

УДК 629.7.06

Белоцерковский В.А., ведущий инженер ЦПГО НГУ,
Малькович Е.Г., инженер института интеллектуальной робототехники,
Окунев А.Г., директор института интеллектуальной робототехники
г. Новосибирск

ПРИМЕНЕНИЕ КРАЕВЫХ-ВЫЧИСЛИТЕЛЕЙ ДЛЯ ЛОКАЛИЗАЦИИ БПЛА ПО ВИДЕОДАНЫМ.

Задача общего осмотра территории с помощью БПЛА часто встречается при проведении поисково-спасательных работ, в промышленности и сельском хозяйстве [1, 2]. Так МЧС применяет БПЛА самолетного типа для воздушного мониторинга зон ЧС таких как затопленные территории в случае наводнения, очаги пожара и др. В отличие от задачи аэрофотосъемки осмотр проходит по кольцевому маршруту и захватывает большие расстояния.

Для осуществления навигации и движения по заданной траектории используются различные GPS комплексы и системы, в том числе использующие относительную навигацию (режим RTK) [3]. При этом оборудование БПЛА, осуществляющее навигацию (как сервоприводы и системы автономного спасения - "САС") обеспечивает надежность комплекса БПЛА в целом. К нему предъявляются повышенные требования отказоустойчивости [4, 5]. Мы предлагаем программно-аппаратный комплекс, который может рассматриваться как дополнительный модуль, увеличивающий вероятность безотказной работы навигационного устройства.

Также данный модуль может быть применен в случае слабого или отсутствующего сигнала спутниковых навигационных системы NAVSTAR и ГЛОНАСС, а также помех в каналах управления летательным аппаратом и каналах передачи видеопотока.

Исследование решает задачу локализации БПЛА — т.е. определение его местоположения на местности. Суть подхода заключается в использовании предобученной нейронной сети, которая по изображению земной поверхности может определить местоположение БПЛА. Нейронная сеть использует классификацию изображений, чтобы выявить наиболее близкое изображение среди спутниковых снимков. Далее уточнение положения БПЛА выполняют с помощью поиска соответствий между ключевыми точками на снимке с камеры устройства и спутниковыми снимками. В данной работе представлены результаты первой части — анализ подхода с использованием только спутниковых снимков и тестирование алгоритма на краевых вычислителях с низким энергопотреблением.

Для решения задачи классификации существует большое число различных методов машинного обучения, включая искусственные нейронные сети (НС), машины опорных векторов и др. [6]. Применение свёрточных нейронных сетей является основным мировым трендом, поскольку их

использование обеспечивает наибольшую эффективность и точность при решении поставленной задачи. Преимуществом данного подхода является отсутствие необходимости выявления информативных признаков на изображении, так как в процессе обучения алгоритм выявляет признаки объекта и находит необходимые значения коэффициентов свертки самостоятельно [7].

С другой стороны, результат обучения нейросети сильно зависит от количества изображений в обучающей выборке. В общем случае, для получения высокой точности необходим большой объем выборки, насчитывающий десятки и сотни тысяч изображений. Обучающая выборка должна быть представительной как с точки зрения мест съемки (координаты съемки, высота, угол наклона камеры), освещения (зависит от погодных условий, времени суток), так и времён года. Часть изображений выборки может быть получена стандартными методами обогащения имеющихся данных (augmentation) [8], т. е. копированием с деформацией, а часть может быть получена с помощью компьютерного моделирования (синтетический набор данных).

В нашей работе мы использовали свёрточную нейросеть с архитектурой ResNet [9] и 527 выходами классификатора. Обучающая выборка составила 17000 изображений для тренировки и 2500 — для валидации. При этом точность составила 85% и 78% процента (оценка "топ-5" и "топ-3" соответственно) для ResNet-18, 95% и 90% для ResNet-50.

Для составления набора данных использовалось спутниковое изображение района города размером 1600x1600 пкс. Далее это изображение разбивалось на 625 квадратов размером 64x64 пкс, каждому из которых присваивался идентификационный номер от нуля до пятьсот двадцати семи (квадраты, расположенные по периметру, выбрасывались), он же являлся номером класса. Для повышения робастности нейронной сети использовали следующие типы преобразований изображений: сдвиг, поворот, масштабирование, размытие и изменение яркости.

Для определения угла поворота и коэффициента масштабирования использовалась матрица гомографии H [10]. Которая представляет собой преобразование между двумя плоскостями, с точностью до коэффициента масштабирования.

В общем виде алгоритм может быть описан следующим образом:

1 небольшой участок карты, случайным образом повернутый и масштабированный, подавался на вход нейросети.

2 сеть выдавала номера пяти лучших кандидатов, максимально похожих на переданное ей изображение.

3 для каждого изображения, включая входное, находились ключевые точки методом SIFT [11].

4 ключевые точки входного изображения сопоставлялись с точками кандидатов.

5 после нахождения соответствий, рассчитывалась матрица гомографии.

6 из матрицы гомографии находился угол поворота и коэффициент масштабирования входного изображения относительно исходного [12].

Следующим этапом после обучения сети и написания алгоритма "матчинга" стал перенос ResNet-18 на edge-устройство — ROC-RK3588S-PC. Достоинствами этого одноплатного компьютера являются низкая стоимость (порядка 150 \$), массогабаритные характеристики и производительность, характеристики устройства представлены в таблице 1. Для запуска алгоритма на устройстве обученная нейросеть была конвертирована в необходимый формат. Для увеличения скорости работы нейросети применялось квантование [13], то есть снижалась точность весов, смещений и активаций до 8-битных чисел. После этого обработка одного изображения в режиме инференса занимает в среднем 0,015 мс. Точность (топ 5) квантованной модели составила 91% и 81% для ResNet-50 и ResNet-18 соответственно.

Таким образом, в докладе предложен алгоритм нахождения местоположения БПЛА с использованием фотографии. Протестирована работа алгоритма на edge-устройстве, измерена точность и скорость работы. Несмотря на то, что данная система довольна критична к метеорологической обстановке, и имеет серьезные ограничения при плохих условиях видимости - осадки, туман, низкая граница облачности, представленный метод целесообразно развивать как альтернативный способ локализации БПЛА в дополнении к существующим радионавигационным методам.

Таблица 1. Спецификация устройства ROC-RK3588S-PC

Характеристика	Значение
Производительность	
Чип	RockChip RK3588S
Процессор	8-core 64-bit (4×Cortex-A76+4×Cortex-A55), частота 2.4GHz
Графика	ARM Mali-G610 MP4 quad-core GPU
Нейропроцессор	Мощность NPU до 6 TOPS
Оперативная память	4GB
Интерфейсы	
Интернет	1 × 1000Mbps
Камера	2 × 2 lane MIPI-CSI input
Питание	DC12V (DC5.5×2.1mm)
...	...
Основные характеристики	
Размер	90mm × 60mm
Вес	≈50g
Потребление	Режим ожидания: ≈ 0.42W (12V/35mA) Обычный: ≈2.25W (12V/190mA) Максимум: ≈12W (12V/1000mA)
Условия работы	Рабочая температура: -20°C ~ 60°C Влажность окр.ср.: -40% ~ 70 %

Список литературы:

1. Вашкевич Ю. В., Титов О. В. Опыт использования беспилотных летательных аппаратов при ликвидации чрезвычайных ситуаций. ГУО МЧС Республики Беларусь С. 36-37
2. Липатов В.Д., Кишалов А.Е. ПРИМЕНЕНИЕ БПЛА В ЗАДАЧАХ ПОДРАЗДЕЛЕНИЙ МЧС. Журнал Технические науки Молодежный Вестник УГАТУ № 1 (13). Май, 2015 г. С. 74-79.
3. Перов А.И., Харисов В.Н., ГЛОНАСС. Принципы построения и функционирования изд. 3-е, перераб. – М.:Радиотехника, 2005.
4. Житомирский Г.И. Конструкция самолетов. – 2-е издание. – М.: Машиностроение, 1995.
5. Интеллектуальные роботы: учебное пособие для вузов / под общей ред. Е. И. Юревича / И. А. Каляев, В.М. Лохин, И. М. Макаров и др. – М.: Машиностроение, 2010. – 360 с.
6. Szeliski R. Computer Vision: Algorithms and Applications, 812 p., Springer-Verlag London, 2011
7. J. Tsitsiklis, D. Bertsekas and M. Athans, Distributed asynchronous deterministic and stochastic gradient optimization algorithms, IEEE Trans. Autom. Control, vol. AC-31, no. 9, pp. 803-812, 1986
8. Luis P, Jason W. The effectiveness of data augmentation in image classification using deep learning. In: Stanford University research report, 2017.
9. He, Kaiming and Zhang, Xiangyu and Ren, Shaoqing and Sun, Jian, Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
10. Dubrofsky, E. Homography Estimation. Ph.D Thesis, University of British Columbia (Vancouver), Kelowna, BC, Canada, March 2009.
11. D. G. Lowe, Distinctive image features from scale-invariant keypoints, Int. J. Comput. Vis., vol. 60, no. 2, pp. 91-110, 2004.
12. Постников М.М. Аналитическая Геометрия. М., Наука, 1973.
13. Jiwei Yang, Xu Shen, Jun Xing, Xinmei Tian, Houqiang Li, Bing Deng, Jianqiang Huang, and Xian-sheng Hua. Quantization networks. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pages 7308–7316, 2019.

Информация об авторах:

Окунев Алексей Григорьевич, г. Новосибирск, ул. Пирогова, д. 1,
okunev73@mail.ru

Малькович Евгений Геннадьевич, г. Новосибирск, ул. Пирогова, д. 1,
e.malkovich@g.nsu.ru

Белоцерковский Валерий Александрович, г. Новосибирск, пр.
Лаврентьева, д. 6, bva@mer.ci.nsu.ru

