

ПОСТРОЕНИЕ И ОЦЕНКА НЕЙРОСЕТЕВОЙ МОДЕЛИ РАСПОЗНАВАНИЯ ДОРОЖНЫХ ОБЪЕКТОВ

Р.М. Хусаинов, Н.Г. Талипов, А.С. Катасёв

Казанский национальный исследовательский технический университет
им. А.Н. Туполева-КАИ
Российская Федерация, 420111, г. Казань, ул. К. Маркса, д. 10

Аннотация. Целью исследования является решение задачи распознавания дорожных объектов с помощью нейросетевой модели. Для ее решения обоснована целесообразность использования сверточных нейронных сетей. Для построения модели использован набор данных из сети Интернет, представляющий собой изображения следующих дорожных объектов: дорожные знаки, дорожная разметка, светофоры. Для построения модели выбраны инструментальные средства: язык программирования Python и среда разработки IDLE. При написании программного кода применялись библиотеки: Open CV, Python Imaging Library, Tensorflow, Keras, Pandas, Sklearn, Matplotlib. В результате анализа существующих архитектур нейронных сетей для построения модели выбрана архитектура LeNet. В архитектуре использованы две функции активации: Relu и Softmax. Построенная модель состоит из четырех слоев свертки, двух слоев подвыборки и двух полносвязных слоев. В полносвязном слое используются три нейрона, которые относятся к классам дорожных объектов. Модель обучалась в течение 15 эпох. На собственной выборке данных, состоящей из 190 изображений, собранных на городских дорогах г. Казани с учетом различных факторов (сезонные и временные условия), проводилось тестирование модели. Точность распознавания дорожных объектов на обучающей выборке данных составила 91,44%, на тестовом наборе данных - 92%, что подтверждает адекватность построенной модели. Для оценки построенной модели спроектирована матрица ошибок, рассчитаны значения метрик precision, recall и f1-score. В перспективе планируется построение других видов моделей, расширение набора данных, а также разработка мобильного приложения для автоматического распознавания дорожных объектов.

Ключевые слова: нейронные сети, дорожные объекты, распознавание объектов, дорожно-транспортные происшествия, точность распознавания.

Введение

В области искусственного интеллекта главной особенностью является метод на основе использования нейронных сетей, построенных по принципу работы человеческого мозга [1-4]. Нейросети позволяют распознавать дорожные объекты (светофоры, знаки дорожного движения, дорожная разметка), пешеходов и транспортные средства для предотвращения дорожно-транспортных происшествий (ДТП) [5]. Применение нейронных сетей широко распространено во многих сферах, включая систему обеспечения безопасности дорожного движения [3, 6].

Отнесение исходных данных к определенному классу называется распознаванием образов. Существует множество методов, с помощью которых проводятся исследования по распознаванию объектов на изображениях. В статьях [7, 8] предложен метод Виолы-Джонса, используемый при обучении каскада классификаторов для обнаружения и классификации дорожных знаков. В статьях [9-11] авторы используют метод поиска по цвету и форме для распознавания знаков дорожного движения. Для обработки изображения выполняется преобразование из цветовой модели RGB в HSV. Данный метод применяется для анализа качественных изображений.

В работах [12-14] для распознавания объектов авторы используют метод преобразования Хафа. Его преимуществом является устойчивость при выделении части

объектов. Однако применение данного метода имеет существенный недостаток, вызванный необходимостью огромных вычислительных затрат.

Авторы в статьях [15-18] предлагают методы преобразования Хафа и быстрой радиальной симметрии для распознавания сигналов светофора. Предлагаемый подход имеет некоторые ограничения, так как он основан на предварительном определении областей сигналов по цвету, что может привести к большому количеству ложных распознаваний и уменьшить их точность. Поэтому метод не используется для распознавания других дорожных объектов.

По официальным данным государственной инспекции безопасности дорожного движения в Российской Федерации за 2023 год совершено 110008 ДТП, в которых погибли 11846 человек, 137766 человек ранены. За тот же период в Республике Татарстан произошло 2827 ДТП, в которых 233 человека погибли, 3368 человек ранены [19]. Аварийные ситуации возникают вследствие нарушения водителями требований установленных дорожных объектов. Для их предотвращения используется разновидность нейронных сетей, архитектура которых включает в себя операцию свертки, т.е. сверточные нейронные сети [1-3, 20-23].

Сбор исходных данных и инструментальных средств для построения модели

В качестве исходных для построения модели использован набор данных из сети Интернет, представляющий собой изображения дорожных объектов (светофоры, знаки дорожного движения и дорожная разметка), размещенных в соответствии с требованиями ГОСТ Р 52289-2019 [24]. По результатам сбора данных найдено 1620 изображений с разрешением от 45x42 до 1237x773 пикселей и с различной степенью зашумленности. 1500 изображений собраны с учетом летнего периода и светлого времени суток, 120 изображений – с учетом вечернего времени суток. Изображения представлены в форматах «jpg» и «png». Примеры изображений, необходимых для построения модели, представлены на рисунке 1.



Рис. 1. Примеры исходных изображений распознаваемых объектов

Для построения модели выбраны следующие инструментальные средства: язык программирования Python (версия 3.9.7) и среда разработки IDLE [25, 26]. При написании программного кода использованы следующие библиотеки [27-32]: Open CV (для обработки изображений с применением методов компьютерного зрения), Python Imaging Library (для работы с растровой графикой), Tensorflow (для разработки нейронной сети), Keras (для взаимосвязи с нейронными сетями), Pandas (для обработки и анализа информации), Sklearn (для задач классификации объектов и оценки производительности модели машинного обучения), Matplotlib (для создания графиков).

Построение архитектуры нейросетевой модели

В результате проведенного анализа существующих архитектур нейронных сетей для построения модели принято решение о целесообразности выбора архитектуры LeNet [33-36]. В этой архитектуре применяется две функции активации – Relu и Softmax.

Функция активации Relu позволяет упростить вычисления и ускоряет процесс обучения, а Softmax используется для классификации изображений. Архитектура построенной модели распознавания дорожных объектов изображена на рисунке 2.

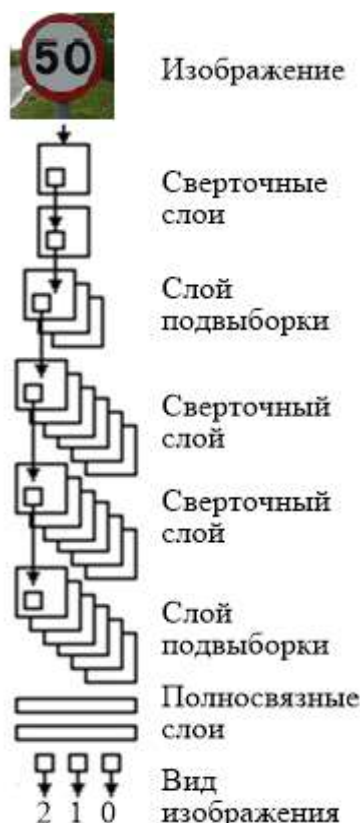


Рис. 2. Архитектура нейронной сети для распознавания объектов

Построенная модель состоит из четырех слоев свертки, двух слоев подвыборки и двух полносвязных слоев. Исходное изображение разделяется на фрагменты, которые впоследствии обрабатывают с применением одинаковых весов свертки. В слоях свертки вычисляется значение интенсивности каждого пикселя, умножается на конкретный элемент ядра, суммируется и подается на вход функции активации нейрона сверточного слоя. В сверточном слое используются 32 фильтра с размерами ядра 5×5 и функцией активации Relu. В результате операции свертки формируется карта признаков. В слое подвыборки, величина ядра которого составляет 2×2 , размеры сформированных карт признаков уменьшаются. Впоследствии карты признаков подаются в сверточные слои с 64 фильтрами и размером ядра 3×3 . После проведения операции свертки и субдискретизации карты признаков направляются на полносвязные слои, необходимые для классификации входного изображения. В этом слое используются три нейрона, которые относятся к классам дорожных объектов (дорожные знаки, дорожная разметка, светофоры), а также функция активации Softmax.

Обучение, тестирование и оценка эффективности модели

Обучение модели распознавания дорожных объектов выполнено в течение 15 эпох на персональном компьютере с двухъядерным процессором Intel Pentium CPU 3825U с тактовой частотой 1.90 ГГц, оперативной памятью 2 Гб, под управлением 64-разрядной операционной системы Windows 10. Исходные изображения для обучения нейронных сетей подавались с разрешением 30×30 пикселей. При обучении дорожных объектов точность распознавания составила 91,44%.

На собственной выборке данных, состоящей из 190 изображений, собранных на городских дорогах г. Казани с учетом различных факторов (сезонные и временные условия), проводилось тестирование модели. 120 изображений собраны с учетом светлого времени суток и весенне-летнего периода, 70 изображений - с учетом вечернего времени суток и осенне-зимнего периода. На рисунке 3 изображены примеры реальных изображений.



Рис. 3. Примеры реальных изображений, необходимых для тестирования модели

Точность распознавания модели составляет 92%, что показывает ее адекватность. Для оценки результатов модели на рисунке 4 спроектирована матрица ошибок, определяющая количество положительных и отрицательных срабатываний.




Рис. 4. Матрица ошибок модели

Как видно из рисунка 4, строка – фактический класс, а каждый столбец – распознанный класс. По диагонали представлены значения, которые соответствуют правильной классификации модели. На рисунке указаны следующие классы: «0» – «знак дорожного движения», «1» – «дорожная разметка», «2» – «светофор». В 0-м классе модель безошибочно распознала 97 изображений, а с ошибками – 26 изображений. По 1-му классу верно распознаны 105 изображений, по 2-му классу – 96 изображений.

Для оценки качества классификационных моделей используют следующие метрики: precision, recall и f1-score. Метрика precision определяет отношение количества истинно положительных результатов и общего набора положительных результатов, метрика recall – отношение количества истинно положительных результатов среди всех результатов класса, которые определены в качестве положительного, а метрика f1-score является средним гармоническим между precision и recall для итоговой оценки эффективности модели [25].

Результаты расчета значений метрик на тестовой выборке данных представлены в таблице.

Таблица. Результаты расчета метрик построенной модели

Класс объекта	Метрики классификации		
	precision	recall	f1-score
0	1	0,79	0,88
1	0,8	1	0,89
2	1	1	1

Как видно из таблицы средняя итоговая оценка эффективности метрики f1-score равна 92%, что в целом соответствует ее точности классификации на тестовой выборке данных.

Заключение

Модель распознавания дорожных объектов на основе нейронной сети по результатам исследования является эффективной, так как позволяет распознавать их с высокой степенью точности. Такая модель может быть использована в системах поддержки принятия решений и в интеллектуальных транспортных системах. Это позволит не только снизить риски возникновения дорожно-транспортных происшествий, происходящих вследствие невнимательности водителей, но и в целом повысить безопасность дорожного движения. В перспективе планируется построение других видов моделей, расширение набора данных, а также разработка мобильного приложения, позволяющего в автоматическом режиме распознавать эти объекты.

Список литературы

1. Lecun Y. Backpropagation applied to handwritten zip code recognition, neural computation / Y. Lecun, B. Boser, J.S. Denker // Neural Computation – 1989. – V.1. – Is.4. – P. 541-551.
2. Shleymovich M.P. The analysis of images in control systems of unmanned automobiles on the base of energy features model / M.P. Shleymovich, M.V. Dagaeva, A.S. Katasev, S.A. Lyasheva, M.V. Medvedev // Computer Research and Modeling. – 2018. – 10 (3). – P. 369-376.
3. Хусаинов Р.М. Анализ алгоритмов и систем распознавания знаков дорожного движения / Р.М. Хусаинов, Н.Г. Галипов // Вестник технологического университета. – 2022. – Т. 25. – №3. – С. 72-77.
4. Паклин Н.Б. Бизнес аналитика: от данных к знаниям. – СПб.: Питер, 2009. – 706 с.
5. Постолиит А.В. Перспективы применения искусственного интеллекта и компьютерного зрения в транспортных системах и подключенных автомобилях / А.В. Постолиит // Мир транспорта. – 2021. – Т. 19. – № 1 (92). – С. 74-90.
6. Тимченко В.С. Система поддержки принятия решений при определении длительности отвлечения локомотивов для ремонта железнодорожного пути / В.С. Тимченко, Д.И. Хомич // Вестник транспорта Поволжья. – 2018. – №1 (67). – С. 30-36.
7. Гурин В.И. Обнаружение и распознавание знаков дорожного движения с использованием методов технического зрения и машинного обучения / В.И. Гурин // Наука без границ. – 2020. – № 5 (45). – 75-82.
8. Зайдулин К.М. Система обнаружения дорожных знаков в видеопотоке / К.М. Зайдулин, С.М. Зайдулин, Ш.С. Фахми // Наука настоящего и будущего. – 2018. – № 1. – С. 43-47.

9. Нестеров А.Ю. Распознавание образов по уникальным точкам на примере дорожных знаков / А.Ю. Нестеров, Ю.С. Белов // Электронный журнал: наука, техника и образование. – 2016. – № 4 (9). – С. 113-119.
10. Черкас Н.А. Программная система распознавания разметки и знаков дорожного движения для мобильного робота / Н.А. Черкас, В.Е. Гай // Информационные системы и технологии ИСТ-2020. Сборник материалов XXVI Международной научно-технической конференции. – 2020. – С. 1045-1049.
11. Аккуратов В.В. Исследование алгоритмов обнаружения и распознавания дорожных знаков / В.В. Аккуратов, Н.И. Пчелинцева, Е.А. Черепков // Международный студенческий научный вестник. – 2018. – № 1. – С. 64.
12. Shein V.A. Road lane line detection with hough transform / V.A. Shein, A.O. Pak // Theoretical & Applied Science. – 2020. – N. 12 (92). – P. 401-408.
13. Куприянов А.Л. Математическая модель видеосистемы распознавания дорожной разметки и сигналов светофора / А.Л. Куприянов // Наука без границ. – 2019. – № 4 (32). – С. 40-45.
14. Илькин И.Р. Применение компьютерного зрения для контроля разметки дорожной полосы / И.Р. Илькин // Молодежная наука как фактор и ресурс инновационного развития: сб. ст. IV Междунар. науч.-практ. конф. Петрозаводск. – 2021. – С. 246-253.
15. Кирпичников А.П. Алгоритм обнаружения световых сигналов транспортных средств и светофоров / А.П. Кирпичников // Вестник технологического университета. – 2019. – Т. 22. – № 9. – С. 130-133.
16. Кирпичников А.П. Обнаружение окружностей на изображениях с помощью метода Хафа и преобразования быстрой радиальной симметрии / А.П. Кирпичников, С.А. Ляшева, А.А. Шакирзянова, М.П. Шлеймович, Р.М. Шакирзянов // Вестник технологического университета. – 2019. – Т. 22. – № 8. – С. 164-167.
17. Шакирзянов Р.М. Детектирование центров объектов на изображениях с применением методов Хафа и преобразования быстрой радиальной симметрии / Р.М. Шакирзянов, А.А. Шакирзянова // XXIV Туполевские чтения (школа молодых ученых): матер. Междунар. молодеж. науч. конф. Казань. – 2019. – С. 497-500.
18. Шакирзянов Р.М. Обнаружение сигналов светофоров с использованием цветовой сегментации и детектора радиальной симметрии / Р.М. Шакирзянов // Вестник Воронежского государственного технического университета. – 2020. – Т. 16. – № 6, С. 25-33.
19. Показатели состояния безопасности дорожного движения. URL: <http://stat.gibdd.ru/> (дата обращения: 28.11.2023).
20. Катасёв А.С. Нейросетевые модели обнаружения и классификации знаков дорожного движения / А.С. Катасёв, Н.И. Фаттахов // Вестник технологического университета. – 2023. – Т. 26. – № 3. – С. 79-84.
21. Катасёв А.С. Сверточные нейросетевые модели распознавания эмоций человека по фотографии / А.С. Катасёв, З.Р. Ханова // Вестник технологического университета. – 2023. – Т. 26. – № 4. – С. 76-81.
22. Катасёв А.С. Распознавание языка жестов с помощью сверточной нейронной сети / А.С. Катасёв, Т.И. Тухбатуллин // Вестник технологического университета. – 2023. – Т. 26. – № 4. – С. 53-57.
23. Катасёв А.С. Сверточная нейросетевая модель определения усталости человека по выражению лица / А.С. Катасёв, Б. Курбанов // Вестник технологического университета. – 2023. – Т. 26, № 4. – С. 67-71.
24. Хорьков А.А. Проблемные вопросы правового регулирования при осуществлении федерального государственного надзора в области обеспечения безопасности дорожного движения / А.А. Хорьков, А.А. Цариков // Дальний восток: проблемы развития архитектурно-строительного комплекса. – 2021. – № 1. – С. 200-204.

25. Хусаинов Р.М. Распознавание объектов дорожной инфраструктуры на основе сверточной нейросетевой модели / Р.М. Хусаинов, Н.Г. Талипов, А.С. Катасёв // Автоматизация процессов управления. – 2023. – № 2 (72). – С. 34-43.
26. Хусаинов Р.М. Система распознавания знаков дорожного движения на основе сверточной нейронной сети / Р.М. Хусаинов, Н.Г. Талипов // Математические методы в технологиях и технике. – 2022. – № 12-1. – С. 59-63.
27. Юдаков Д.С. Библиотеки Open CV как основа систем технического зрения / Д.С. Юдаков, А.И. Коротченко // Охрана, безопасность, связь. – 2016. – № 1-1. – С. 219-222.
28. Барышева Н.Н. Обработка и визуализация данных о электрофизических свойствах зерен пшеницы с помощью библиотеки Matplotlib / Н.Н. Барышева, Д.Д. Барышев, Р.Е. Дорохов // Наука и образование. – 2020. – Т. 3. – № 2. – С. 375-380.
29. Пылов П.А. Использование и представление массивов в библиотеке Numpy / П.А. Пылов, А.В. Протодяконов // Инновации. Наука. Образование. – 2020. – № 23. – С.258-266.
30. Padhi A. Intelligent intrusion detection using Tensorflow / A. Padhi, G. Sahoo, S. Maity // Smart Innovation, Systems and Technologies. – 2021. – V. 153. – P. 653-662.
31. Васяева Т.А. Прогнозирование финансовых временных рядов с помощью нейронных сетей с использованием библиотеки Keras в Python / Т.А. Васяева, Т.В. Мартыненко, Н.С. Суббота // Информатика и кибернетика. – 2019. – № 2 (16). – С. 41-50.
32. Катасёв А.С. Нейронечеткая модель формирования нечетких правил для оценки состояния объектов в условиях неопределенности / А.С. Катасёв // Компьютерные исследования и моделирование. – 2019. – Т. 11. – № 3. – С. 477-492.
33. LeCun Y. Gradient-Based Learning Applied to Document Recognition / Y. LeCun, L. Bottou, Y. Bengio, P. Haffner // Proceedings of the IEEE 1998. – V. 86. – N. 11. – P. 2278-2324.
34. Krizhevsky A. ImageNet Classification with Deep Convolutional Neural Networks / A. Krizhevsky, I. Sutskever, G.E. Hinton // Advances in Neural Information Processing Systems. – 2012. – N. 25. – P. 1097-1105.
35. Szegedy C. Going deeper with convolutions / C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich // IEEE Conference on Computer Vision and Pattern Recognition. – 2015. – P. 1-9.
36. Новиков Е.А. Сравнительный анализ архитектур сверточных нейронных сетей / Е.А. Новиков // Молодежная школа-семинар по проблемам управления в технических системах имени А.А. Вавилова. – 2021. – № 1. – С. 73-74.

CONSTRUCTION AND EVALUATION OF A NEURAL NETWORK MODEL FOR ROAD OBJECT RECOGNITION

R.M. Khusainov, N.G. Talipov, A.S. Katasev

Kazan National Research Technical University named after A.N. Tupolev-KAI
10, st. Karl Marx, Kazan, 420111, Russian Federation

Annotation. The purpose of the study is to solve the problem of road objects recognition using a neural network model. To solve this problem, the feasibility of using convolutional neural networks is justified. To build the model, a data set from the Internet was used, which represents images of the following road objects: road signs, road markings, traffic lights. To build the model, the following tools were chosen: the Python programming language and the IDLE development environment. When writing the program code, the following libraries were used: Open CV, Python Imaging Library, Tensorflow, Keras, Pandas, Sklearn, Matplotlib. As a result of the analysis of existing neural network architectures, the LeNet architecture was chosen to build the model. The architecture uses two activation functions: Relu and Softmax. The constructed model consists of four convolution layers, two subsampling layers and two fully connected layers. The fully connected layer uses three neurons that belong to the classes of road objects. The model was trained for 15 epochs. The model was tested on our own data sample, consisting of 190 images collected on city roads in Kazan, taking into account various factors (seasonal

and time conditions). The accuracy of recognition of road objects on the training data set was 91.44%, on the test data set - 92%, which confirms the adequacy of the constructed model. To evaluate the constructed model, an error matrix was designed, and the values of the metrics precision, recall and f1-score were calculated. In the future, it is planned to build other types of models, expand the data set, and also develop a mobile application for automatic recognition of road objects.

Keywords: neural networks, road objects, object recognition, road accidents, recognition accuracy.

Статья представлена в редакцию 05 декабря 2023 г.