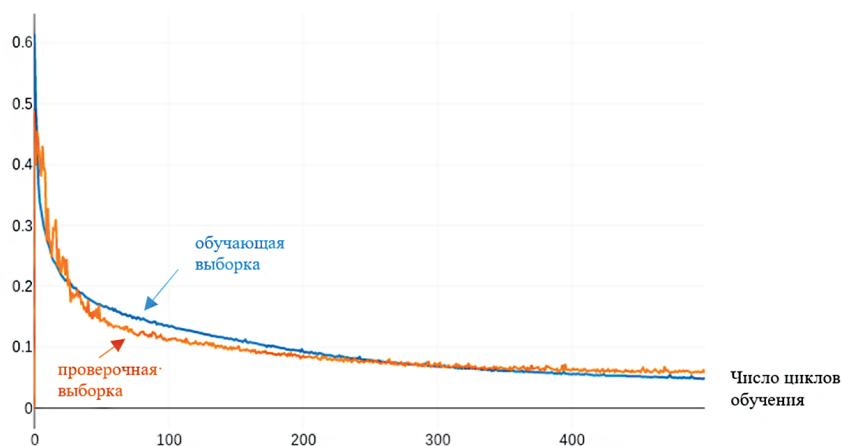


Рис. 4. График функции ошибки на обучающей и проверочной выборках

Оценка точности алгоритма

Для оценки точности работы алгоритма было проведено математическое моделирование, при этом использовались данные векторной и растровой карты г. Лион (Франция) размером $\sim 10 \times 10$ км (в масштабе 1.193 м на пиксель), загруженных с публичного сервиса [29]. Полученные векторные данные применялись в качестве эталонной цифровой карты, а растровые – в качестве изображения, поступающего от камеры БПЛА.

В эксперименте для каждого пикселя растровой карты «вырезался» окружающий его фрагмент размером 512×512 пикселей. Затем на полученном изображении с помощью разработанного программного модуля производился расчет географических координат центра визирования и величины $\sigma(H)$. Поскольку координаты растровой карты в данном эксперименте известны, далее вычислялось отклонение координат, рассчитанных в соответствии с алгоритмом, от истинных.




Рис. 5. Тепловые карты $\sigma(H)$ (а) и их корреляции с точностью (б)

Результаты эксперимента представлены в виде двух тепловых карт. На одной из них (см. рис. 6, а) поверх эталонной векторной карты для каждого пикселя нанесено значение $\sigma(H)$, где $\sigma(H) = 0$ соответствует белый цвет, а $\sigma(H) = 100$ – красный. Из рисунка видно, что зоны с высоким значением $\sigma(H)$ соответствуют преимущественно районам с низкой плотностью рек и дорог. На другой тепловой карте (см. рис. 6, б) представлена корреляция между значением $\sigma(H)$ и отклонением рассчитанных координат от истинных. Белый цвет соответствует высокой степени корреляции. Из рисунка видно, что изображение на 70% белое, что свидетельствует о высокой степени корреляции указанных величин. Результаты подтверждают возможность использования $\sigma(H)$ в полете для оценки потенциальной точности вычисляемых алгоритмом координат.

Летный эксперимент проводился с использованием комплекса воздушной разведки «Орион-Э» с БПЛА, имеющим большую продолжительность полета. Технические характеристики его навигационной и оптико-электронной систем приведены в рекламном паспорте [30]. Время эксперимента составило 150 с, высота съемки – 3000 м, длина участка – порядка 7 км. Было получено 55 изображений местности разрешением 1600×900 пикселей каждое.

На рис. 6 приведены исходное изображение местности и результат его сегментации с применением обученной нейронной сети.




Рис. 6. Входное (а) и сегментированное (б) изображения

Для оценки точности были использованы координаты, вычисляемые штатной навигационной системой БПЛА.

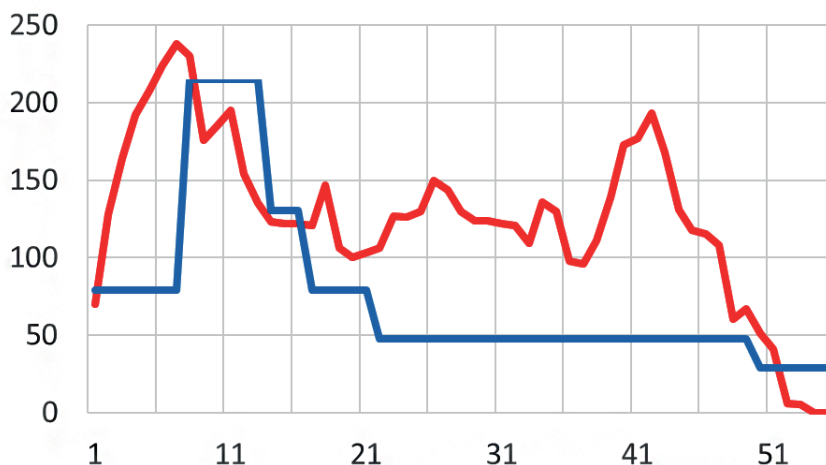


Рис. 7. Покадровый график $\sigma(H)$ (синий) и погрешностей координат (красный), м

На рис. 7 для каждого кадра приведены полученные графики отклонения координат (кривая красного цвета) и рассчитанное значение $\sigma(H)$ (кривая синего цвета) в метрах. Видно, что графики коррелированы, отсутствие второго максимума на синей кривой может быть связано с погрешностями вычисления местоположения БПЛА навигационной системой.

Заключение

В работе предложен оригинальный алгоритм коррекции автономной навигационной системы БПЛА, основанный на комбинации широко применяемых методов обработки изображений и нейросетевых моделей. В состав алгоритма не входит предполетная подготовка данных, в чем заключается его основное преимущество. Рассмотренный подход достаточно прост, не требует высоких затрат, легко внедряется, при этом обеспечивает навигацию БПЛА в условиях полного отсутствия сигнала GPS и четко выраженных объектов местности (домов, промышленных сооружений и др.).

Проведенные эксперименты по апробации алгоритма на заимствованных и натурных летных данных показали возможность определения координат с погрешностью ~100 м и подтвердили возможность использования среднеквадратического отклонения, получаемого при расчете гомографии, как критерия оценки точности алгоритма.

В настоящий момент проводятся дальнейшие исследования по усовершенствованию предложенного алгоритма в части подбора инвариантных к сезонным изменениям топографических слоев. Кроме того, исследуется возможность применения алгоритма в различных условиях освещенности, в том числе в ночное время с использованием изображений, получаемых в инфракрасном диапазоне волн.

ЛИТЕРАТУРА

1. Шмидт Дж.Т. Эксплуатация навигационных систем на основе GPS в сложных условиях окружающей среды // Гироскопия и навигация. 2019. Т. 27. № 1 (104). С. 3–21. DOI: 10.17285/0869-7035.2019.27.1.003-021.
2. Емельянец Г.И., Степанов А.П., Блажнов Б.А. О решении навигационной задачи для летательных аппаратов с использованием инерциального модуля на микромеханических датчиках и наземных радиориентиров // Гироскопия и навигация. 2017. Т. 25. № 1 (96). С. 3–17. DOI: 10.17285/0869-7035.2017.25.1.003-017.
3. Chigin, G.P., Use of a field of linear reference points in problems of extremal navigation, *Journal of computer and systems sciences international*, 1998, vol. 37, no. 2, pp. 318–328.
4. Джанджгава Г.И., Августов Л.И. Навигация по геополям. М.: Научтехлитиздат, 2018. 296 с.
5. Пешехонов В.Г., Степанов О.А. и др. Современные методы и средства измерения параметров гравитационного поля земли / Под общей ред. В.Г. Пешехонова; науч. редактор О.А. Степанов. СПб., 2017.
6. Дюр К., Шольц Г., Троммер Г.Ф. SLAM-алгоритм на основе лазерных измерений при использовании микролетательных аппаратов в помещении // Гироскопия и навигация. 2017. Т. 25. № 1 (96). С. 18–32. DOI: 10.17285/0869-7035.2017.25.1.018-032.
7. Conte, G. and Doherty, P., Vision-based unmanned aerial vehicle navigation using geo-referenced information, *EURASIP Journal on Advances in Signal Processing*, 2009:10, 2009.
8. Yol, A., Delabarre, B., Dame, A., Dartois, J.-E., and Marchand, E., Vision-based absolute localization for unmanned aerial vehicles, *Intelligent Robots and Systems (IROS 2014)*, 2014 *IEEE/RSJ International Conference on*, 2014, pp. 3429–3434.
9. Fan, B., Du, Y., Zhu, L., and Tang, Y., The registration of UAV down-looking aerial images to satellite images with image entropy and edges, *Intelligent Robotics and Applications*, 2010, pp. 609–617.
10. Sim, D.-G., Park, R.-H., Kim, R.-C., Lee, S.U., and Kim, I.-C., Integrated position estimation using aerial image sequences, *IEEE transactions on pattern analysis and machine intelligence*, 2002, 24(1):1–18.
11. Majdik, A.L., Verda, D., Albers-Schoenberg, Y., and Scaramuzza, D., Air-ground matching: Appearance-based GPS-denied urban localization of micro aerial vehicles, *Journal of Field Robotics*, 2015, 32(7):1015–1039.
12. Majdik, A.L., Albers-Schoenberg, Y., and Scaramuzza, D., MAV urban localization from google street view data. In *Intelligent Robots and Systems (IROS)*, 2013 *IEEE/RSJ International Conference on*, 2013, pp. 3979–3986.
13. Ghouaïel, N. and Lefevre, S., Coupling ground-level panoramas and aerial imagery for change detection, *Geo-spatial Information Science*, 2016, 19(3):222–232.
14. Viswanathan, A., Pires, B.R., and Huber, D., Vision based robot localization by ground to satellite matching in gps-denied situations. In *Intelligent Robots and Systems (IROS 2014)*, 2014 *IEEE/RSJ International Conference on*, 2014, pp. 192–198.
15. Workman, S., Souvenir, R., and Jacobs, N., Wide-area image geolocalization with aerial reference imagery, *Proceedings of the IEEE International Conference on Computer Vision*, 2015, pp. 3961–3969.
16. Zhai, M., Bessinger, Z., Workman, S., and Jacobs, N., Predicting ground-level scene layout from aerial imagery, 2016, *arXiv preprint arXiv:1612.02709*.

17. Lefevre, S., Tuia, D., Wegner, J.D., Produit, T., and Nassar, A.S., Toward seamless multiview scene analysis from satellite to street level, *Proceedings of the IEEE*, 2017.
18. Saurer, O., Baatz, G., Koser, K., Pollefeys, M. et al., Image based geo-localization in the alps, *International Journal of Computer Vision*, 2016, 116(3):213–225.
19. Tian, Y., Chen, C., and Shah, M., Cross-view image matching for geo-localization in urban environments, *arXiv preprint arXiv:1703.07815*, 2017.
20. Lowe, D.G., Distinctive image features from scale invariant keypoints, *International journal of computer vision*, 2004, 60(2): 91–110.
21. Bay, H., Ess, A., Tuytelaars, T., and Van Gool, L., Speeded-up robust features (SURF), *Computer vision and image understanding*, 2008, 110(3):346–359.
22. 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.
23. Muller, M., Urban, S., and Jutzi, B., Squeezeposenet: Image based pose regression with small convolutional neural networks for real time UAS navigation, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2017, 4:49.
24. Buslaev, A., Seferbekov, S., Iglovikov, V., and Shvets, A., Fully Convolutional Network for Automatic Road Extraction from Satellite Imagery, *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2018, pp. 207–210.
25. Ronneberger, O., Fischer, P., Brox, T., U-Net: Convolutional Networks for Biomedical Image Segmentation, *MICCAI 2015. Lecture Notes in Computer Science*, vol. 9351, Springer, Cham.
26. Ciresan, D.C., Gambardella, L.M., Giusti, A., Schmidhuber, J., Deep neural networks segment neuronal membranes in electron microscopy images, *NIPS*, 2012, pp. 2852–2860.
27. Lowe, D.G., Distinctive Image Features from Scale-Invariant Keypoints, *International Journal of Computer Vision*, 2004, vol. 60, issue 2, pp. 91–110. DOI:10.1023/B:VISI.0000029664.99615.94.
28. Fischler, M.A., and Bolles, R.C., Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography, *Comm. ACM*, 1981, 24 (6): 381–395. DOI:10.1145/358669.358692.
29. Data Grand Lyon. [Электронный ресурс]. URL: <https://rdata-grandlyon.readthedocs.io/en/latest/index.html> (дата обращения: 01.01.2020).
30. Рекламный паспорт №143\17\ЭП на Комплекс воздушной разведки с беспилотными летательными аппаратами большой продолжительности полета «Орион-Э».

Tanchenko, A.P. (KT Unmanned Systems, St. Petersburg, Russia), **Fedulin, A.M.** (KT Unmanned Systems), **Bikmaev, R.R.** (Institute of Engineering Physics, Serpukhov, Russia), and **Sadekov, R.N.** (ERA Military Innovation Technopolis, Anapa, Russia; National Institute of Science and Technology MISiS, Moscow, Russia) UAV Navigation System Autonomous Correction Algorithm Based on Road and River Network Recognition, *Giroskopiya i Navigatsiya*, 2020, vol. 28, no. 3 (110), pp. 32–42.

Abstract. The paper considers an original autonomous correction algorithm for UAV navigation system based on comparison between terrain images obtained by onboard machine vision system and vector topographic map images. Comparison is performed by calculating the homography of vision system images segmented using the convolutional neural network and the vector map images. The presented results of mathematical and flight experiments confirm the algorithm effectiveness for navigation applications.

Key words: unmanned aerial vehicle, ground map correction, neural network, image segmentation, vector and raster map comparison, machine vision system

Материал поступил 25.11.2019