

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ И ТЕЛЕКОММУНИКАЦИИ
INFORMATION TECHNOLOGY AND TELECOMMUNICATIONS

УДК 004.032



DOI: 10.21822/2073-6185-2023-50-3-118-123

Оригинальная статья /Original article

Анализ и обучение модели нейронной сети распознавания дорожных знаков

А.У. Менциев¹, Т.Г. АйгуMOV², Э.М. Абдулмукминова²

¹Чеченский государственный университет им. А.А. Кадырова»,

¹364060, г. Грозный, Бульвар Дудаева, 17а, Россия,

²Дагестанский государственный технический университет,

²367026, г. Махачкала, пр-т. Имама Шамиля, д. 70, Россия

Резюме. Цель. Целью исследования является разработка и обучение модели нейронной сети на основе сверточных нейронных сетей для эффективного распознавания дорожных знаков на изображениях. **Метод.** Используются методы глубокого обучения, а именно сверточные нейронные сети, которые позволяют автоматически извлекать характеристики изображений и обучаться на большом наборе данных. Методика исследования включала следующие этапы: сбор и подготовку разнообразных данных дорожных знаков, создание и обучение модели нейронной сети на основе сверточных слоев, применение методов увеличения данных для повышения производительности модели, и оценку эффективности модели на тестовом наборе данных. **Результат.** Разработана модель нейронной сети, способная классифицировать различные типы дорожных знаков на основе входных изображений с высокой точностью. Модель была обучена на разнообразных и качественных данных, что позволило ей обобщать и распознавать дорожные знаки в различных условиях освещения и ракурсах камеры. Применение методов увеличения данных существенно повысило производительность модели и улучшило ее способность к обобщению. **Вывод.** Исследование подчеркивает важность использования разнообразных и качественных данных для обучения модели и применение методов увеличения данных для повышения ее производительности. Исследование подтверждает эффективность использования нейронных сетей, особенно сверточных нейронных сетей, для задачи распознавания дорожных знаков на изображениях.

Ключевые слова: анализ данных, нейронная сеть, распознавание данных, сверточные сети, машинное обучение.

Для цитирования: А.У. Менциев, Т.Г. АйгуMOV, Э.М. Абдулмукминова. Анализ и обучение модели нейронной сети распознавания дорожных знаков. Вестник Дагестанского государственного технического университета. Технические науки. 2023; 50(3):118-123. DOI:10.21822/2073-6185-2023-50-3-118-123

Analysis and training of a traffic sign recognition neural network model

A.U. Mentsiev¹, T.G. Aigumov², E.M. Abdulkumminova²

¹A.A. Kadyrov Chechen State University,

¹17a Dudaeva Boulevard, Grozny 364060, Russia,

²Daghestan State Technical University,

²70 I. Shamilya Ave., Makhachkala 367026, Russia

Abstract. Objective. The purpose of the research is to develop and train a neural network model based on convolutional neural networks for effective recognition of road signs in images. **Method.** Deep learning methods were used, namely convolutional neural networks, which allow you to automatically extract image characteristics and train on a large data set. The research methodology included the following steps: collecting and preparing a variety of road sign data, creating and training a neural network model based on convolutional layers, applying data

augmentation methods to improve model performance, and evaluating the model's effectiveness on a test data set. **Result.** A neural network model is developed that can classify various types of road signs based on input images with high accuracy. The model was trained on diverse and high-quality data, allowing it to generalize and recognize road signs in different lighting conditions and camera angles. The use of data augmentation techniques significantly increased the model's performance and improved its generalization ability. **Conclusion.** The study highlights the importance of using diverse and high-quality data to train a model and applying data augmentation techniques to improve its performance. The study confirms the effectiveness of using neural networks, especially convolutional neural networks, for the task of recognizing road signs in images.

Keywords: data analysis, neural network, data recognition, convolutional networks, machine learning.

For citation: A.U. Mentsiev, T.G. Aigumov, E.M. Abdulmukminova. Analysis and training of a traffic sign recognition neural network model. Herald of Daghestan State Technical University. Technical Science. 2023; 50(3):118-123. DOI:10.21822/2073-6185-2023-50-3-118-123

Введение. Целью данного исследования является разработка и обучение модели нейронной сети для распознавания дорожных знаков на изображениях. Задача состоит в создании модели, способной классифицировать различные типы дорожных знаков на основе входных изображений. Для достижения этой цели будут использованы методы глубокого обучения, в частности, сверточные нейронные сети, а также алгоритмы увеличения данных для повышения производительности модели.

Постановка задачи. Научная новизна данного исследования заключается в применении нейронных сетей и методов глубокого обучения для задачи распознавания дорожных знаков. В частности, использование сверточных нейронных сетей позволяет изучать особенности изображений дорожных знаков и автоматически извлекать характеристики, которые помогут в их классификации. Также, применение методов увеличения данных позволяет улучшить производительность модели и повысить ее способность к обобщению.

Нейронные сети были впервые предложены в 1940-х годах как вычислительная модель, вдохновленная структурой и функцией биологических нейронов в мозге. Однако только в 1980-х годах был открыт алгоритм обратного распространения для обучения нейронных сетей, что привело к возрождению интереса и развитию в этой области. С тех пор было сделано много достижений в архитектуре, алгоритмах обучения и приложениях нейронных сетей, включая разработку сверточных нейронных сетей (convolutional neural networks CNN) для обработки изображений и видео, рекуррентных нейронных сетей (recurrent neural networks RNN) для последовательных данных и генеративно-сопоставительных сетей (generative adversarial networks GAN) для генерации новых данных. На современном уровне развития нейронных сетей преобладают модели глубокого обучения, которые представляют собой многоуровневые нейронные сети, и их успешное применение в таких областях, как компьютерное зрение, обработка естественного языка и обучение с подкреплением [1].

Методы исследования. Распознавание объектов. Исследования в области нейронных сетей – это динамичная и активная область с большим и растущим сообществом исследователей и практиков. Некоторые текущие области исследований включают разработку более эффективных и точных алгоритмов обучения, улучшение интерпретируемости нейронных сетей, изучение новых архитектур и типов слоев, разработку методов работы с неструктурированными и неполными данными, а также исследование связей между нейронными сетями и другими областями. машинное обучение и искусственный интеллект. Кроме того, продолжают исследования теоретических свойств нейронных сетей, таких как их выразительность и способность аппроксимировать функции, а также этические и социальные последствия их использования в различных приложениях [2]. Исследования нейронных сетей направлены на углубление нашего понимания этих мощных моделей и улучшение их возможностей для решения сложных задач.

Нейронные сети успешно применяются для распознавания дорожных знаков, то есть обнаружения и классификации дорожных знаков на изображениях или видеопотоках.

Обычно для этой задачи используются сверточные нейронные сети. Они хорошо подходят для задач обработки изображений, поскольку они могут изучать особенности необработанных данных пикселей, которые затем можно использовать для классификации. Входом в сеть является изображение дорожного знака, а выходом – классификация типа знака. Для обучения сети требуется большой набор данных дорожных знаков. Этот набор данных должен быть разнообразным и включать широкий спектр дорожных знаков, условий освещения и ракурсов камеры. Затем сеть обучается с помощью «обучения с учителем», когда оператор показывает сети изображение дорожного знака и правильную классификацию для этого знака [3]. После обучения сети ее можно использовать для обнаружения и классификации дорожных знаков в новых изображениях или видеопотоках. Это можно сделать в режиме реального времени, что делает его полезным для таких приложений, как беспилотные автомобили или усовершенствованные системы помощи водителю (advanced driver assistance systems ADAS) [4].

Нейронные сети продемонстрировали большие перспективы для распознавания дорожных знаков и являются ключевой технологией для развития транспорта и автономных транспортных средств.

Существует множество инструментов языков программирования для создания нейронных сетей, каждый из которых имеет свои сильные и слабые стороны. В данной работе рассмотрим наиболее популярные инструменты.

1. Python + Keras: Python – популярный выбор для разработки нейронных сетей благодаря простоте использования и большому сообществу пользователей. Keras – это высокоуровневый API нейронной сети, созданный на основе Python и упрощающий создание и обучение нейронных сетей.
2. TensorFlow: TensorFlow – это платформа машинного обучения с открытым исходным кодом, разработанная Google, которая предоставляет ряд инструментов для создания и обучения нейронных сетей. Это одна из наиболее широко используемых сред для глубокого обучения, которая обеспечивает поддержку ряда языков, включая Python, C++ и Java.
3. PyTorch: PyTorch – еще одна популярная библиотека машинного обучения с открытым исходным кодом, разработанная Facebook. Она предоставляет ряд инструментов для построения и обучения нейронных сетей и особенно хорошо подходит для исследований и экспериментов благодаря динамическому графу вычислений.
4. Caffe: Caffe – это среда глубокого обучения, разработанная Berkeley Vision and Learning Center, которая хорошо подходит для задач классификации и сегментации изображений. Она обеспечивает поддержку C++, Python и MATLAB.
5. MATLAB: MATLAB – это популярный инструмент для научных вычислений, который предоставляет ряд инструментов для построения и обучения нейронных сетей. Он особенно хорошо подходит для прототипирования и экспериментов.

В конечном итоге, выбор языка программирования для создания нейронных сетей будет зависеть от конкретных потребностей проекта, а также предпочтений и навыков разработчика. Факторы, которые следует учитывать, включают простоту использования, производительность, гибкость и поддержку сообщества [5].

Обсуждение результатов. В рамках данного исследования был выбран Python совместно с библиотекой Keras по ряду причин:

1. Python является наиболее популярным языком программирования для научных вычислений и машинного обучения, обладая богатым набором библиотек и инструментов, включая Keras, TensorFlow, PyTorch, NumPy и другие;
2. Keras является модульной и гибкой библиотекой, позволяющей ясное и компактное описание моделей, что существенно облегчает процесс их отладки и анализа.

3. И Python, и Keras обладают крупными и активными сообществами, что обеспечивает хорошую поддержку и обилие доступных руководств и примеров кода, что значительно облегчает изучение и применение этих инструментов [6].

Рассмотрим в качестве примера часть кода для распознавания некоторых дорожных знаков на Python с использованием библиотеки Keras на рис. 1.

```
aug = ImageDataGenerator(
    rotation_range=10,
    zoom_range=0.15,
    width_shift_range=0.1,
    height_shift_range=0.1,
    shear_range=0.15,
    horizontal_flip=False,
    vertical_flip=False,
    fill_mode="nearest")

history = model.fit(aug.flow(X_train, y_train, batch_size=32), epochs=epochs, validation_data=(X_val, y_val))
```

Рис. 1. Код по увеличению изображения на обучающих данных

Fig. 1. Code for enlarging an image on training data

Предоставленный код обучает модель классификации дорожных знаков с использованием методов увеличения изображения. Создается объект ImageDataGenerator с именем aug, который будет выполнять различные операции по увеличению изображения на обучающих данных.

Указанные методы увеличения включают вращение, масштабирование, сдвиг и сдвиг, в то время как горизонтальное и вертикальное отражение отключено. Эти методы увеличения помогают преумножить разнообразие обучающих данных за счет создания дополнительных вариантов исходных изображений.

Затем модель обучается с использованием дополненных данных с помощью model.fit(), сгенерированных aug.flow(X_train, y_train, batch_size=32).

Метод потока генерирует увеличенные пакеты изображений и меток на лету, что позволяет проводить обучение с эффективным использованием памяти. Он принимает обучающие данные X_train и y_train, а также размер пакета 32.

Обучение проводилось в течение 30 эпох (epoch). Показатели хода обучения и проверки, включая потери и точность, записываются в объект истории (рис. 2).

Данные проверки (X_val, y_val) предоставляются для оценки производительности модели во время обучения (val_loss, val_acc).

```
Epoch 1/30
858/858 [-----] - 105s 123ms/step - loss: 1.1208 - acc: 0.7001 - val_loss: 0.1252 - val_acc: 0.9604
Epoch 2/30
858/858 [-----] - 100s 116ms/step - loss: 0.1849 - acc: 0.9443 - val_loss: 0.0338 - val_acc: 0.9903
Epoch 3/30
858/858 [-----] - 100s 116ms/step - loss: 0.1019 - acc: 0.9691 - val_loss: 0.0228 - val_acc: 0.9944
Epoch 4/30
858/858 [-----] - 100s 116ms/step - loss: 0.0790 - acc: 0.9765 - val_loss: 0.0121 - val_acc: 0.9967
Epoch 5/30
858/858 [-----] - 100s 117ms/step - loss: 0.0621 - acc: 0.9803 - val_loss: 0.0312 - val_acc: 0.9908
Epoch 6/30
858/858 [-----] - 106s 124ms/step - loss: 0.0553 - acc: 0.9828 - val_loss: 0.0142 - val_acc: 0.9961
Epoch 7/30
858/858 [-----] - 107s 125ms/step - loss: 0.0514 - acc: 0.9843 - val_loss: 0.0137 - val_acc: 0.9958
Epoch 8/30
858/858 [-----] - 108s 126ms/step - loss: 0.0410 - acc: 0.9872 - val_loss: 0.0144 - val_acc: 0.9952
Epoch 9/30
858/858 [-----] - 109s 127ms/step - loss: 0.0364 - acc: 0.9886 - val_loss: 0.0076 - val_acc: 0.9981
Epoch 10/30
858/858 [-----] - 109s 127ms/step - loss: 0.0344 - acc: 0.9892 - val_loss: 0.0068 - val_acc: 0.9979
Epoch 11/30
858/858 [-----] - 108s 126ms/step - loss: 0.0326 - acc: 0.9901 - val_loss: 0.0077 - val_acc: 0.9974
Epoch 12/30
858/858 [-----] - 107s 125ms/step - loss: 0.0305 - acc: 0.9906 - val_loss: 0.0070 - val_acc: 0.9974
Epoch 13/30
858/858 [-----] - 107s 125ms/step - loss: 0.0257 - acc: 0.9917 - val_loss: 0.0059 - val_acc: 0.9984
Epoch 14/30
858/858 [-----] - 107s 124ms/step - loss: 0.0233 - acc: 0.9934 - val_loss: 0.0069 - val_acc: 0.9979
Epoch 15/30
```

Рис. 2. Показатели хода обучения

Fig. 2. Training progress indicators

Во время обучения прогресс модели отображается для каждой эпохи, включая показатели потерь и точности как для обучающего, так и для проверочного наборов. Отображаемая информация показывает текущую эпоху, количество обработанных шагов или пакетов (858/858), время, затрачиваемое на шаг, а также значения потерь и точности. После каждой эпохи производительность модели оценивается на проверочном наборе.

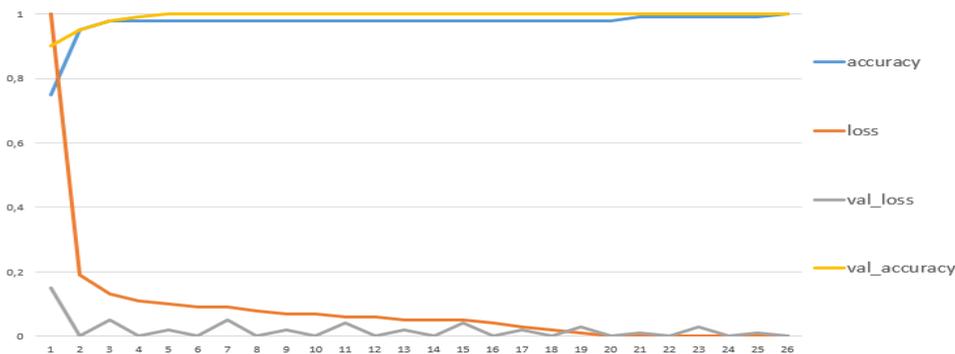
История обучения визуализируется (рис.3) с помощью pd.DataFrame(history.history).plot(), создавая линейный график показателей обучения и проверки (рис.4).

```
pd.DataFrame(history.history).plot(figsize=(8, 5))
plt.grid(True)
plt.gca().set_ylim(0, 1)
plt.show()
```

Рис.3. Код визуализации истории обучения**Fig. 3. Learning history visualization code**

Здесь значения потерь и точности при обучении и проверке отображаются в зависимости от эпох, что дает обзор производительности модели и потенциального переобучения или недообучения. Результирующий график отображается с помощью `plt.show()`.

Команды `plt.grid(True)` и `plt.gca().set_ylim(0,1)` соответственно включают сетку на графике и устанавливают пределы оси Y в диапазоне от 0 до 1.

**Рис.4. Визуализация истории обучения модели****Fig. 4. Visualization of model training history**

В целом, этот код демонстрирует процесс увеличения данных, обучения модели, сохранения модели и визуализации истории обучения для задачи классификации дорожных знаков. Важно подчеркнуть, что представленный код требует точного следования всем этапам обработки данных, которые были использованы при обучении модели. Данный подход гарантирует правильность и точность входных данных и обеспечивает верные результаты прогнозирования [7]. Рассмотренный пример демонстрирует, как можно использовать современные инструменты и библиотеки для создания и применения моделей глубокого обучения. Это подтверждает эффективность использования нейронных сетей в задачах классификации изображений, которые могут быть весьма востребованы в различных областях, включая автомобильную индустрию и системы безопасности дорожного движения.

Развитие нейронных сетей проложило путь для широкого спектра приложений в таких областях, как здравоохранение, финансы, транспорт и другие. Они стали незаменимым инструментом для решения сложных проблем и расширения нашего понимания окружающего мира [8].

Данное исследование имеет практическую значимость, поскольку распознавание дорожных знаков является важным компонентом различных приложений, включая системы безопасности дорожного движения и автономные транспортные средства. Предложенная модель может быть использована для автоматического распознавания и классификации дорожных знаков на основе входных изображений, что повышает эффективность и безопасность таких систем.

Вывод. Исследование нейронных сетей и их применение в распознавании дорожных знаков позволяет лучше понять и использовать возможности глубокого обучения в различных областях. Результаты исследования показывают, что использование нейронных сетей для распознавания дорожных знаков обладает высокой точностью и применимо для реальных сценариев, таких как автономные транспортные средства и системы помощи водителю. Однако, для достижения оптимальной производительности, необходимо обеспечить разнообразный и качественный набор данных для обучения моделей.

Дальнейшее развитие исследований в области нейронных сетей может привести к улучшению алгоритмов обучения, увеличению интерпретируемости моделей и расширению их применения в других сферах. Продвижение в этом направлении может принести значительный вклад в развитие искусственного интеллекта и повышение безопасности и эффективности транспортных систем.

Библиографический список:

1. Чухраев И.В., Ильичев В.Ю. Распознавание характерных объектов на изображении с использованием технологий компьютерного зрения // E-Scio. 2021. №8 (59). С. 1-10
2. Карпов К.Д., Холмогоров В.В. Система оценки качества изображения на основе компьютерного зрения // International Journal of Open Information Technologies. 2022. №12. С.62-66
3. Примкулов О.Д.У., Тожиев М.Р., Хасанов Д.Р.У. Компьютерное зрение как средство извлечения информации из видеоряда // Academic research in educational sciences. 2021. №9. С. 582-585
4. Менциев А.У., Айгунов Т.Г., Эмирова Г.А. Анализ характеристик и функциональных возможностей устройств IoT//Инженерный вестник Дона. 2023. № 2. URL: ivdon.ru/ru/magazine/archive/n2y2023/8191
5. Федутин К.А. Машинное обучение в задачах поддержки принятия решений при управлении охраной природы//Инженерный вестник Дона. 2022. № 9. URL: ivdon.ru/ru/magazine/archive/n9y2021/7186
6. Ветохин В.В., Ракитин Я.Е., Нестеренко И.А. Выбор средств реализации при разработке автоматизированной информационной системы с применением технологий машинного зрения // Столыпинский вестник. 2022. №4. С. 1958-1967
7. Шемарулин И.А., Карпычев В.Ю. Распознавание дорожных знаков на основе цветных контуров // Труды НГТУ им. Р. Е. Алексеева. 2016. №2 (113). С. 1-7
8. Захаров В.С. Технологии компьютерного зрения на российском и мировом рынках и их перспективы // Вестник ТИУиЭ. 2022. №1 (35). С. 114-115

References

1. Chukhraev I.V., Ilyichev V.Yu. Recognition of characteristic objects in the image using computer vision technologies. *E-Scio*. 2021;8 (59):1-10
2. Karpov K.D., Kholmogorov V.V. Image quality assessment system based on computer vision. *International Journal of Open Information Technologies*. 2022; 12:62-66
3. Primkulov O.D.U., Tozhiev M.R., Khasanov D.R.U. Computer vision as a means of extracting information from video. *Academic research in educational sciences*. 2021; 9: 582-585
4. Mentsiev A.U., Aigumov T.G., Emirova G.A. Analysis of the characteristics and functionality of IoT devices. *Engineering Bulletin of the Don*. 2023; 2. URL: ivdon.ru/ru/magazine/archive/n2y2023/8191 (In Russ)
5. Fedutinov K.A. Machine Learning in Decision Support Problems in Nature Conservation Management. *Inzhenerny Vestnik Dona*. 2022; 9. URL: ivdon.ru/ru/magazine/archive/n9y2021/7186(In Russ)
6. Vetokhin V.V., Rakitin Ya.E., Nesterenko I.A. The choice of means of implementation in the development of an automated information system using machine vision technologies. *Stolypinskiy Vestnik*. 2022;4: 1958-1967(In Russ)
7. Shemarulin I.A., Karpichev V.Yu. Recognition of road signs based on colored contours. *Proceedings of the NNSTU im. R. E. Alekseeva*. 2016; 2 (113): 1-7(In Russ)
8. Zakharov V.S. Computer vision technologies in the Russian and world markets and their prospects. *Bulletin of TIUE*. 2022;1 (35):114-115(In Russ)

Сведения об авторах:

Менциев Адам Умалтович, старший преподаватель, кафедра программирования и инфокоммуникационных технологий; a.mentsiev@chesu.ru

Айгунов Тимур Гаджиевич, кандидат экономических наук, доцент; заведующий кафедрой программного обеспечения вычислительной техники и автоматизированных систем 915533@mail.ru

Абдулмукуминова Элиза Мурадовна, студентка; eguri@inbox.ru

Information about the authors:

Adam U. Mentsiev, Senior Lecturer, Department of Programming and Infocommunication Technologies; a.mentsiev@chesu.ru

Timur G. Aigumov, Cand. Sci. (Econom), Assoc. Prof.; Head of Department, Department of Computer Software and Automated Systems 915533@mail.ru

Eliza M. Abdulkuminova, Student; eguri@inbox.ru

Конфликт интересов/Conflict of interest.

Авторы заявляют об отсутствии конфликта интересов/The authors declare no conflict of interest.

Поступила в редакцию/ Received 23.06.2023.

Одобрена после рецензирования/ Revised 18.07.2023.

Принята в печать/ Accepted for publication 18.07.2023.