

## РАЗРАБОТКА МОДЕЛИ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ КЛАССИФИКАЦИИ РОССИЙСКИХ ДОРОЖНЫХ ЗНАКОВ

Д.А. Матвеев

matveevda@student.bmstu.ru

SPIN-код: 4619-4962

А.С. Петруничева

alexandrapetrunicheva@gmail.com

SPIN-код: 8140-4969

МГТУ им. Н.Э. Баумана, Москва, Российская Федерация

---

### Аннотация

Систему классификации дорожных знаков можно использовать и как самостоятельное решение для задач анализа изображений, и как часть системы компьютерного зрения автомобиля для решения задач помощи водителю и автономного управления. В работе рассмотрены некоторые современные подходы в области классификации изображений с помощью сверточных нейронных сетей, проанализированы их типовые архитектуры и особенности, описаны этапы разработки и обучения модели такой нейросети. Представленные результаты получены на основе использования базы изображений российских дорожных знаков — Russian Traffic Sign Dataset (RTSD). Программная реализация алгоритмов обучения модели нейросети и ее анализа осуществлялась на языке Python с помощью библиотеки Keras на общедоступной платформе Google Colaboratory.

### Ключевые слова

Компьютерное зрение, сверточная нейронная сеть, обучение нейронной сети, задача классификации изображений, классификация дорожных знаков, Russian Traffic Sign Dataset, Google Colaboratory, Keras

Поступила в редакцию 30.07.2020

© МГТУ им. Н.Э. Баумана, 2020

---

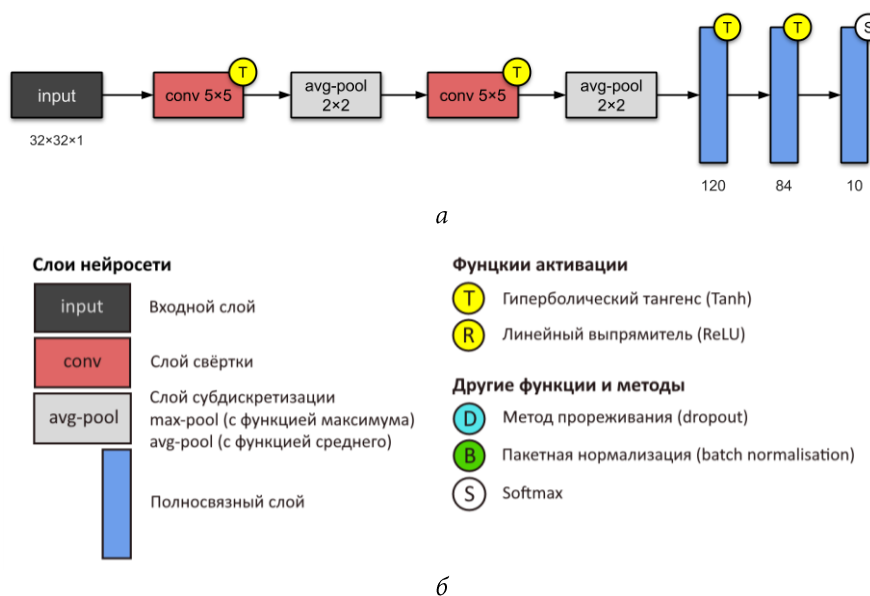
**Введение.** Области применения компьютерного зрения как технологии в решении задач анализа изображений имеют устойчивую тенденцию к постоянному росту и развитию на протяжении последних десятилетий [1]. Этому способствует повышение доступности вычислительных ресурсов, современных алгоритмов и подходов, быстрого обмена и получения информации и данных. Задачи обработки изображений для обнаружения, отслеживания и классификации объектов — одни из базовых в компьютерном зрении, актуальность их решения свойственна многим сферам промышленности и жизни.

Автономное управление автомобилем — область, которая интенсивно развивается в последние годы и состоит из множества сложных систем со своими назначениями и функциями. В данной работе рассмотрена система классификации дорожных знаков, для решения задач которой разработана и обучена модель сверточной нейронной на основе базы изображений российской дорожных знаков Russian Traffic Sign Dataset.

**Система классификации изображений.** Назначение такой системы заключается в отнесении изображения объекта к одному классу из списка заданных. Предполагается, что сам объект был ранее обнаружен некоторым другим алгоритмом, и в систему классификации поступает уже обрезанная часть исходного изображения.

По сравнению со многими известными алгоритмами, которые часто используются в решении задачи классификации (например, деревья решений (*Decision Trees*), метод опорных векторов (*Support Vector Machines*) и др.), сверточные нейронные сети становятся более популярными и более точными в решении данной задачи [2, 3]. Широкое применение данного подхода стало возможным благодаря использованию операций свертки матриц. Поскольку изображения в компьютере хранятся в виде матриц, операции свертывания позволяют легко обнаружить определенные шаблонные согласованности в пикселях, характерные для тех или иных объектов. Задача обучения модели нейросети — научиться выявлять характерные для каждого заданного класса наборы образов и различать их.

**Разработка модели нейросети.** Для разработки модели нейросети необходимо настроить ее структуру: размер входного изображения, количество слоев и нейронов, функции активации и т. д., и некоторые основные гиперпараметры: функцию потерь (loss-function), шаг обучения (learning rate), количество эпох и т. п. Большинство значений обычно подбирают экспериментально, но можно учесть назначение модели и круг задач, которые необходимо решать, и взять за основу некоторые известные разработки и их успешные реализации. Для лучшего понимания того, как работают нейронные сети и за что отвечают элементы, представленные ниже, можно ознакомиться со статьями [4, 5].



**Рис. 1.** Сверточная нейронная сеть LeNet-5 (1998):

*a* — архитектура сети; *b* — легенда с пояснениями используемых здесь и далее обозначений

Одной из основополагающих сверточных нейронных сетей принято считать сеть LeNet-5, которую представил французский ученый Yann Lecun [6]. Данная модель является одной из самых простых, имеет два сверточных слоя (*convolutional layer*) и три полносвязных (*fully-connected layer*), а в качестве функции активации используется гиперболический тангенс. На выходе нейросети применяется функция *softmax*, которая преобразует вектор выходных значений в вектор с вероятностями определения для каждого класса. Модель имеет 63 тыс. параметров, а ее архитектура в схематичном виде представлена на рис. 1, а. Легенда с пояснением используемых обозначений приведена на рис 1, б.

В 2012 г. разработчиками была представлена сеть AlexNet [7]. С данной нейронной сети началось применение функции активации ReLU, которая позволяла ускорить обучение, и метода Dropout для предотвращения переобучения [7]. Модель имеет 60 млн параметров, а ее архитектура представлена на рис. 2.




Рис. 2. Архитектура сверточной нейронной сети AlexNet (2012)

Совершенствование более новых моделей сводится к усложнению архитектуры (увеличению количества слоев и параметров [8]), созданию нейросетей с вложенной структурой [9], применению новых операций и уловок (например, пакетной нормализации — *batch normalization*) [10], которые позволяют достичь лучших результатов.

**Оценка точности модели.** Для общего понимания точности модели рассмотрим следующие понятия.

Общая точность (*accuracy*) — доля правильных ответов по сравнению со всеми ответами:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN},$$

где *TP* (*true positive*) — правильный положительный ответ, т. е. объект присутствует на фото и алгоритм его определил; *TN* (*true negative*) — правильный отрицательный ответ, т. е. алгоритм правильно определил, что объект отсутствует на фото; *FP* (*false positive*) — неправильный положительный ответ, т. е. объекта нет на фото, но алгоритм его обнаружил. Это значение является ошибкой первого рода; *FN* (*false negative*) — неправильный отрицательный ответ, т. е. объект есть на фото, но алгоритм его не обнаружил. Это значение является ошибкой второго рода.

Точность успешного распознавания (*precision*). Знание данного значения позволяет ответить на вопрос: «Какой процент всех случаев, классифицированных как положительные ( $TP + FP$ ), был верным ( $TP$ )?». Формула данной метрики имеет вид

$$precision = \frac{TP}{TP + FP}.$$

Полнота (*recall*). Данное значение характеризует способность классификатора правильно определять объекты среди всех отмеченных при разметке. Это значение является ответом на вопрос: «Какой процент всех случаев, которые действительно были положительными, был классифицирован правильно?». Полнота определяется формулой

$$recall = \frac{TP}{TP + FN}.$$

Метрики *precision* и *recall* предназначены для оценки работы алгоритма по каждому из классов объектов, поэтому их использование в случае несбалансированности выборок будет предоставлять наилучшую оценку качества алгоритма по сравнению с оценкой *accuracy*.

**Исследование российской базы дорожных знаков Russian Traffic Sign Dataset.** Согласно ГОСТ Р 52289–2004, в России установлено около 300 дорожных знаков с учетом всех их разновидностей. Russian Traffic Sign Dataset (RTSD) — база изображений, которая была создана из видеозаписей, снятых на видеорегистратор. В ней имеется 180 тыс. фото, на которых размечены 156 различных дорожных знаков, и в сумме около 105 тыс. обрезанных изображений с отдельным знаком. База RTSD подходит для обучения и детекторов, и классификаторов. Это одна из больших баз изображений дорожных знаков, которая учитывает некоторые погодные явления, время суток и время года [11].

База RTSD разделена на три части:

1) *classification* — обрезанные изображения для обучения классификатора дорожных знаков;

2) *detection* — широкоформатные изображения для обучения детектора дорожных знаков на основе размеченных областей в виде координат прямоугольников;

3) *full-frame* — оригинальные широкоформатные изображения без разметки.

Часть базы RTSD *classification* поделена на две группы изображений:

1) RTSD-r1: 67 классов, 32 983 изображения формата  $48 \times 48 \times 3$  пикселей;

2) RTSD-r3: 106 классов, 93 654 изображения формата от  $16 \times 16 \times 3$  до  $320 \times 280 \times 3$  пикселей.

Выборка RTSD-r3 менее сбалансирована — разброс количества изображений по классам составляет от 9 до 24 106 шт. В качестве набора данных для обучения выбран RTSD-r1. Визуальное представление минимального и максимального

ного количества изображений по некоторым классам представлено на рис. 3. В наименьшем количестве представлены знаки «Выброс гравия», «Ограничение высоты» (3,5 м), в наибольшем количестве — «Остановка запрещена», «Дети».

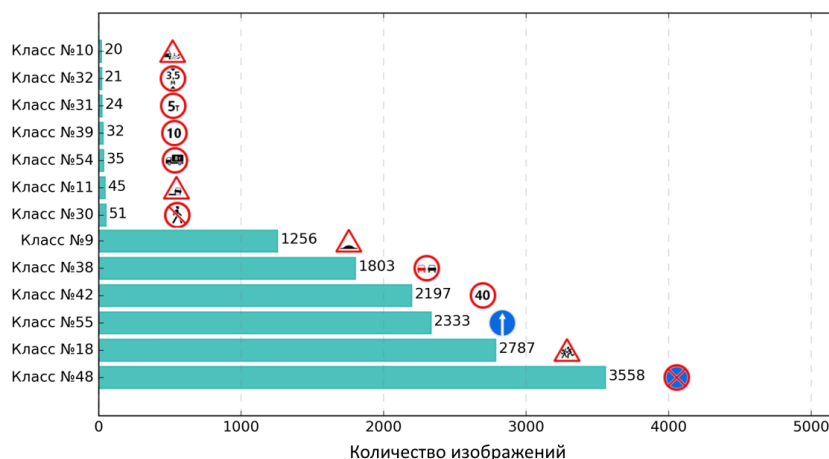


Рис. 3. Классы с минимальным и максимальным количеством изображений в RTSD-r1

**Проблемы в разметке данных в RTSD-r1.** Перед обучением нейронной сети необходимо выполнить подготовку данных, которая чаще всего предполагает ручную разметку и выделение действительных положений объектов и/или их классов на множестве изображений. Разметка данных — долгий и трудный процесс, который может происходить с появлением ошибок, например, если человек неправильно классифицирует изображение дорожного знака. Такие недоработки желательно устранять по мере обнаружения. На рис. 4, а показаны примеры изображения класса «Опасный поворот направо» и на рис. 4, б — класса «Пересечение с второстепенной дорогой» из RTSD-r1. Красными прямоугольниками выделены изображения, которые не относятся к выбранным классам.

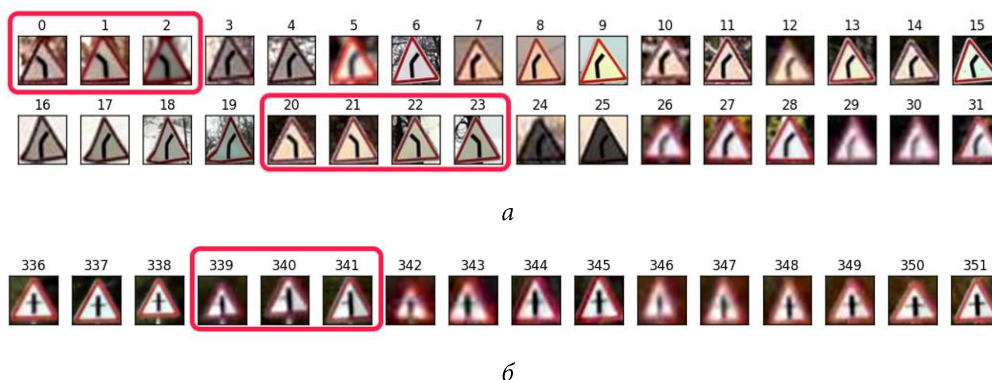


Рис. 4. Визуализация классов дорожных знаков для определения ошибок в разметке:

- а — красным прямоугольником выделены ошибки в классе «Опасный поворот направо»;
- б — выделены ошибки в классе «Пересечение с второстепенной дорогой»

Подобные ошибки также обнаружены в классах «Стоянка запрещена», «Сужение дороги» (справа), «Сужение дороги» (слева), «Примыкание второстепенной дороги» (слева), «Опасный поворот налево», «Светофорное регулирование».


**Разделение данных на обучающую и проверочную выборки.** Для обучения нейросети необходимо разделить исходные данные на группы:

- обучающую (*train*) — на ней нейросеть настраивает свои весовые параметры, стремясь минимизировать значение заданной функции потерь;
- проверочную (*validation*, сокращенно *val*) — для оценки способности модели обобщать наборы признаков объектов путем проверки значения функции потерь на данной группе.

Также отметим, что разделение, используемое в данной работе, выполнено с учетом случайного перемешивания по каждому классу дорожного знака на пропорции 70 и 30 %, что отличается от выполненного создателями базы данных RTSD. Размеры групп изображений\*:

- обучающего набора данных (70 %): (23 088, 48, 48, 3);
- проверочного набора данных (30 %): (9 895, 48, 48, 3).

**Выбор параметров и архитектуры модели.** Сформируем модель на основе следующих исходных данных. Нам известно, что для обучения имеется 23 088 изображений, а это достаточно мало для многих объемных и тяжелых моделей. Известно также, что лучше использовать входной размер изображения 48×48×3 пикселей, и что в выбранной базе данных RTSD-r1 существует 67 классов. На основе многих успешных разработок нейронных сетей, описанных выше, сформирована модель, структура которой изображена на рис. 5 (легенда с обозначениями приведена на рис. 1, б).



**Рис. 5.** Архитектура спроектированной сверточной нейронной сети

В качестве функции потерь (*loss-function*) используется перекрестная кросс-энтропия (*Categorical Crossentropy, CCE*), определяемая по формуле

$$CCE = - \sum_i^N t_i \log p_i,$$

где  $N$  — количество выходов нейросети;  $t_i$  — целевое значение  $i$ -го выхода;  $p_i$  — вероятность  $i$ -го выхода (класса). Задача обучения заключается в минимизации значения этой функции.

\* Формат записи: (количество фото, ширина в пикселях, высота в пикселях, количество каналов).

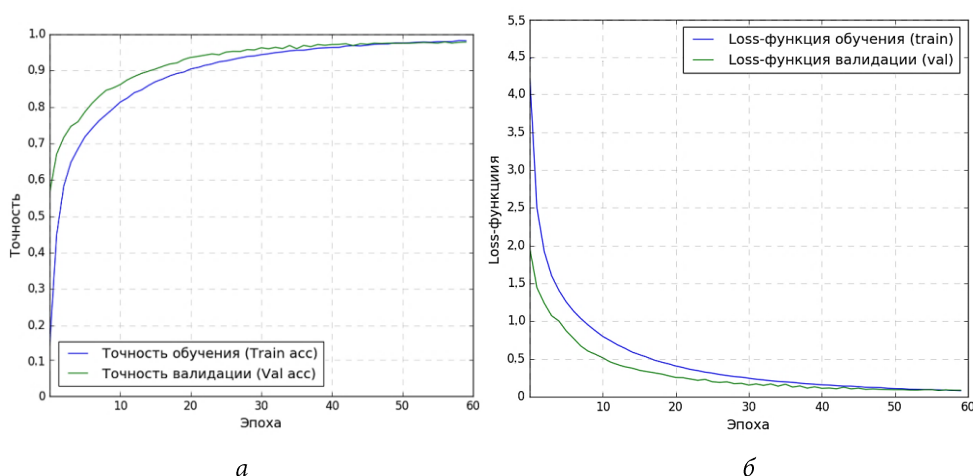
В качестве оптимизатора (*Optimizer*) используется метод Adam [12].

В качестве метрики используется общая точность (*accuracy*).

Общее количество параметров нейросети — 2 795 875, из которых 2 654 464 принадлежат трем полносвязным слоям, что составляет 94,94 % всех параметров модели. Это наиболее емкие слои нейросети, которые отвечают непосредственно за классификацию информации из изображения, полученной на предыдущих слоях свертки и субдискретизации. Для программной реализации на языке *Python* использовалась библиотека *Keras*.

**Обучение модели.** Для обучения нейросети лучше использовать графический процессор (Graphics Processing Unit, GPU), чем центральный процессор (Central Processing Unit, CPU), так как структура первого позволяет распараллелить многочисленные операции работы с матрицами и значительно увеличить скорость обучения. В данной работе использовалась онлайн-платформа Google Colaboratory, которая позволяет удаленно и бесплатно использовать CPU и GPU, предоставляемые компанией Google. Таким образом, обучение осуществлялось на удаленно подключенной видеокарте NVIDIA Tesla K80 с 12,72 ГБ доступной оперативной памяти.

Графики обучения вплоть до момента его окончания представлены на рис. 6, а и б. Обучение прекратилось, поскольку модель начала переобучаться и функция потерь проверочного набора данных (рис. 6, б, зеленый график) перестала уменьшаться.



**Рис. 6.** Графики процесса обучения модели для обучающих (*train*) и проверочных (*val*) данных:

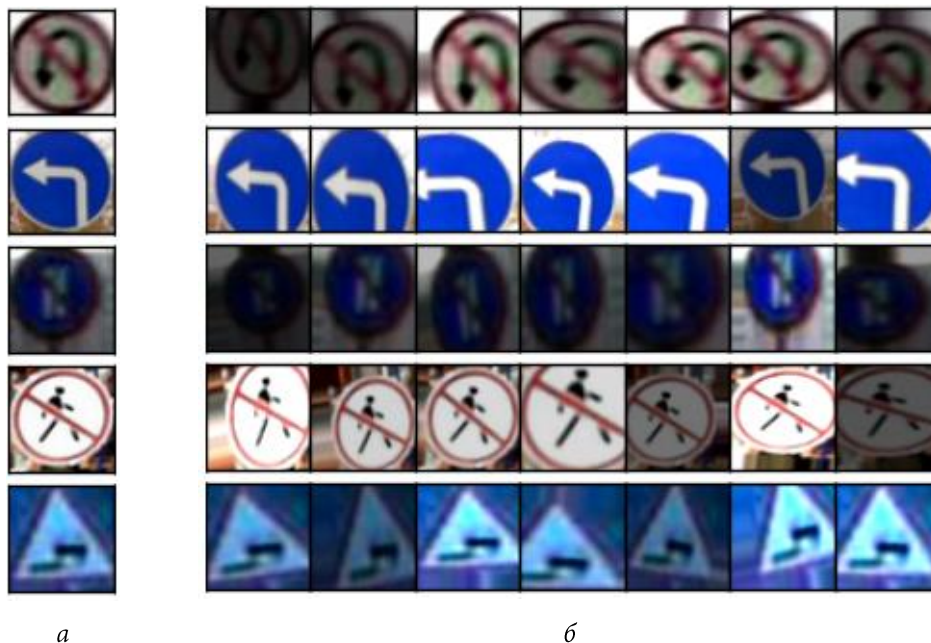
*а* — точность классификации в процессе обучения; *б* — функция потерь

В итоге получены следующие значения:

- количество эпох: 59;
- общая точность (*accuracy*): 0,97901;
- функция потерь (*loss-функция*): 0,08194;
- общее время обучения: 184 с (3 мин 4 с).

**Дополнительное обучение модели.** Данные являются одним из наиболее важных факторов при обучении модели, поскольку от их количества и разнообразия зависит точность нейросети [13]. Для расширения обучающего набора данных можно применить некоторые трансформации к изображениям: вращение, изменение масштаба, сдвиг изображений, изменение яркости, отражение по вертикали и горизонтали, цветокоррекцию. Стоит учитывать, что отражение по вертикали или по горизонтали и сильная цветокоррекция могут привести к потере смысла некоторых дорожных знаков.

В работе для каждого изображения обучающего набора данных было сформировано по 16 новых со случайным применением трансформации, т. е. обучающий набор был увеличен с 23 088 до 369 408 фото. Пример оригинальных фотографий из базы RTSD-r1 представлен на рис. 7, а, после трансформаций — на рис. 7, б.



**Рис. 7.** Пример изображений из RTSD-r1:  
а — оригинальные; б — после трансформаций

Графики дополнительного обучения представлены на рис. 8, а и б.  
В итоге получены следующие значения:

- количество эпох: 13;
- общая точность (*accuracy*): 0,99363 (+0,01462 по сравнению с первым обучением);
- функция потерь (*loss-функция*): 0,02339 (–0,05855 по сравнению с первым обучением);
- общее время обучения: 4 237 с (70 мин 37 с).






Рис. 8. Графики процесса обучения для обучающих (*train*) и проверочных (*val*) данных: *а* — точность классификации в процессе обучения; *б* — функция потерь

**Оценка достигнутых результатов.** Чтобы понять, какие ситуации могут вызывать затруднения классификации, полезно увидеть ошибки модели. Примеры изображений из RTSD-r1, на которых модель дала неверные результаты, представлены на рис. 9. На столбчатой диаграмме ниже приведены значения, полученные с трех выходов модели, вероятности которых максимальны. Зеленый столбец указывает на выход модели, который соответствует правильному классу дорожного знака, красный — неправильному.

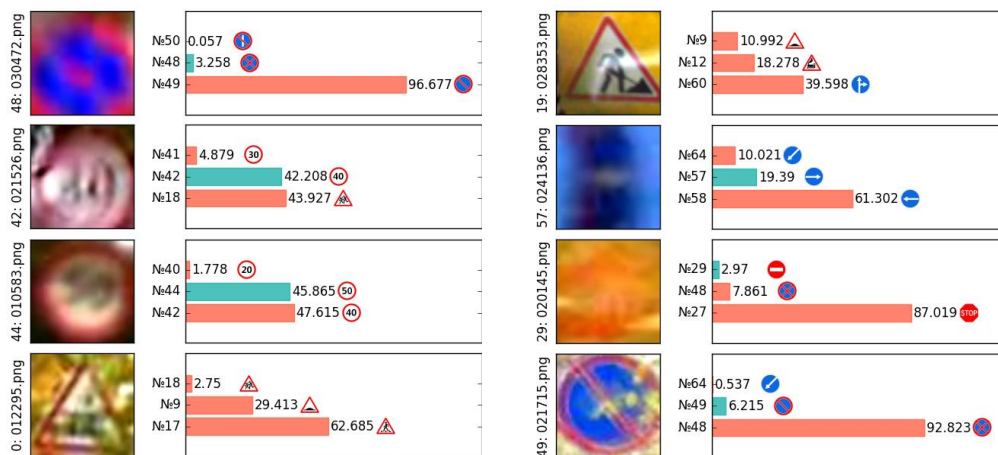
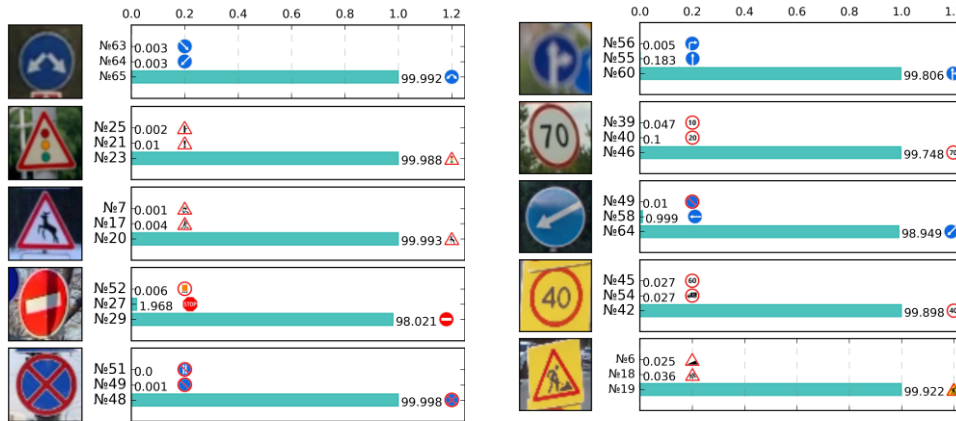


Рис. 9. Примеры ошибочной классификации обученной модели на изображениях из RTSD-r1

Заметим, что некоторые изображения трудноразличимы даже для человека, но другие, в силу наличия бликов, перекрытия другими объектами (листьями деревьев) и искажений, привели к неверной классификации.

Для дополнительной проверки модели также были выбраны некоторые новые изображения, которые можно сделать самостоятельно или загрузить с он-

лайн-ресурсов. На рис. 10 показаны примеры правильно классифицированных фото со значениями вероятностей от 0,98 и выше.



**Рис. 10.** Пример работы обученной модели на изображениях, полученных из открытого доступа

**Выводы.** В работе рассмотрен процесс проектирования и обучения сверточной нейронной сети для классификации российских дорожных знаков из базы данных Russian Traffic Sign Dataset из выборки RTSD-r1, представлены и визуализированы достигнутые результаты и имеющиеся ошибки. Отметим, что полученное значение точности классификации дорожных знаков 0,99363 главным образом связано с выбранной базой изображений RTSD-r1, а значения точностей на других изображениях могут варьироваться в зависимости от многих критериев: количества фотографий, факторов съемки и других, которые могли быть не учтены в силу ограниченности доступных и подготовленных данных.

### Литература

- [1] Shruti J., Sudip P. Recent trends in image and signal processing in computer vision. Springer, 2020.
- [2] Kamusoko C. Image classification. In: Remote sensing image classification in R. Springer, 2019, pp. 81–153.
- [3] Russakovsky O., Deng J., Su H., et al. ImageNet large scale visual recognition challenge. *Int. J. Comput. Vis.*, 2015, vol. 115, no. 3, pp. 211–252. DOI: <https://doi.org/10.1007/s11263-015-0816-y>
- [4] Shadman S., Nazib A., Kabir J.A., et al. An overview of convolutional neural network. *Preprints*, 2018, art. 2018110546. DOI: <https://doi.org/10.20944/preprints201811.0546.v1>
- [5] O'Shea K., Nash R. An introduction to convolutional neural networks. *arxiv.org: веб-сайт*. URL: <https://arxiv.org/abs/1511.08458v2> (дата обращения: 20.03.2020).
- [6] LeCun Y., Bottou L., Bengio Y., et al. Gradient-based learning applied to document recognition. *Proc. IEEE*, 1998, vol. 86, no. 11, pp. 2278–2324. DOI: <https://doi.org/10.1109/5.726791>
- [7] Krizhevsky A., Sutskever I., Hinton G.E., et al. Imagenet classification with deep convolutional neural networks. *Proc. NIPS*, 2012, pp. 1097–1105.

- [8] Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. *arxiv.org: веб-сайт*. URL: <https://arxiv.org/abs/1409.1556> (дата обращения: 20.03.2020).
- [9] Szegedy Ch., Liu W., Jia Ya., et al. Going deeper with convolutions. *IEEE CVPR*, 2015. DOI: <https://doi.org/10.1109/CVPR.2015.7298594>
- [10] He K., Zhang X., Ren Sh., et al. Deep residual learning for image recognition. *IEEE CVPR*, 2016, pp. 770–778. DOI: <https://doi.org/10.1109/CVPR.2016.90>
- [11] Шахуро В.И., Конушин А.С. Российская база изображений автодорожных знаков. *Компьютерная оптика*, 2016, т. 40, № 2, с. 294–300. DOI: <https://doi.org/10.18287/2412-6179-2016-40-2-294-300>
- [12] Kingma D.P., Ba J.L. Adam: a method for stochastic optimization. *arxiv.org: веб-сайт*. URL: <https://arxiv.org/abs/1412.6980> (дата обращения: 20.03.2020).
- [13] Ajiboye A., Arshah A., Qin R., et al. Evaluating the effect of dataset size on predictive model using supervised learning technique. *IJSECS*, 2015, 1. pp. 74–84. DOI: <https://doi.org/10.15282/ijsecs.1.2015.6.0006>

**Матвеев Дмитрий Александрович** — студент кафедры «Системы автоматического управления», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

**Петруничева Александра Сергеевна** — студентка кафедры «Стартовые ракетные комплексы», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

**Научный руководитель** — Парфентьев Кирилл Викторович, старший преподаватель кафедры «Системы автоматического управления» и кафедры «Программное обеспечение ЭВМ и информационные технологии», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

**Ссылку на эту статью просим оформлять следующим образом:**

Матвеев Д.А., Петруничева А.С. Разработка модели сверточной нейронной сети для классификации российских дорожных знаков. *Политехнический молодежный журнал*, 2020, № 09(50). <http://dx.doi.org/10.18698/2541-8009-2020-09-640>

---

## DEVELOPMENT OF A CONVOLUTIONAL NEURAL NETWORK MODEL FOR THE CLASSIFICATION OF RUSSIAN TRAFFIC SIGNS

D.A. Matveev

matveevda@student.bmstu.ru

SPIN-code: 4619-4962

A.S. Petrunicheva

alexandrapetrunicheva@gmail.com

SPIN-code: 8140-4969

Bauman Moscow State Technical University, Moscow, Russian Federation

---

### Abstract

The traffic sign classification system can be used both as an independent solution for image analysis tasks, and as part of a car computer vision system for solving problems of driver assistance and autonomous control. The paper considers some modern approaches in the field of image classification using convolutional neural networks, analyzes their typical architectures and features, describes the stages of developing and training a model of such a neural network. The presented results were obtained based on the use of the database of images of Russian traffic signs — Russian Traffic Sign Dataset (RTSD). The software implementation of the algorithms for training the neural network model and its analysis was carried out in Python using the Keras library on the public platform Google Colaboratory.

### Keywords

Computer vision, convolutional neural network, neural network training, image classification problem, traffic sign classification, Russian Traffic Sign Dataset, Google Colaboratory, Keras

Received 30.07.2020

© Bauman Moscow State Technical University, 2020

---

### References

- [1] Shruti J., Sudip P. Recent trends in image and signal processing in computer vision. Springer, 2020.
- [2] Kamusoko C. Image classification. In: Remote sensing image classification in R. Springer, 2019, pp. 81–153.
- [3] Russakovsky O., Deng J., Su H., et al. ImageNet large scale visual recognition challenge. *Int. J. Comput. Vis.*, 2015, vol. 115, no. 3, pp. 211–252. DOI: <https://doi.org/10.1007/s11263-015-0816-y>
- [4] Shadman S., Nazib A., Kabir J.A., et al. An overview of convolutional neural network. *Preprints*, 2018, art. 2018110546. DOI: <https://doi.org/10.20944/preprints201811.0546.v1>
- [5] O'Shea K., Nash R. An introduction to convolutional neural networks. *arxiv.org: website*. URL: <https://arxiv.org/abs/1511.08458v2> (accessed: 20.03.2020).
- [6] LeCun Y., Bottou L., Bengio Y., et al. Gradient-based learning applied to document recognition. *Proc. IEEE*, 1998, vol. 86, no. 11, pp. 2278–2324. DOI: <https://doi.org/10.1109/5.726791>
- [7] Krizhevsky A., Sutskever I., Hinton G.E., et al. Imagenet classification with deep convolutional neural networks. *Proc. NIPS*, 2012, pp. 1097–1105.

- [8] Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. *arxiv.org: website*. URL: <https://arxiv.org/abs/1409.1556> (accessed: 20.03.2020).
- [9] Szegedy Ch., Liu W., Jia Ya., et al. Going deeper with convolutions. *IEEE CVPR*, 2015. DOI: <https://doi.org/10.1109/CVPR.2015.7298594>
- [10] He K., Zhang X., Ren Sh., et al. Deep residual learning for image recognition. *IEEE CVPR*, 2016, pp. 770–778. DOI: <https://doi.org/10.1109/CVPR.2016.90>
- [11] Shakhuro V.I., Konushin A.S. Russian traffic sign images dataset. *Komp'yuternaya optika* [Computer Optics], 2016, vol. 40, no. 2, pp. 294–300. DOI: <https://doi.org/10.18287/2412-6179-2016-40-2-294-300> (in Russ.).
- [12] Kingma D.P., Ba J.L. Adam: a method for stochastic optimization. *arxiv.org: website*. URL: <https://arxiv.org/abs/1412.6980> (accessed: 20.03.2020).
- [13] Ajiboye A., Arshah A., Qin R., et al. Evaluating the effect of dataset size on predictive model using supervised learning technique. *IJSECS*, 2015, 1. pp. 74–84. DOI: <https://doi.org/10.15282/ijsecs.1.2015.6.0006>

**Matveev D.A.** — Student, Department of Automatic Control Systems, Bauman Moscow State Technical University, Russian Federation.

**Petrunicheva A.S.** — Student, Department of Rocket Launch Complexes, Bauman Moscow State Technical University, Russian Federation.

**Scientific advisor** — Parfentiev K.V., Senior Lecturer, Department of Automatic Control Systems and Department of Computer Software and Information Technologies, Bauman Moscow State Technical University, Russian Federation.

**Please cite this article in English as:**

D.A. Matveev, A.S. Petrunicheva. Development of a convolutional neural network model for the classification of Russian traffic signs. *Politekhnikheskiy molodezhnyy zhurnal* [Politechnical student journal], 2020, no. 09(50). <http://dx.doi.org/10.18698/2541-8009-2020-09-640.html> (in Russ.).