

АИС Интеллектуальная система беспилотного транспортного средства

А. М. Тен, email: andreiten1@gmail.com

И.А. Барков, email: IABarkov@kai.ru

Казанский национальный исследовательский технический университет
им. А. Н. Туполева - КАИ

***Аннотация.** В данной работе рассматриваются методы компьютерного зрения, а также обработки изображения в интеллектуальных системах для беспилотного автомобиля.*

***Ключевые слова:** Машинное обучение, глубокое обучение, компьютерное зрение, беспилотный автомобиль, интеллектуальная система, искусственный интеллект.*

Введение

На текущий момент в России, а также во многих других странах, актуальна такая проблема как ДТП, а также затраты на ущерб от них. Россия тратит порядка 6-8% от ВВП России на ДТП каждый год. Из-за таких происшествий, страдают не только люди, но окружающая среда, экономика и т.д. Ущерб от ДТП по всему миру насчитывается почти пол триллиона \$. Внедрение беспилотных систем, не только должно улучшить качество дорожной ситуации на дороге, но и уменьшить материальный ущерб.

Беспилотный автомобиль – транспортное средство, оборудованное системой автоматического интеллектуального управления, которое может передвигаться без участия человека. Существуют 5 уровней автономности автомобиля. Беспилотный автомобиль снижает затраты на ремонт и амортизацию на 35%, а расходы на страхование - на 15%. беспилотные автомобили позволяют существенно сократить сроки доставки грузов, в среднем - вдвое. При традиционном подходе у водителя есть обязательное рабочее время отдыха - восемь часов, есть время на сон. Две трети дня грузовик просто стоит неподвижно, а в рабочее время может проехать не более 500 километров при соблюдении скоростного режима. Два водителя могут немного увеличить скорость перевозки, но при этом увеличат стоимость доставки для заказчика. Вождение на беспилотном транспорте намного безопаснее хотя бы потому, что беспилотный автомобиль не нарушает правила дорожного движения.

Country	GDP Lost to Traffic Accidents (Millions of US Dollars)	GDP Lost to Traffic Accidents with Driverless Cars (Millions of US Dollars)
USA	\$340,992.92	\$34,099.29
India	\$62,206.29	\$6,220.63
Japan	\$53,602.35	\$5,360.24
Germany	\$40,269.26	\$4,026.93
Russia	\$34,476.39	\$3,447.64
Italy	\$32,665.73	\$3,266.57
Canada	\$29,460.20	\$2,946.02
UK	\$28,487.55	\$2,848.76
Australia	\$28,130.32	\$2,813.03
Indonesia	\$26,719.95	\$2,672.00
Iran	\$25,519.56	\$2,551.96
Mexico	\$25,175.28	\$2,517.53
South Africa	\$24,398.24	\$2,439.82
France	\$24,216.82	\$2,421.68
Brazil	\$21,296.70	\$2,129.67

Рис. 1. Расходы стран на ДТП

2. Анализ подобных беспилотных систем

На текущий момент рынок беспилотных автомобилей все увеличивается и увеличивается. Крупные компании соревнуются между собой. Из зарубежных систем и автомобилей можно выделить таких крупных гигантов как автопроизводителя Tesla, Audi, Mercedes, Wolsvagen, а сервисов Uber и DiDi.

У компании Яндексa датчики собирают информацию об окружающей среде, а специальный софт ее обрабатывает. 3D-карта позволяет определить расстояния до объектов. Данные принимаются не только с лидара, но и с радаров, которые могут "видеть" намного

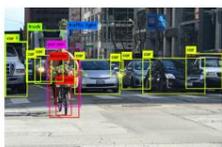
дальше, чем лидары. Из недостатков можно выделить слишком длительное время для принятия решения, что важно для беспилотника.

Беспилотники Сбер-Авто-Тех используют собственное ПО и бортовой компьютер, который подключен к картографическому сервису 2ГИС. Также как и многие использует лидар, камеры и радары. Обзор у беспилотника на 360 градусов, есть оптимальное распределение задач и маршрутов.

KAMAZ также не отстает в развитии беспилотных систем. Машина оснащена сразу четырьмя типами сенсоров: видеокамерами, радары, лидарами и сонарами. Авторобот оборудован несколькими системами связи: промышленным Wi-Fi, 4G и специальным УКВ-диапазоном на случай, если заглушены другие каналы связи, то есть экстренным каналом. Все данные с датчиков поступают в мозг машины – компьютер, где будет происходить анализ входящей информации о параметрах движения.

3. Особенности системы

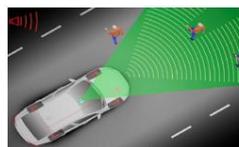
В данной системе будут реализованы следующие функции: Система детектирования объектов, которая будет работать с новой технологией YOLO v4, работающей в реальном времени, распознавание дорожных полос движения, а также регулирование съезда с полосы при помощи метода RANSAC, система принятия решений при обнаружении препятствий, а также защита персональных данных. Беспилотные автомобили знают слишком много информации об водителе, поэтому целесообразно сделать защиту конфиденциальных данных.



Детектирование мобильных объектов при помощи нового YOLO v5



Распознавание дорожной разметки



Система принятия решений при обнаружении препятствий



Улучшение качество видеопотока при плохих погодных условиях



Интеграция с картографическим ГИС сервисом



Защита персональных данных

Рис. 2. Ключевые особенности системы

4. Подготовка и анализ данных в среде RStudio

Задача нахождения объектов на изображении – задача машинного обучения, в рамках которой реализуется определение нахождения объекта в пространстве. Все это зависит от конкретной реализации алгоритма детектирования.

YOLO детектор является лидирующей архитектурой детектирования объектов на данный момент. Главная особенность этой архитектуры по сравнению с другими состоит в том, что большинство систем применяют CNN несколько раз к разным регионам изображения, в YOLO CNN применяется один раз ко всему изображению сразу. Сеть делит изображение на своеобразную сетку и предсказывает bounding boxes и вероятности того, что там есть искомый объект для каждого участка. Плюсы данного подхода состоит в том, что сеть смотрит на все изображение сразу и учитывает контекст при детектировании и распознавании объекта [1].

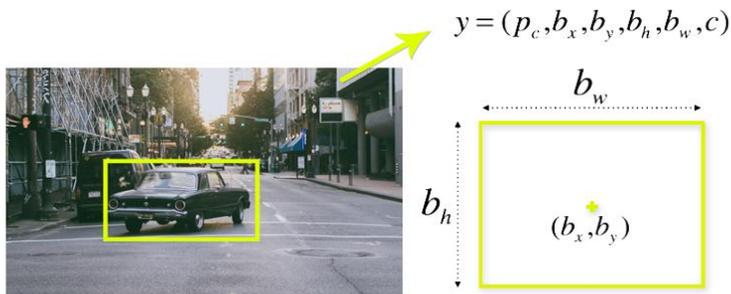


Рис. 3. Bounding Box

У каждого окна есть свойства: P_c – вероятность правильного определения границ bounding box, x, y – координаты центра ячейки, w – ширина, h – высота обрамляющего окна, n – количество классов, которых алгоритм должен распознать [1].



Рис. 4. Вектор bounding box

Таким образом, каждая ячейка сетки предсказывает B ограничивающих окон и доверительные оценки (confidence scores) для них. Теперь перемножим эти оценки каждого окна с вероятностями классов соответствующей ячейки сетки. Получим набор векторов размера C в количестве $2 \times 7 \times 7$ [1].

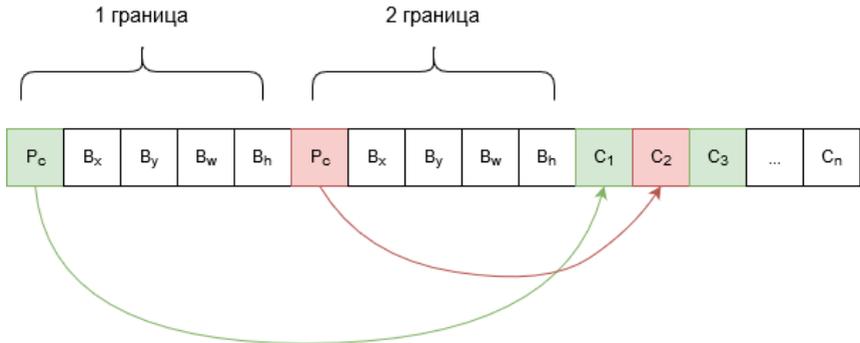


Рис. 5. Перемножение P_c на C

В результате получим набор векторов $S \times S \times 2$. Далее в каждом из векторов последовательно рассматривается один из классов. Компонентам, у которых значение меньше порогового числа (ставится вручную), ставятся в соответствие нули, после чего вектора сортируются по убыванию. Но возможна ситуация, когда один и тот же объект, обнаруживается несколькими bounding box. Для этого применяют алгоритм NMS (Non-Maximum Suppression). Он заключается в том, что сравниваются прямоугольники и выбирается прямоугольник с наибольшим значением вероятности нахождения в нём объекта класса. Сравнение происходит с помощью функции IoU. И на изображение наносятся только те окна, в векторе которых есть ненулевые значения, при этом окну присваивается класс с наибольшим значением [1].

Детектор RCNN работает в несколько этапов. На вход подается изображение и происходит генерация гипотез того, где находится нужный объект. В RCNN используется метод Selective Search. Принцип алгоритма изображен на рисунке 6 [3].

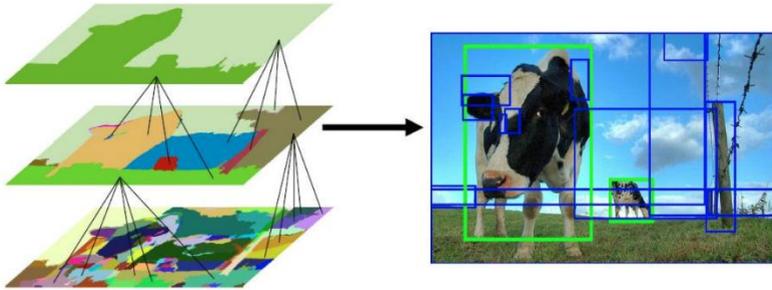


Рис. 6. Selective Search

После окна обрезаются в изображении до нужного (в сети AlexNet которая имеется в данном примере, обрезаются до 227x227) размера. Окна подаются на вход свёрточной нейронной сети, которая пропускает их через сверточные слои (в Alexnet количество 5), снимает показания с предпоследнего полносвязного слоя и выдает в виде векторов признаков.

После завершения обработки, набор векторов, подают в набор линейных SVM (support vector machine), для классификации и на регрессию для уточнения положения каждого Bounding Box (фигура ограничивающая интересующий объект) [3]. Структурная схема алгоритма R-CNN представлена на рисунке.

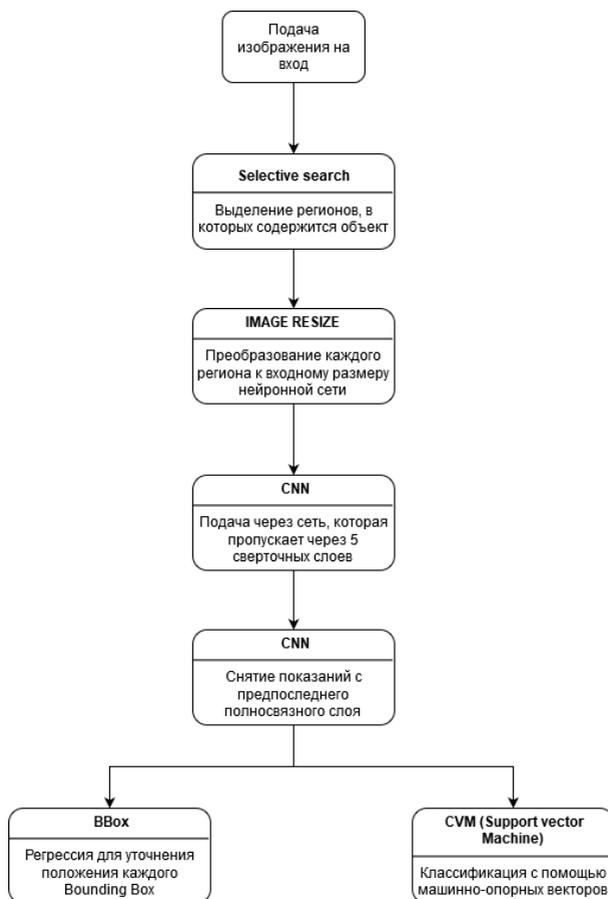


Рис. 7. Структура R-CNN

Каскадный детектор детектирует объекты в изображениях путем скольжения окна по исходному изображению. Детектор использует каскадный классификатор, чтобы решить, содержит ли окно предмет интереса. Он довольно чувствительный к вращению необходимого изображения, так как у 3D объекта изменяется соотношение сторон. Поэтому обычно обучают сразу несколько детекторов для каждой ориентации объекта [2]. Структурная схема каскадного алгоритма приведена на рисунке 8.

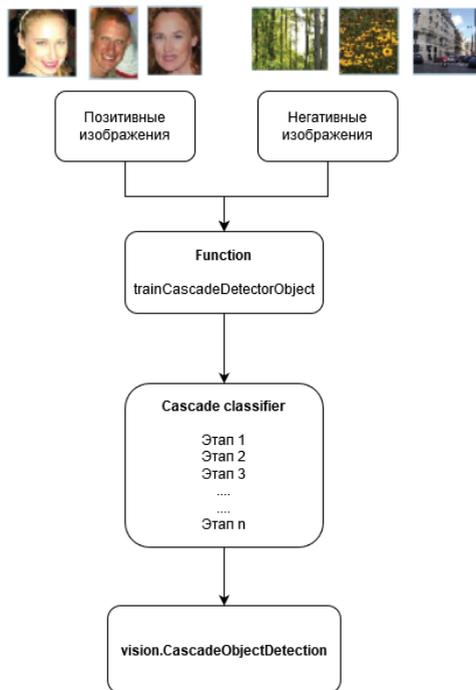


Рис. 8. Схема каскадного детектора

Для начала необходимо собрать положительный и отрицательный набор данных. Для того, чтобы создать положительный набор данных, можно использовать приложение Image Labeler. С помощью Image Labeler можно пометить положительные выборки путем интерактивного определения прямоугольных видимых областей (ROIs). Отрицательный набор данных не представлен явным образом. Вместо этого каскадный детектор автоматически генерирует отрицательные выборки от предоставленных пользователями негативных изображений, которые не содержат интересные объекты.

Перед обучением каждый этап запускает детектор, который был обучен на негативных изображениях. Любые объекты, обнаруженные от них, отображают, ложные положительные стороны, которые используются в качестве отрицательных выборок. Получается, что каждый новый этап каскада обучен корректировать ошибки, сделанные предыдущими этапами. Отрицательных изображений лучше представить больше. И для того, чтобы улучшить точность

детектирования, необходимо представить изображения, которые содержат фон сопоставленные с объектом, которым мы хотим распознать. Либо же изображения, где есть похожий объект [2].

5. Сравнение алгоритмов детектирования

Было взят набор данных состоящий из 1554 изображений, на которых помечен интересующий нас объект. Отдельно для каскадного детектора также было отобран Dataset из 5050 негативных изображений.

В таблице представлены показатели обучения алгоритмов, тестируемых на данном наборе данных и в таблице показатели алгоритмов, тестируемых на этом наборе.

Таблица

Сравнение показателей обучения алгоритмов

Алгоритмы	Dataset	Время обучения	Необходимы ли негативные изображения
Cascade Detector	Dataset	29 мин	Да
YOLO v4	Dataset	5 часов 3 минуты	Нет
Faster R-CNN	Dataset	9 часов 11 минут	Нет

Таблица

Сравнение результатов методов на изображениях

Алгоритмы	Dataset	mAP	FPS
Cascade Detector	Dataset	66,1 %	78
YOLO v4	Dataset	75,4 %	52
Faster R-CNN	Dataset	71,3 %	4



Рис. 9. Результат детектирования детектора YOLO реализованного в Matlab



Рис. 10. Результат детектирования детектора YOLO реализованного в Python

Исходя из результатов, самым лучшим и оптимальным детектором стал YOLO.

Заключение

В данной работе рассмотрены основные аспекты беспилотных систем и их особенностей, рассмотрены подобные интеллектуальные транспортные системы. Были рассмотрены методы детектирования мобильных объектов, а также был выбран самый оптимальный детектор YOLO. Беспилотные интеллектуальные системы помогут снизить количество ДТП, жертвы, а также экономические расходы всех стран на них.

Список литературы

2. Распознавание образов транспортных средств на основе эвристических данных и машинного обучения Мокшин В.В., Сайфудинов И.Р., Кирпичников А.П., Шарнин Л.М. Вестник Технологического университета. 2016. Т. 19. № 5. С. 130-137.

3. Многоклассовое обнаружение и отслеживание транспортных средств в видеопоследовательности Сайфудинов И.Р., Мокшин В.В., Кирпичников А.П. Вестник Казанского технологического университета. 2014. Т. 17. № 19. С. 348-355.

4. Отслеживание объектов в видеопотоке по значимым признакам на основе фильтрации частиц Мокшин В.В., Кирпичников А.П., Шарнин Л.М. Вестник Казанского технологического университета. 2013. Т. 16. № 18. С. 297-303.