

НЕЙРОСЕТЕВЫЕ МОДЕЛИ ВЫДЕЛЕНИЯ И РАСПОЗНАВАНИЯ АВТОМОБИЛЬНЫХ НОМЕРОВ

Киреев Даниил Сергеевич

Студент

Факультет ВМК МГУ имени М. В. Ломоносова, Москва, Россия

E-mail: daniil.kireev@graphics.cs.msu.ru

На сегодняшний день наблюдается массовое внедрение камер видеонаблюдения во всех отраслях нашей жизни. Их количество уже сейчас исчисляется миллионами и продолжает увеличиваться каждый день. Камеры устанавливают повсюду: начиная от офисных зданий и улиц города и заканчивая общественным транспортом. Каждая из них имеет свое предназначение, одно из которых — контроль ситуации на дорогах.

Существует множество сценариев, в ходе которых нам бы хотелось идентифицировать участников дорожного движения. Для этой цели мы можем использовать информацию с автомобильного номера транспортного средства, который и является его уникальным идентификатором.

Имеющиеся на данный момент алгоритмы имеют ограничения по производительности и качеству выделения/распознавания автомобильных номеров, что увеличивает накладные расходы на их использование в реальных системах. В данной области наблюдается большое количество работ, авторы которых пытаются улучшить характеристики алгоритмов [1,2]. По итогу, задача не является решенной в полной мере и остается актуальной до сих пор.

Полный процесс распознавание автомобильного номера можно разделить на два этапа:

- Обнаружение на изображении автомобильных номеров
- Непосредственно распознавание символов на каждом обнаруженном номере

Для поиска номера на изображении использовалась нейросетевая архитектура RetinaNet [3]. Её особенность заключается в том, что информация с карт, получаемых на выходе сверточных слоев, передается на вход деконволюционных слоев, где для каждого строится свой набор ограничивающих прямоугольников, которые описывают местоположении автомобильного номера на изображении. Данная архитектура хорошо себя зарекомендовала на задачах детекции различного рода объектов. Автомобильные номера не стали

исключением, достаточно было изменить набор якорных боксов на те, что лучше соответствуют форме автомобильных номеров, чтобы увеличить качество поиска. Данный подход демонстрирует 99.16% точности и 99.26% полноты обнаружения сравнимую с [2]: 99.56% и 99.34% точности и полноты соответственно на общей тестовой базе AOLP AC [1], однако скорость работы алгоритма выше в три раза.

Далее необходимо произвести распознавание символов, которые изображены на найденном автомобильном номере. Для этого он изначально с помощью трансформаций приводится к стандартному виду, разбивается на последовательные кусочки, для каждого из которых заранее натренированная на распознавание символов сеть формирует его признаки. Данная последовательность признаков подается на вход двунаправленной рекуррентной нейронной сети с долгой краткосрочной памятью [4], которая на выходе выдает последовательность символов, которые изображены на номере. Её особенностью является то, что она способна использовать при анализе элемента последовательности информацию о его соседях. Данный подход показал 97.5% посимвольной точности распознавания номера, лучший результат полученный с помощью одной сети в [1] — 96.89% на общей тестовой базе AOLP [1].

Важным преимуществом использования рекуррентной сети для распознавания последовательности символов является возможность автоматически выучивать особенности номеров из обучающей выборки во время фазы тренировки. Для российских номеров существует определенный набор паттернов, алгоритм обучился использовать их в своей работе. Это позволяет его с легкостью масштабировать на распознавание автомобильных номеров других стран, достаточно предоставить достаточно полную обучающую выборку для интересующих нас номеров.

Литература

1. Li H., Shen C. Reading car license plates using deep convolutional neural networks and LSTMs //arXiv preprint arXiv:1601.05610. — 2016.
2. Li H., Wang P., Shen C. Towards End-to-End Car License Plates Detection and Recognition with Deep Neural Networks //arXiv preprint arXiv:1709.08828. — 2017.
3. Lin T. Y. et al. Focal loss for dense object detection //arXiv preprint arXiv:1708.02002. — 2017.
4. Hochreiter S., Schmidhuber J. Long short-term memory //Neural computation. — 1997. — Т. 9. — №. 8. — С. 1735-1780.