

11. Лебедев, В.Б. Генетический алгоритм глобальной трассировки на основе иерархических многохромосомных представлений [Текст] / В.Б. Лебедев, О.Б. Лебедев // Интеллектуальные системы. Коллективная монография / Под ред. В.М. Курейчика. – М.: Физматлит, 2009. С. 88-105.
12. Cho, M. BoxRouter: A new global router based on box expansion and progressive ILP [Текст] / M. Cho, D.Z Pan // *Proc. Des. Autom. Conf.*, 2006.
13. Kennedy, J. Particle swarm optimization [Text] / J. Kennedy, R.C. Eberhart // In Proceedings of IEEE International Conference on Neural Networks, 1995, pp. 1942–1948.
14. Карпенко, А.П. Современные алгоритмы поисковой оптимизации. Алгоритмы, вдохновленные природой: учебное пособие [Текст] / А.П. Карпенко // – М: Издательство МГТУ им. Н.Э. Баумана, 2014, – 478 с.
15. Blum, C. Metaheuristics in combinatorial optimization: overview and conceptual comparison [Text] / C. Blum, A. Roli // *ACM computing surveys*. – 2003. – № 35. – pp. 268-308.
16. Chu, C. Fast and accurate rectilinear steiner minimal tree algorithm for VLSI design [Text] / C. Chu, Y.-C. Wong. // In Proc. International Symposium on Physical Design, New York, ACM Press, 2005, pp. 28–35.
17. Cho, M. BoxRouter 2.0: Architecture and implementation of a hybrid and robust global router [Text] / M. Cho, K. Lu, K. Yuan, D.Z. Pan // *Proc. Int. Conf. Comput-Aided Des.*, 2007, pp. 503–508.
18. Moffitt, M.D. MaizeRouter: Engineering an effective global router [Text] / M.D. Moffitt // *Proc. Asia South Pacific Des. Autom. Conf.*, 2008, pp. 226–231.
19. Lee, T.-H. Congestion-Constrained Layer Assignment for Via Minimization in Global Routing [Text] / T.-H. Lee, T.-C. Wang // *IEEE Trans. Comput.-Aided Design Integr. Circuits Syst.*, vol. 27, № 9, 2008, pp. 1643–1656.

РАЗРАБОТКА СИСТЕМЫ ТЕХНИЧЕСКОГО ЗРЕНИЯ ДЛЯ СЕЛЬСКОХОЗЯЙСТВЕННОЙ ТЕХНИКИ

К.П. Лошаков

(г. Томск, Томский политехнический университет)

e-mail: kpl2@tpu.ru

DEVELOPING A TECHNICAL VISION SYSTEM FOR AGRICULTURE

K.P. Loshakov

(Tomsk, Tomsk Polytechnic University)

Abstract. This paper describes the solution of object detection and segmentation tasks for raw plots of crops. Recurrent convolution neural network had been used. As the result this approach has shown high result on training and validation set.

Keywords: detection, segmentation, neural networks, mask R-CNN, agricultural machinery.

Введение. Рост сложности задач современных робототехнических систем послужил развитию алгоритмов и методов обнаружения, отслеживания, классификации и сегментации окружающего пространства. Эта тенденция охватила все сферы жизни человека, от промышленности до сельского хозяйства и медицины. Робототехнические комплексы могут обрабатывать окружающее пространство в двухмерном и трехмерном виде. В качестве систем 3D могут выступать стереокамеры - строящие карту глубины, RGB-D-датчиков, а также LIDAR-датчики, строящие окружающее пространство в виде облака точек.

LIDAR-датчики используются компанией “Waymo” для создания беспилотного автомобиля. Преимуществами является работоспособность в любое время суток, высокая точность. Вместе с тем эффективность снижается при работе в плохих погодных условиях (дождь, туман, снег), а также при загрязнении камеры.

Одним из представителей RGB-D-датчика является датчик Kinect, который был использован Rosell-Polo et al в проектах точного сельского хозяйства [1]. Эксперимент проводился с датчиками в разных сезонных условиях. Было обнаружено, что Kinect неэффективен при обнаружении малых или сложных целей при дневном свете. Дальность обзора 4 м. Обработка до 30 кадров в секунду.

Камера ZED является одним из представителей стереокамер. Камера позволяет обрабатывать до 100 кадров в секунду и строить карту глубины до 20 м. Однако в задачах распознавания объектов существенное значение имеют шумы [2].

В системах 2D зрения используются спектральные, промышленные или цифровые камеры.

Применение спектральных камер является также актуальным по решению ряда задач, несмотря на высокую стоимость. Их эффективность обуславливается анализом изображения в определенном диапазоне длин волн электромагнитного спектра, причем границы этого диапазона выходят за границы диапазона видимого света, что приносит дополнительную информацию, которая помогает решить множество различных проблем, в том числе мониторинг состояния растительности [3].

Для получения информации могут использоваться также промышленные или обычные цифровые камеры. Для дальнейшей обработки информации используются два подхода. Один из вариантов таких подходов – создание алгоритмов компьютерного зрения, недостатком которого является сложность разработки алгоритмов. Второй вариант основывается на использовании нейронных сетей. Недостатком является приобретение дополнительных вычислительных мощностей.

Рисунок 1 отображает сравнительную характеристику каждого из устройств, использующегося в компьютерном зрении.

Устройство	Стоимость	Скорость	Работа вне помещения	Стоимость доп. оборудования
LIDAR-датчик	Худший выбор	Средний выбор	Лучший выбор	Средний выбор
Стереокамера	Средний выбор	Средний выбор	Средний выбор	Средний выбор
RGB-D-датчик	Средний выбор	Средний выбор	Худший выбор	Средний выбор
Цифровая камера	Средний выбор	Средний выбор	Средний выбор	Средний выбор
Спектральная камера	Худший выбор	Худший выбор	Средний выбор	Средний выбор

Худший выбор
 Средний выбор
 Лучший выбор

Рис. 1. Сравнение устройств в системах компьютерного зрения

Исходя из данной таблицы, можно сделать вывод, что LIDAR-датчик имеет высокую стоимость и невысокую скорость обработки изображений, что ведет к необходимости дополнительных вычислительных мощностей. RGB-D-датчик рассчитан на малую дальность обзора и не работоспособен в уличных условиях. Спектральные камеры же имеют возможность решить задачу, но достаточно дорогие и обладают низкой скоростью обработки изображений. Именно поэтому для задачи детектирования и сегментирования необработанных участков сельскохозяйственных культур в поле применена нейронная сеть с архитектурой mask R-CNN на основе информации с камеры [4].

Экспериментальная часть. В ходе работы использована одна из предобученных моделей репозитория Tensorflow Object Detection API [5] – mask_rcnn_inception_v2_coco_2018_01_28 – для детектирования и сегментирования необработанных комбайном участков поля. Для составления обучающей выборки было получено 65 изображений с разрешением 640x480 пикселей в цветовой модели RGB в разных окружающих средах. К каждому элементу выборки прикреплялись два файла. Один из них содержал

данные о картинке в том числе и об координатах ограничивающей объект рамки, полученной при выделении объекта. Другой содержал бинарную маску изображения, в котором каждому пикселю принадлежащему объекту присваивалось значение 1, другим 0. Данные из этих файлов перевели в стандартный формат для библиотеки, с которой работаем, то есть в формат TFRecords. После чего настроен конфигурационный файл для обучения модели с нужным количеством обучающихся изображений за эпоху.

Визуализация данных обучения нейронной сети представлена на рисунке 2. Общая ошибка складывается из ошибок при выполнении классификации, создания ограничивающей рамки и создания маски. Ошибка создания маски в процессе обучения была намного больше остальных ошибок, поэтому график ошибки маски представлен на рисунке 2.



Рис. 2. Ошибка определения маски

Можно заметить, что в первой четверти процесса обучения ошибка увеличивается в связи с настройкой весов нейронной сети и такой продолжительный монотонный рост можно объяснить тем, что во время обучения за одну эпоху обрабатывалось одно изображение в связи с нехваткой технических ресурсов для более продуктивного обучения модели. В последующее время наблюдается монотонное уменьшение ошибки. Ошибка при выполнении задачи сегментации имеет тенденцию уменьшаться и принимает значение менее 0.2 начиная с 3300 эпохи. На рисунке 3 представлены результаты обработки изображений из тестовой выборки обученной нейронной сетью.

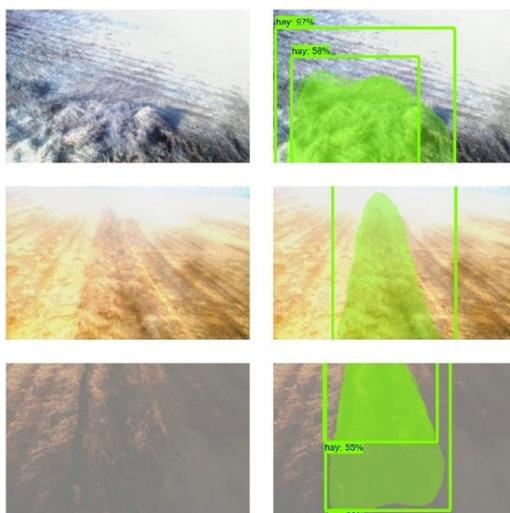


Рис. 3. Результаты тестирования модели

Тестовая выборка, часть изображений которых представлена на рисунке 3, состояла не только из объектов, располагающихся в центральной части камеры. Точность результатов сегментации на тестовой выборке, состоящей из 10 изображений, составила 90.00%.

Заключение. Один из главных факторов, влияющих на эффективность нейронной сети является выделение каждого пикселя исследуемого объекта на изображении при подготовке данных для обучающей выборки, а также имеющиеся вычислительные мощности. Факт того, что изображения на обучающей выборке содержали исследуемый объект по центру изображения, не повлиял на способность обученной нейронной сети определять необработанные участки поля, располагающиеся по краям камеры (рисунок 3).

ЛИТЕРАТУРА

1. J. R. Rosell-Polo, F. A. Cheein, E. Gregorio, D. Andujar, L. Puigdomenech, J. Masip, and A. Escol`a, "Advances in structured light` sensors applications in precision agriculture and livestock farming," *Advances in Agronomy*, vol. 133, pp. 71–112, 2015.
2. R. Xiang, H. Jiang, and Y. Ying, "Recognition of clustered tomatoes based on binocular stereo vision," *Computers and Electronics in Agriculture*, vol. 106, pp. 75–90, 2014.
3. Геоскан. Сельское хозяйство. – URL: <https://www.geoscan.aero/ru/application/agriculture> (дата обращения 10.10.2018).
4. Mask R-CNN. – URL: <https://arxiv.org/abs/1703.06870> (дата обращения 10.10.2018).
5. Tensorflow Object Detection API. – URL: https://github.com/tensorflow/models/tree/master/research/object_detection (дата обращения 8.10.2018).

АЛГОРИТМ ОТСЛЕЖИВАНИЯ И ВЫДЕЛЕНИЯ ДВИЖУЩИХСЯ ОБЪЕКТОВ В ВИДЕОПОТОКЕ

К.П. Лошаков

(г. Томск, Томский политехнический университет)

e-mail: kpl2@tpu.ru

ALGORITHM OF TRACKING AND DETECTION MOVING OBJECTS IN VIDEO STREAM

K.P. Loshakov

(Tomsk, Tomsk Polytechnic University)

Abstract. This paper describes the solution detection moving people in a videostream. Instruments of OpenCV library were used. As the result this approach shown high accuracy of people detection and no high images processing time.

Keywords: OpenCV, python, detection algorithm, frames comparison, real-time processing, BackgroundSubstractionMOG2, numpy, Mask R-CNN.

Введение. С увеличением количества камер на улицах, в переулках, торговых центрах и прочих местах растет возможность записывать все, что происходит в месте видеосъемки. Соответственно, появляется возможность применения технического зрения для решения ряда задач, основанных на анализе видеопотока. [1] Особенность внедрения технического зрения заключается в возможности анализа видеопотока. Например, решение задачи слежения за изменениями обстановки в кадре (появление объекта, его движение), что напрямую связано с возможностью обнаружения подозрительного поведения человека в кадре, находящегося магазине, банке, аэропорту или другом общественном месте. Также анализируя видеопоток, достигается предприятие каких-либо действий (отсылка информации о подозрительном поведении объекта в пункт охраны заведения). Другая целевая задача – определение скорости перемещения автомобилей по автомагистрали, для контроля соблюдения водителями правил скоростного движения.[2] Также техническое зрение используется для создания эффектив-