

ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ-КЛАССИФИКАТОРОВ ДЛЯ ОБНАРУЖЕНИЯ ИЗМЕНЕНИЙ НА СПУТНИКОВЫХ СНИМКАХ

Рогачёв Н. Е.

Механико-математический факультет, Белорусский государственный университет

Минск, Республика Беларусь

E-mail: mikalai.rahachou@gmail.com

В рамках исследования был сформирован массив оптических изображений земной поверхности до и после стихийного бедствия. Для обнаружения обрушенных зданий на этих изображениях был разработан алгоритм обнаружения изменений по результатам сегментации изображений нейронной сетью, основанной на распространенной архитектуре для общей задачи классификации изображений. Результаты работы алгоритма позволяют сделать вывод о высокой эффективности подхода по модификации и дообучению сети-классификатора для интеллектуального анализа изображений дистанционного зондирования.

ВВЕДЕНИЕ

Информация об изменениях на земной поверхности имеет крайне важное значение в процессах мониторинга материальных ресурсов. Для высокой точности обнаружения изменений необходимо выявление сложных пространственных связей на изображении. Важное значение приобретают интеллектуальные методы анализа изображений и, в частности, нейросетевые методы, позволяющие автоматизировать выявление таких связей. В рамках настоящего исследования был разработан алгоритм обнаружения изменений и оценена его работа в условиях, максимально приближенных к условиям реальной прикладной задачи.

I. ИСПОЛЬЗОВАННЫЕ ДАННЫЕ

Для обучения нейронной сети использовался массив данных Inria Aerial Image Labeling Dataset [1]. В общей сложности он содержит 180 снимков размером 5000×5000 пикселей с пространственным разрешением 30 см на пиксель. Изображения разнообразны по плотности застройки, размеру зданий и цветовой гамме, поэтому можно ожидать устойчивости обученной модели к этим факторам.

Из каждого изображения извлекались фрагменты размером 500×500 пикселей с шагом в 250 пикселей, для каждого из фрагментов создавалось 8 копий с различной ориентацией объектов в пространстве. В результате было получено 519840 фрагментов. Пятая часть из них была случайным образом отобрана для валидации обучения.

В качестве конкретного приложения для системы было предложено обнаружение обрушения зданий в результате землетрясения в Гаити в январе 2010 года [2]. Размер снимков составляет, как правило, 19584×19584 пикселей, пространственное разрешение – около 48 см на пиксель.

Из перечня предоставленных снимков была отобрана пара разновременных снимков с пересекающейся областью захвата. После этого на изображении был произведен визуальный поиск разрушенных зданий. Фрагменты изображения, содержащие разрушенные здания, составили новый массив данных для проверки качества работы системы обнаружения.

II. ОПИСАНИЕ АЛГОРИТМА

Предлагаемый метод распознавания принадлежит к группе методов выявления изменений после классификации. Для сегментации изображений в нем была использована сверточная нейронная сеть, на вход которой подаются изображения земной поверхности в видимом диапазоне.

В качестве архитектуры нейронной сети для сегментации было выбрано семейство SegNet [3]. Основная идея архитектуры состоит в формировании «бутылочного горлышка» между сетью-кодировщиком и сетью-декодировщиком, в котором размерность карт свойств уменьшается, а количество карт для каждого сверточного слоя растет (см. рис. 1). Таким образом, сеть вынуждена выделять наиболее информативные высокоуровневые свойства.

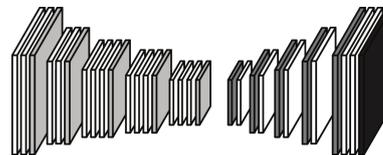


Рис. 1 – Схема сети SegNet

Сеть-кодировщик представлена известной сетью для классификации изображений VGG13. Эти сети обладают проверенными возможностями по выделению высокоуровневых свойств изображений [4].

Недостатком многократного применения пулинга и обратной ему операции является достаточно грубая карта сегментации. Для устранения этого недостатка была использована мо-

дель фильтрации Guided Filter [5]. В её основе лежит предположение о том, что карта сегментации локально линейно зависит от направляющего изображения. Это ограничение не сказывается на качестве фильтрации, но позволяет произвести её за линейное время относительно размера изображения.

Итоговая схема алгоритма выглядит следующим образом (см. рис. 2):

- для пары одновременных изображений вычисляются карты вероятности принадлежности к классу «здание»;
- вычисляется карта разности;
- карта разности фильтруется с использованием более раннего изображения в качестве направляющего;
- карта отсекается по положительному граничному значению.



Рис. 2 – Шаги алгоритма

III. РЕЗУЛЬТАТЫ РАБОТЫ АЛГОРИТМА

В качестве начального приближения для кодировщика были использованы веса VGG13, натренированные для задачи классификации изображений из массива ImageNet [6]. Веса декодировщика были инициализированы из равномерного случайного распределения, предложенного в [7]. В качестве функции потерь использовалась функция категориальной перекрестной энтропии, обучение производилось методом градиентного спуска, темп обучения вычислялся с применением алгоритма ADADELTA. Мини-батчи состояли из 2 изображений, обучение производилось в течение 2 эпох. Общее время обучения составило около четырех суток. Значение метрики Intersection-over-Union без применения фильтрации составило 0,549. Применение Guided Filter с параметрами $r = 8$, $\epsilon = 6$ позволило поднять это значение до 0,564 и существенно повысить детализацию и четкость сегментации.

Алгоритм корректно обнаруживает обрушение зданий на фрагментах снимка (см. рис. 3). В отдельных случаях замечены ложноположительные срабатывания в случае оптических искажений и у краев фрагмента. С учетом значительных отличий в условиях съемки между обучающим множеством и данными прикладной задачи, результаты следует считать высокими.



Рис. 3 – Пример обнаружения обрушений

По результатам исследования был сделан вывод о том, что использование нейронных сетей-классификаторов для выделения свойств является эффективной стратегией разработки систем интеллектуального анализа изображений. На примере задачи выявления обрушений было показано, во-первых, что веса нейронных сетей, полученные в рамках общей задачи классификации изображений, представляют собой эффективное приближение для задачи сегментации изображений дистанционного зондирования, а во-вторых, то, что сеть, обученная на изображениях одних регионов, обладает достаточной обобщающей способностью для выявления изменений на изображениях других регионов даже при значительных отличиях в условиях съемки.

При этом разумно предположить, что повышение разнообразия данных в обучающем множестве способно обеспечить еще более высокие результаты. Также к улучшению результатов может привести использование нейросетевых архитектур со сквозными связями. Эти предположения обуславливают необходимость дальнейшей работы над проблемами настоящего исследования.

1. Maggiori, E. et al. Can Semantic Labeling Methods Generalize to Any City? The Inria Aerial Image Labeling Benchmark / E. Maggiori et al. // IEEE International Symposium on Geoscience and Remote Sensing (IGARSS). – IEEE, 2017. – P. 3226–3229.
2. Open Data Program [Electronic resource] / DigitalGlobe, 2018. – Mode of access: <http://www.digitalglobe.com/opendata> – Date of access: 01.09.2018.
3. Badrinarayanan, V, Kendall, A., Cipolla, R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation [Electronic resource] / V. Badrinarayanan, A. Kendall, R. Cipolla. – 2015. – 14 p. – Mode of access: <https://arxiv.org/pdf/1511.00561.pdf> – Date of access: 01.09.2018.
4. Simonyan, K., Zisserman, A. Very Deep Convolutional Networks for Large-Scale Image Recognition [Electronic resource] / K. Simonyan, A. Zisserman // 2014. – Mode of access: <https://arxiv.org/pdf/1409.1556.pdf> – Date of access: 01.09.2018.
5. He, K., Sun, J., Tang, X. Guided Image Filtering / K. He, J. Sun, X. Tang // IEEE Transactions on Pattern Analysis and Machine Intelligence. – IEEE, 2013. – Vol. 35, № 6. – P. 1397–1409.
6. Release VGG16, VGG19, and ResNet50 · fchollet/deep-learning-models [Electronic resource] / F. Chollet. – 2016. – Mode of access: <https://github.com/fchollet/deep-learning-models/releases/tag/v0.1> – Date of access: 01.09.2018.
7. Glorot, X., Bengio, Y. Understanding the difficulty of training deep feedforward neural networks / X. Glorot, Y. Bengio // Proceedings of the International Conference on Artificial Intelligence and Statistics (AISTATS'10). – Society for Artificial Intelligence and Statistics, 2010. – P. 249–256.