

- Taranchuk // Computer Algebra Systems in Teaching and Research. – 2017. – Vol. VI. – P. 195–203.
21. Taranchuk, V. B. Development of interactive teaching materials for computer mechanics. / V. B. Taranchuk, M. A. Zhuravkov // Vestnik BGU. – Ser. 1 : Fiz. Mat. Inform. – 2016. – № 3. – P. 97–107.

22. Таранчук, В. Б. Математическое и программное обеспечение аппроксимации цифровых полей / В. Б. Таранчук // Теория вероятностей, случайные процессы, математическая статистика и приложения : сб. науч. ст. Междунар. науч. конф., Минск, 15–17 сент. 2008 г. – Минск : Изд. центр БГУ, 2008. – С. 326–334.

Материал поступил в редакцию 11.01.2019

TARANCHUK V. B. Methods and toolkit of an estimation of an accuracy of computer geological models

The article discusses the problems of development, tool filling, usages of the integrated program complex of the composer of digital geological and geocological models. Examples illustrate advantages of an offered process engineering of selection and usage of components of the program complex by synthesis of units of computer algebra systems and geographical information systems. Possibilities of adapting of digital models, interactive graphics visualization, comparison of results are marked. Results of work of algorithm of address consolidation of the seismic profiles are presented, the resulted maps of isolines visually illustrate algorithm possibilities.

УДК 004.89

Головко В. А., Крощенко А. А., Михно Е. В., Войцехович О. Ю.

НЕЙРОСЕТЕВЫЕ МОДЕЛИ ДЕТЕКЦИИ ТОВАРОВ НА ИЗОБРАЖЕНИИ

Постановка задачи. Задача детекции объектов на изображении относится к наиболее активно исследуемым задачам искусственного интеллекта ввиду их высокой практической значимости. Развитие мобильных технологий позволило осуществить миниатюризацию устройств, используемых для детекции различных объектов.

Поиск объектов и оценка их примерного количества на фото и видео имеет большое значение в среде бизнеса. Рутинные задачи по ручной количественной оценке товара определенных товарных марок занимают существенное время в работе квалифицированных кадров. Поэтому применение последних исследований в области глубоких сверточных нейронных сетей и разработанных моделей для детекции способно поднять автоматизацию на новый уровень.

В данной работе нами исследовались различные модели для осуществления детекции товаров определенных торговых марок на изображениях. Полученные результаты позволяют говорить о степени применимости различных моделей к предложенной задаче детекции.

Обзор существующих решений. Детекция объектов на изображении является одним из самых популярных направлений исследований в последние годы. Для решения этой задачи ранее активно применялись традиционные методы, основанные на использовании дескрипторов признаков SIFT (Scale-Invariant Feature Transform) [1] и SURF (Speeded Up Robust Features) [2]. Метод SIFT строится на извлечении ключевых точек из набора интересующих объектов и их сравнения с новыми анализируемыми изображениями. SIFT позволяет детектировать объект при наличии шума и частичном перекрытии. Метод SURF основан на SIFT, но при этом обладает большей скоростью работы [3]. Оба метода имеют высокую математическую сложность и в целом обладают худшей обобщающей способностью чем современные методы, основанные на использовании сверточных нейронных сетей [4].

Успехи, достигнутые в обучении глубоких нейронных сетей, повлияли на методы, используемые в детекции объектов. Так, стали активно развиваться идеи и подходы, основанные на использовании различных нейросетевых архитектур. В 2014 году была предложена R-CNN [5], в 2015 – Fast R-CNN [6], особенностью которого стало использование специального ROI-слоя, позволившего ускорить работу сети. Вслед за ней была разработана архитектура Faster R-CNN [7], которая отличается от Fast R-CNN наличием специальной сети RPN (Region Proposal Network), основная задача которой – выделение областей претендентов. Изменения позволили не только ускорить работу сети, но и получить лучшие показатели обобщающей способности по сравнению с Fast R-CNN. В 2016 году были предложены архитектуры YOLO [8] и SSD [9].

Все упомянутые архитектуры разделяются на две основные категории:

1. Методы с предварительным выделением кандидатов (R-CNN, Fast R-CNN, Faster R-CNN).

2. Однопроходные методы (one-look), к которым относятся SSD, YOLO, YOLO9000.

Отличительная особенность второй группы методов заключается в том, что они осуществляют детекцию объектов на изображении за один проход (one-look), без необходимости решения двух независимых задач, а именно локализации объекта и его классификации. Для методов первой группы две эти задачи решаются отдельными частями нейросетевой архитектуры или даже отдельными методами (R-CNN).

Все модели для детекции объектов на изображениях базируются на использовании предварительно обученной глубокой сверточной нейронной сети. Чаще всего в роли таких сетей выступают классифицирующие сети, у которых отбрасываются последние слои, используемые для классификации, а затем сеть дообучается на новых данных. Таким образом, предобученная сеть играет роль «поставщика» признаков для слоев, выполняющих детекцию.

Обучающая выборка. В качестве исходных данных, используемых для формирования обучающей выборки для решения поставленной задачи, нами использовались цветные фотографии из супермаркетов, предоставленные компанией LeverX [10]. Примеры фотографий, используемых для обучения, представлены на рис. 1.

Нами использовалась общая выборка из 783 фотографий, при этом 650 изображений исходной выборки формировали обучающую подвыборку, а 133 изображения — тестовую. В процессе разметки выделялись товары, относящиеся к десяти маркам пива.



Рисунок 1 – Примеры изображений из обучающей выборки

Головко Владимир Адамович, д. т. н., профессор, зав. кафедрой интеллектуальных информационных технологий Брестского государственного технического университета.

Крощенко Александр Александрович, ст. преподаватель кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

Михно Егор Владимирович, аспирант кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

Беларусь, БрГТУ, 224017, г. Брест, ул. Московская, 267.

Физика, математика, информатика

Подготовка выборки состояла в ручном переборе изображений с определением для каждого характеристик прямоугольных областей, включающих товары (длина, ширина, координаты левого верхнего угла). Интересующих областей на изображении может быть несколько (для случая нескольких ящиков с товарами, расположенных один на одном).

При подготовке обучающей выборки для решения задачи детекции использование прямоугольных областей для выделения некоторых объектов не выглядит целесообразным, поскольку объекты могут иметь сложную форму, далекую от прямоугольной (рис. 2). Это объясняется тем, что изначально трехмерные объекты (такие как ящики) сложно поместить в прямоугольную область без включения лишних элементов (таких как фрагменты других ящиков, фоновое изображение и т. д.). Для таких объектов удается получить приемлемые результаты детекции, если при их разметке делать акцент на изображение торговой марки, а не на тару, на которой она расположена.

Решение задачи детекции продукции определенных брендов. Для решения поставленной задачи детекции нами применялось несколько различных архитектур глубоких нейронных сетей. Все они показали приемлемые результаты при решении задачи детекции. Анализ проводился для следующих архитектур: Faster R-CNN, базирующейся на классификаторе ResNet-50/101 [11], SSD и YOLO.

Модель Faster R-CNN состоит из трех частей (рис. 3). Первая часть – это классификатор ResNet-50 (ResNet-101), предобученный на выборке COCO [12]. Вторая часть – это RPN-сеть, которая генерирует регионы-претенденты. Наконец, третья часть – это детектор, который представлен дополнительными полносвязными слоями, генерирующими координаты прямоугольных областей, содержащих в себе искомые объекты, и метки класса для каждой такой области. Ключевую роль, влияющую на скорость и эффективность анализа, играет RPN-сеть, на вход которой подаются карты признаков, полученные предшествующим сверточным слоем. Благодаря этому, генерация претендентов осуществляется быстрее, чем при использовании исходного полноразмерного изображения.



Рисунок 2 – Пример изображения с объектами сложной формы

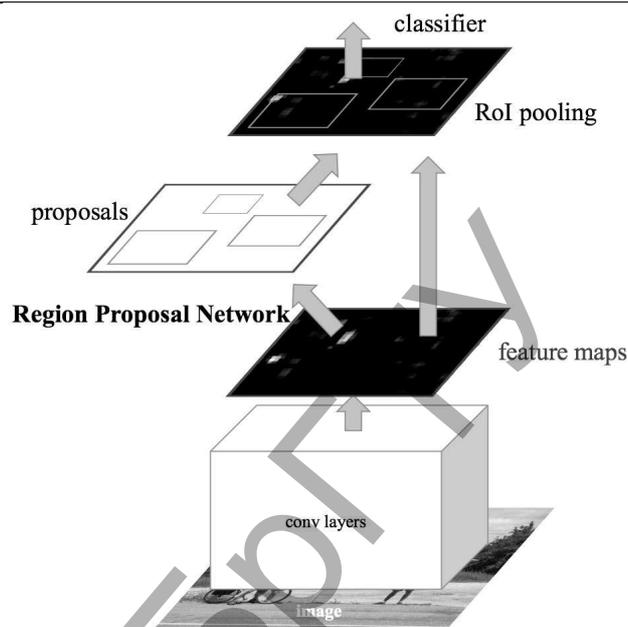


Рисунок 3 – Структура нейросетевой архитектуры Faster R-CNN [7]

Оценка эффективности моделей. Для оценки эффективности обученных моделей нами использовался показатель mAP (mean average precision metric). Эта метрика является наиболее часто используемой для оценки качества моделей детекции. Она используется вместе со своими модификациями, вычисленными для различных значений порога IoU (Intersection over Union, величина, называемая мерой Жаккара). Значение IoU вычисляется по формуле:

$$IoU = \frac{S_{ground_true} \cap S_{box}}{S_{ground_true} \cup S_{box}},$$

где S_{ground_true} определяет площадь эталонного бокса, который используется для разметки обучающей выборки, а S_{box} – площадь бокса, сгенерированного моделью.

Как известно, точность вычисляется по формуле

$$P = \frac{TP}{TP + FP},$$

где TP и FP обозначают, соответственно, число истинно-положительных и ложно-положительных результатов детекции, а P обозначает долю корректных детекций в общем количестве детекций, полученных нейронной сетью.

Относительно задачи детекции объектов, число TP определяет общее количество прямоугольных областей, для которых величина IoU , вычисленная относительно истинных областей (Ground-true box), больше некоторого заданного порога (чаще всего выбирается порог 0,5). Таким образом, если величина IoU для такой спрогнозированной области превысила 0,5, то детекция рассматривается как истинно-положительная. Если детекций для данной истинной области несколько, то выбирается одна детекция с самым большим значением IoU , а остальные рассматриваются как FP .

Усредненное значение для всех значений чувствительности дает AP :

$$AP = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i},$$

где N – число значений чувствительности, вычисленных через равные промежутки.

Значение mAP получается из AP усреднением по всем рассматриваемым классам объектов.

Таблица 1 – Результаты детекции для различных архитектур

| Архитектура | Количество итераций обучения | Размер мини-батча | Оптимизатор | mAP |
|-------------------------|------------------------------|-------------------|-------------|--------|
| Faster R-CNN (ResNet50) | 7150 | 1 | Adam | 0,8418 |
| Faster-RCNN (ResNet101) | 8450 | 1 | Adam | 0,824 |
| SSD | 30000 | 4 | RMSProp | 0,675 |
| YOLO | 2000 | 8 | Adam | 0,628 |

Результаты эксперимента. Все тестируемые модели обучались разным количеством итераций. В среднем приемлемый результат достигался после 5000 итераций обучения. Мы использовали общий подход: изучаемая архитектура обучалась на протяжении 1000 итераций, после чего тестировалась, затем процесс повторялся для следующей 1000 итераций. Если после очередного этапа обучения результаты не улучшались или становились хуже, процесс завершался.

В таблице 1 указаны результаты, полученные для различных архитектур и методов оптимизации. Из представленной таблицы видно, что наилучшие результаты продемонстрировали архитектуры Faster-RCNN (ResNet-50/101). Остальные архитектуры (такие, как YOLO и SSD) показали худшие результаты детекции вне зависимости от применяемого метода обучения и количества итераций обучения. Это объясняется тем, что SSD и YOLO в целом имеют плохую способность к обнаружению мелких объектов на изображении [13, 14] – карты признаков для таких архитектур имеют низкое разрешение. Для рассматриваемой задачи детекции это имеет критическое значение, поскольку все изображения из выборки имеют достаточно высокое разрешение, но при этом относительный размер искомого объекта невелик. Однако, архитектура Faster-RCNN обладает большей ресурсоемкостью, чем SSD и YOLO.

На рисунках 4 и 5 изображены результаты детекции единичных и нескольких товаров соответственно.



Рисунок 4 – Результаты детекции для отдельных классов объектов



Рисунок 5 – Результаты детекции для нескольких классов объектов

Заключение. В данной статье рассматривается применение различных моделей к решению задачи детекции товаров различных брендов на изображении.

Проведен сравнительный анализ наиболее эффективных и широко применяемых нейросетевых архитектур Faster R-CNN (ResNet50/101), SSD и YOLO. Полученные результаты подтверждают эффективность применения архитектуры Faster R-CNN к любым

выборкам изображений. Однако нужно отметить ресурсоемкость таких архитектур и их непригодность для решения задач, в котором важным критерием эффективности является время выполнения анализа. Модели SSD и YOLO, хотя и не дают преимуществ при детекции объектов малых и средних размеров, могут успешно применяться в составе мобильных систем детекции, ограниченных в своих аппаратных возможностях. Кроме этого, данные нейросетевые архитектуры выполняют обработку быстрее Faster R-CNN и могут рассматриваться как базовые модели для детекции и сегментации фото- и видеоизображений в реальном времени.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

- Lowe, D. Object recognition from local scale-invariant features / D. Lowe // Proceedings of the International Conference on Computer Vision. – 1999. – Vol. 2. – P. 1150–1157.
- Bay, H. SURF: Speeded Up Robust Features / H. Bay, T. Tuytelaars, L. Van Gool // Proceedings of the ninth European Conference on Computer Vision. – 2006.
- Panchal, P. M. A comparison of SIFT and SURF / Panchal, P. M., S. R. Panchal, and S. K. Shah // International Journal of Innovative Research in Computer and Communication Engineering, 1(2). – 2013. – P. 323–327.
- Lobna Ragab, S. Object Detection using Histogram and SIFT Algorithm Vs Convolutional Neural Networks / S. Lobna Ragab // Academia [Веб-ресурс]. – 2014. – Режим доступа: http://www.academia.edu/24497785/Object_Detection_using_Histogram_and_SIFT_Algorithm_Vs_Convolutional_Neural_Networks. – Дата доступа: 20.12.2018.
- Girshick, R. Rich feature hierarchies for accurate object detection and semantic segmentation / R. Girshick, J. Donahue, T. Darrell, J. Malik // arXiv [Web-resource]. – 2014. – Режим доступа: <https://arxiv.org/pdf/1311.2524v5.pdf>. – Дата доступа: 20.12.2018.
- Girshick, R. Fast R-CNN / R. Girshick // arXiv [Web-resource]. – 2015. – Режим доступа: <https://arxiv.org/pdf/1504.08083.pdf>. – Дата доступа: 20.12.2018.
- Ren, S. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks / S. Ren, K. He, R. Girshick, J. Sun // arXiv [Web-resource]. – 2016. – Режим доступа: <https://arxiv.org/pdf/1506.01497.pdf>. – Дата доступа: 20.12.2018.
- Redmon, J. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // arXiv [Web-resource]. – 2016. – Режим доступа: <https://arxiv.org/pdf/1506.02640.pdf>. – Дата доступа: 20.12.2018.
- Liu, W. SSD: Single Shot MultiBox Detector / W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Fu, A. C. Berg // arXiv [Web-resource]. – 2016. – Режим доступа: <https://arxiv.org/pdf/1512.02325.pdf>. – Дата доступа: 20.12.2018.
- Hire SAP integrator, long-term SAP service provider | LeverX // LeverX [Web-resource]. – 2018. – Режим доступа: <https://leverx.com>. – Дата доступа: 20.12.2018.
- Kaiming, He Deep Residual Learning for Image Recognition / H. Kaiming, Z. Xiangyu, R. Shaoqing, S. Jian // arXiv [Web-resource]. – 2015. – Режим доступа: <https://arxiv.org/pdf/1512.03385.pdf>. – Дата доступа: 20.12.2018.
- Lin, T. Microsoft COCO: Common Objects in Context / T. Lin, M. Maire, S. Belongie, L. Bourdev, R. Girshick, J. Hays, P. Perona, D. Ramanan, C. L. Zitnick, P. Dollár // arXiv [Web-resource]. – 2015. –

- Режим доступа: <https://arxiv.org/pdf/1405.0312.pdf>. – Дата доступа: 20.12.2018.
13. Huang, J. Speed/accuracy trade-offs for modern convolutional object detectors / J. Huang, V. Rathod, C. Sun, M. Zhu, A. Korattikara, A. Fathi, I. Fischer, Z. Wojna, Y. Song, S. Guadarrama, K. Murphy // Computer Vision and Pattern Recognition. – 2017. – P. 7310–7319.
14. Hui, J. What do we learn from single shot object detectors (SSD, YOLOv3), FPN & Focal loss (RetinaNet)? / J. Hui // Medium.com [Web-resource]. – 2018. – Режим доступа: https://medium.com/@jonathan_hui/what-do-we-learn-from-single-shot-object-detectors-ssd-yolo-fpn-focal-loss-3888677c5f4d. – Дата доступа: 20.12.2018.

Материал поступил в редакцию 15.02.2019

GOLOVKO V. A., KROSHCHENKO A. A., MIKHNO E. V. Neural network models of detection of goods on the image

In this paper we investigate applying of several common models to task of detection goods in images.

We implemented compare of most effective and widely used architectures as Faster R-CNN (ResNet50/101), SSD и YOLO. Received results confirm effectiveness of applying Faster R-CNN to any sets of images. However, it is necessary to note the resource-intensiveness of this architecture and its unsuitability for solving problems, in which an important criterion of efficiency is the time for performing the analysis. The SSD and YOLO models do not offer advantages in the detection of small and medium-sized objects, but can be successfully used as part of mobile detection systems that are limited in their hardware capabilities. In addition, these neural network architectures perform processing faster than Faster R-CNN and can be considered as basic models for detecting and segmentation of objects in images and video in real time.

УДК 621.311.6

Grzeszczyk K., Кочан В. В., Саченко О. А., Русин Б. П., Лендюк Т. В.

КОНТРОЛЬ ТРАНСПОРТНЫХ ДЕФЕКТОВ ЭНЕРГОГЕНЕРИРУЮЩИХ ПАНЕЛЕЙ СОЛНЕЧНЫХ БАТАРЕЙ

Введение. Как известно, фирмы, выпускающие энергогенерирующие панели солнечных батарей, при выпуске из производства проводят 100%-й контроль их качества. Поэтому вероятность выпуска недоброкачественных панелей мала. Но потребителю иногда поступают неисправные панели или панели, энергетическая эффективность которых снижена. Монтаж таких панелей причиняет значительные потери из-за необходимости их последующего демонтажа и монтажа исправной панели. Неисправности энергогенерирующих панелей солнечных батарей, появляющихся у потребителя, в значительной мере вызвана дефектами, возникающими во время транспортирования. А при установке такие панели обычно не проходят объективный контроль качества (они проходят лишь визуальный контроль, который является поверхностным и субъективным). Частично это вызвано отсутствием эффективных методов оперативного контроля дефектов, возникающих при перегрузках энергогенерирующих панелей солнечных батарей, а также отсутствием соответствующего оборудования. Поэтому целесообразно разработать метод и оборудование, предназначенное для проведения потребителем объективного контроля качества энергогенерирующих панелей солнечных батарей непосредственно перед их монтажом. К такому методу предъявляются специфические требования. Он должен быть простым, не требовать использования дорогого или специализированного оборудования и много времени на проведение контроля (обеспечивать малую трудоемкость и высокую производительность). Метод должен обеспечить идентификацию дефектов, снижающих энергетическую эффективность энергогенерирующих панелей солнечных батарей до недопустимого уровня.

Обзор известных работ и постановка задачи. Для контроля качества энергогенерирующих панелей солнечных батарей разработано достаточно много методов и методик [1–3], используемых при их выпуске, монтаже и даже непосредственно в условиях эксплуатации. В частности, важной является проблема устранения неисправности электрических соединений, которая может существенно повы-

сить общие эксплуатационные свойства всей системы.

Применение при производстве энергогенерирующих панелей солнечных батарей некачественных фотомодулей приводит к эффекту локального перегрева участков. Это дает возможность использовать для идентификации дефектов тепловизор [4–6]. Использование тепловизора для диагностики энергогенерирующих панелей солнечных батарей является наиболее распространенным. При помощи тепловизора наличные или скрытые дефекты энергогенерирующих панелей солнечных батарей могут быть выявлены на всех стадиях их жизненного цикла. В результате диагностики этим методом можно выявить следующие дефекты солнечных батарей:

- «полосковые» дефекты обратных диодов (неисправные «горячие» «полоски» или отдельные фотозвенья энергогенерирующих панелей солнечных батарей);
- красные пятна и затемнения, указывающие на высокую мощность рассеяния фотозвеньев, а также указывающие на поврежденные соединения;
- физические дефекты и механические повреждения элементов солнечной установки, которые можно локализовать по наличию «горячей точки».

Несмотря на разнообразие методов контроля качества энергогенерирующих панелей солнечных батарей, определение энергетической эффективности дефектных энергогенерирующих панелей солнечных батарей после их транспортирования (непосредственно перед монтажом) остается актуальной задачей и требует дополнительных исследований.

Таким образом, цель настоящей работы может быть определена как создание простого в применении, не требующего использования дорогого или специализированного оборудования оперативного метода выявления дефектов энергогенерирующих панелей солнечных батарей, возникающих при их транспортировании.

Предлагаемая методика. Предлагаемая методика контроля качества энергогенерирующих панелей солнечных батарей непосред-

Grzeszczyk Konrad, International Vision Machinery, VISORT Sp., J. Radom, Poland.

Кочан Владимир Владимирович, к. т. н., профессор кафедры информационно-вычислительных систем и управления Тернопольского национального экономического университета.

Саченко Олег Анатольевич, преподаватель кафедры информационно-вычислительных систем и управления Тернопольского национального экономического университета.

Лендюк Тарас Васильевич, старший преподаватель кафедры информационно-вычислительных систем и управления Тернопольского национального экономического университета

Украина, ТНЕУ, 46020, г. Тернополь, площадь Победы, 3.

Русин Богдан Павлович, д. т. н., профессор Физико-механического института им. Г. В. Карпенко НАН Украины

Украина, г. Львов, ул. Науковая, 5.