

$$K = \frac{1}{150}L = \begin{bmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 9 & 12 & 9 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 9 & 12 & 9 & 4 \\ 2 & 4 & 5 & 4 & 2 \end{bmatrix}$$

В дальнейшем, после связи границ в совокупность точек, образующие прямые линии, требуется отсеивать прямые, не относящиеся к карте (данную задачу облегчает изначальное знание отношения сторон и их параллельности). На найденном четырехугольнике требуется применить проективное преобразование, приводящее изображение карты к ортогональному виду с фиксированным разрешением. После этого в наличии имеется область изображения, на котором находятся все интересные поля и можно приступать непосредственно к поиску и распознаванию текстовой информации.

В первую очередь, необходимо отсеять фон карты предварительной фильтрацией без подавления текстовой информации. Затем следует выделить зоны для поиска интересующей информации, чтобы увеличить быстродействие поиска и минимизировать ошибки. В данную задачу можно включить сегментацию изображения на области символов и отсеивание остальных областей, получив своеобразные «коробки символов» (прямоугольные области, интересные для распознавания текста).

Основной интерес и наибольшую сложность представляет из себя распознавание символов в «коробках символов». Для этого требуется локализовать строки символов, после чего строки-кандидаты следует сегментировать на символы в вертикальной ориентации. Этот момент является краеугольным, поскольку нахождение строки не является принципиально сложной (многочисленность символов в строке сама по себе является уточняющим фактором, уменьшающим вероятность ошибки, тогда как вертикальная сегментация работает с одним символом).

В случае успешной сегментации и выделения всех интересующих символов, требуется их непосредственное распознавание. Для этого следует каждый интересующий объект пропустить через нейронную сеть, предварительно обученную на выборке символов. Так как разрабатываемый модуль предполагает распознавание как *embodied* (выбитых), так и напечатанных символов, то требуется обучение как минимум 2 различным шрифтам. В случае невозможности распознать какой-либо символ, можно использовать дополнительный анализ нескольких последующих кадров, который сработает значительно быстрее, так как известна позиция поиска, и можно отсеять успешно распознанные символы.

После непосредственного анализа требуется применение постобработки, как использование алгоритма Луна для выявления ошибок распознавания, сравнение распознанной даты истечения на предмет актуальности текущей даты, возможно применение словарей имен и фамилий для уточнения.

Список использованных источников:

1. Canny Edge Detection [Электронный ресурс]. – Электронные данные. – Режим доступа: www.cvmt.dk/education/teaching/f09/VGIS8/AIP.
2. Shapiro, L. G. & Stockman, G. C. Computer Vision. — Prentence Hall, 2001. — С. 137, 150.

СВЕРТОЧНАЯ НЕЙРОННАЯ СЕТЬ ДЛЯ ОБРАБОТКИ ДАННЫХ БЕСПИЛОТНОГО ЛЕТАТЕЛЬНОГО АППАРАТА

*Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь*

Миранович И. А.

Иванов Н. Н. – канд. физ.-мат. наук, доцент

В сообщении описано решение задачи обнаружения и распознавания объектов бортовым оптико-электронным модулем беспилотного летательного аппарата. Задача решена алгоритмом глубинного обучения на основе сверточной нейронной сети (CNN). Задача решается в режиме реального времени.

Выбор метода для обнаружения и распознавания объектов на изображениях в режиме реального времени с учетом конкретной архитектуры беспилотного летательного аппарата (БПА) остается актуальной задачей. Специфика этой задачи в том, что большая часть известных методов работает только с «идеальным» изображением, что практически невозможно ввиду шумов при передаче видеопотока оператору, вибрация камеры в полете, влияния погодных условий, потерей кадров при передаче с удаленного БПА и т. п.

Глубинное обучение является областью более широкого машинного обучения. Глубинное обучение основано на двух постулатах: использованию большого количества уровней представления информации,

необходимых для моделирования семантических отношений в данных; и применении немаркированных данных (не включенных в процесс обучения). Глубинное обучение продемонстрировало свои преимущества в области машинного обучения, значительно превзойдя другие модели. Особенно полезным оно оказалось при решении задач распознавания речи и изображений и ряде других [1]. Недостатком глубинного обучения являются затраты ресурсов большого объема.

Целью сообщения является применение сверточной нейронной сети в режиме реального времени для глубинного обучения распознавателя прямоугольных движущихся объектов в зашумленном видеопотоке.

Отличительными чертами предлагаемого метода являются следующие аппаратные и программные особенности системы распознавания:

- 1) Все вычисления выполняются на борту БЛА, это стало возможным благодаря NVIDIA Jetson TX1.
- 2) Работа сверточной нейронной сети ускорена за счет предобработки изображения.
- 3) Для реализаций алгоритма использовалась библиотека Caffe.

В аппаратной части применяется NVIDIA Jetson TX1 – это модульный суперкомпьютер, обладающий высокой производительностью и энергоэффективностью. Он создан в 2015 году на основе архитектуры NVIDIA Maxwell, имеет 256 ядер CUDA, что обеспечивают производительность не менее, чем 1 терафлопс. Его 64-битный CPU способен кодировать/декодировать 4KB видео и интерфейс камеры со скоростью сенсора 1400 МП/с [2]. Этот суперкомпьютер идеально подходит для поставленной задачи.

Библиотека Caffe хранит данные в четырехмерных массивах, которые предоставляют интерфейс для хранения серий изображений, их параметров и данных об обновлении этих параметров. Операции над этими данными проводятся посредством взаимодействия CPU и GPU, что несколько замедляет обработку. Библиотека Caffe позволяет снизить временные затраты посредством синхронизации работы устройств «по требованию» [3].

Система детектирования объектов R-CNN впервые была представлена в 2014 году в [4] и состоит из трех модулей. Первый модуль генерирует гипотезы о местоположении объекта на изображении независимо от класса объекта. Второй модуль представляет собой большую сверточную нейронную сеть, которая извлекает признаки из каждой гипотезы, преобразуя их в вектор фиксированной длины. Третий модуль – это машина опорных векторов, осуществляющая классификацию векторов-признаков на наборе конкретных классов объектов.

Сеть содержит слои 3 видов: сверточные, подвыборочные и полносвязные. Подвыборочные слои служат лишь для масштабирования, их веса постоянны. Сверточные слои служат для нахождения признаков. Полносвязные слои представляют собой обычный перцептрон с количеством нейронов, совпадающим с количеством классов идентификации, и служит для финальной классификации.

Выбранная сфера применения алгоритма ставит одной из главных целей обнаружение и распознавание движущихся объектов. Это существенно сужает круг детектируемых объектов.

Главная идея заключается в выделении только движущиеся объекты, что существенно сокращает количество генерируемых гипотез. Метод обрабатывает данные путем фильтрации исходного изображения на основе его изменений во времени; на исключения гипотез, для которых можно сделать вывод, что они не относятся ни к одному из целевых объектов; на основании размера объекта и его формы на изображении. Пример работы метода выделения движущихся объектов приведен на рис. 1.

Таким образом, предлагаемое изменение исходного алгоритма сверточной нейронной сети состоит в следующем:

Предварительное выделение фона от новых областей на изображении. Этот этап приводит к значительному уменьшению количества обрабатываемых данных и времени, затрачиваемого на генерацию гипотез.

Игнорирование слишком больших и слишком малых объектов, которые рассматриваются как разновидности шумов на изображениях.



Рис. 1 – Выделения движущихся объектов.

Были выполнены прогоны алгоритма на рабочем стенде. В результате оказалось, что получено 12% ускорения обработки по сравнению с применяемыми методами. Это стало возможным ввиду применения сверточной нейронной сети, существенного сокращения площади поиска объектов на изображениях и использованию параллельных вычисления на GPU. Большую роль сыграла высокая производительность применяемой вычислительной техники.

Список использованных источников:

1. Пильгун В. М. Глубинное обучение нейронных сетей и достижения в их применении, Киев, 2015.
2. «Модуль JETSON TX1 Самая технически продвинутая в мире система визуальных вычислений для встраиваемых систем» [Электронный ресурс]. – URL: <http://www.nvidia.ru/object/jetson-tx1-module-ru.html> (дата обращения: 07.12.2015).
3. «Caffe is a deep learning framework» [Электронный ресурс]. – URL: <http://caffe.berkeleyvision.org/> (дата обращения: 08.12.2015).
4. Ross Girshick Rich feature hierarchies for accurate object detection and semantic segmentation / R. Girshick, J.Donahue,
5. T. Darrell, J.Malik – IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014.

АРХИТЕКТУРНЫЕ ОСОБЕННОСТИ SAAS ДЛЯ ИССЛЕДОВАНИЙ В ОБЛАСТИ ЯДЕРНОЙ ФИЗИКИ

*Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь*

Солодкий Д.М., Чистяков М.Ю., Супринович И.Ю.

Ташлыкова-Бушкевич И. И. – доцент

В статье рассматривается проблематика современных исследований в ядерной физике. Модель SaaS представлена в качестве архитектурного решения для программного комплекса обработки результатов исследований, полученных методом резерфордского обратного рассеяния. Обоснована актуальность данной модели и ее преимущества.

Фундаментальная наука редко бывает привлекательным клиентом для производителей программного обеспечения. Зачастую продуктовые IT-компаний ориентированы на производство приложений для массового рынка. Узкоспециализированные научные приложения в целом не являются коммерчески выгодными за исключением тендеров и прямых закупок. Тем не менее, именно научные сотрудники более других потребителей нуждаются в высокотехнологичном и современном ПО — это напрямую влияет на эффективность исследований и косвенно — на научный прогресс в целом.

В области физики твердого тела есть раздел исследований композиционного состава твердых тел методом ионной спектроскопии. Одним из способов изучения является метод резерфордского обратного рассеяния (РОР). Это современный неразрушающий метод изучения строения вещества, в основе которого положены законы сохранения энергии и импульса. Поток ускоренных частиц рассеивается на атомах исследуемого вещества и детектируется специальными приборами [1]. Данные, полученные детекторами