

ОБУЧЕНИЕ НЕЙРОСЕТИ ДЛЯ ИДЕНТИФИКАЦИИ ДОРОЖНЫХ ЗНАКОВ В КОНТЕКСТЕ АВТОНОМНЫХ ТРАНСПОРТНЫХ СРЕДСТВ

М. А. АКПАЕВА¹, Г. М. ГИМАЛЕТДИНОВА¹

¹Международный университет Ала-Тоо (МУА),
(г. Бишкек, Киргизия)

E-mail: madinaakpaeva000@gmail.com

Аннотация. Рост числа автономных автомобилей и стремительное развитие технологий компьютерного зрения делают крайне важным проведение исследований по точности распознавания дорожных знаков. Это исследование важно, так как автономные машины в скором времени станут массовыми. Настоящая работа — начальный этап серии исследований, посвященных распознаванию городских дорожных знаков в различных условиях. Поскольку это первое исследование, в качестве начальной точки рассматривались только три типа знаков, а датасет для обучения был собран вручную и доступен в открытом доступе по ссылке [1]. После обучения модели была достигнута точность распознавания в 97%. Полученные результаты позволяют продолжить эксперименты с более широким спектром знаков в условиях повышенной сложности, включая ситуации с плохой видимостью, недостаточной освещенностью и другими факторами окружающей среды.

Abstract. The growing number of autonomous vehicles and the rapid development of computer vision technologies highlight the critical importance of research on the accuracy of road sign recognition. This study is significant as autonomous vehicles are expected to become mainstream in the near future. The present work represents the initial phase of a series of studies dedicated to the recognition of urban road signs under various conditions. Since this is a preliminary study, only three types of signs were considered as a starting point, and the dataset for training was manually collected and made publicly available at the provided link [1]. After training the model, an accuracy of 97% was achieved. The results obtained enable further experimentation with a broader range of signs in more challenging conditions, including scenarios with poor visibility, insufficient lighting, and other environmental factors.

Введение

Распознавание дорожных знаков напрямую влияет на безопасность и эффективность транспорта будущего. Эта область науки и технологий приближается к практическому применению, требуя высокой надежности и точности. С развитием автономных транспортных средств, способность точно и быстро распознавать дорожные знаки становится критически важной для предотвращения аварий и обеспечения безопасного движения. Технологии компьютерного зрения, такие как автоматическое распознавание знаков, помогают снизить влияние человеческого фактора и улучшить взаимодействие автомобилей с окружающей средой, повышая эффективность транспортных систем и безопасность на дорогах. В рамках данного проекта, посвященного классификации дорожных знаков, был применен искусственный интеллект (ИИ), который показывает хорошие результаты не только в распознавании знаков, но и находит успешное применение в других сферах [2, 3, 4, 5]. Разработанная на основе ИИ модель способна извлекать и обрабатывать ключевые признаки из изображений. В данной статье будут рассмотрены процессы обработки данных и методы, используемые для обучения данной модели.

Обработка данных

Эффективная обработка данных играет решающую роль в успешном обучении нейронных сетей, особенно в задачах распознавания изображений [6]. Одним из этапов предобработки является изменение размера изображений, что помогает сократить объем вычислений и ускорить процесс обучения. После ручного сбора датасета я обрезала изображения, чтобы на них оставались только дорожные знаки, убрав лишние элементы фона. Это позволило модели сосредоточиться на характеристиках знаков во время обучения. Для дальнейшего уменьшения нагрузки на вычислительные ресурсы все изображения были предварительно приведены к размеру 128x128 пикселей, что также позволило унифицировать их, так как изначально изображения имели разные размеры. Уменьшение размера изображений помогло снизить

нагрузку на вычислительные ресурсы и улучшило производительность модели, не теряя при этом значимых деталей, необходимых для точной классификации.

Далее было выполнено нормализация данных, преобразовав значения пикселей из диапазона [0, 255] в диапазон [0, 1] так как нейронные сети обучаются более стабильно и быстрее сходятся, когда входные данные находятся в диапазоне от 0 до 1 или от -1 до 1.

Аугментация данных

Аугментация данных — это процесс увеличения объема данных путем внесения случайных изменений в изображения. Этот метод помогает модели лучше обобщать данные и быть устойчивой к различным условиям, таким как изменение масштаба, яркости и положения объектов.

В этом проекте была интегрирована аугментация данных непосредственно в архитектуру модели, используя возможности библиотеки TensorFlow. Это позволило выполнять аугментацию "на лету" — изображения случайным образом преобразуются при каждом проходе через модель, что делает процесс динамичным и эффективным. Также был добавлен объект data augmentation в качестве первого слоя модели, применяя такие виды аугментации, как масштабирование, изменение контраста и смещение. Благодаря этому подходу, модель адаптировалась к разнообразию условий, что улучшило её способность к обобщению и повысило точность на реальных изображениях.

Обучение модели

В проекте по классификации дорожных знаков была разработана нейронная сеть, использующая структуру, которая позволяет последовательно соединять слои обработки данных.

Модель состоит из 15 слоев, включая 4 слоя свертки (2D Convolutional Layer) с количеством ядер (convolutional kernels) 16, 32, 64 и 128 соответственно, каждый из которых использует активацию ReLU и регуляризацию L2, а также 4 слоя подвыборки (Max Pooling 2D) с размером окна 2x2, которые помогают уменьшить размерность изображений.

На начальных этапах обработки изображения, сверточные слои (2D Convolutional Layer) извлекают ключевые визуальные признаки, такие как контуры и края дорожных знаков. Эти слои анализируют изображения и выделяют важные элементы, что позволяет разработанной модели более точно классифицировать знаки.

После каждого слоя свертки идет слой подвыборки, который способствует извлечению важных признаков и снижению вычислительных затрат. После слоев свертки и подвыборки идет слой выпрямления (Flatten), который преобразует данные в одномерный вектор, передаваемый в полносвязные слои. Модель включает два слоя с полными связями (Dense layer) с 256 и 128 нейронами. Последний слой — это выходной слой с 3 нейронами и активацией Softmax, который предназначен для классификации изображений на три класса (рисунок 1).

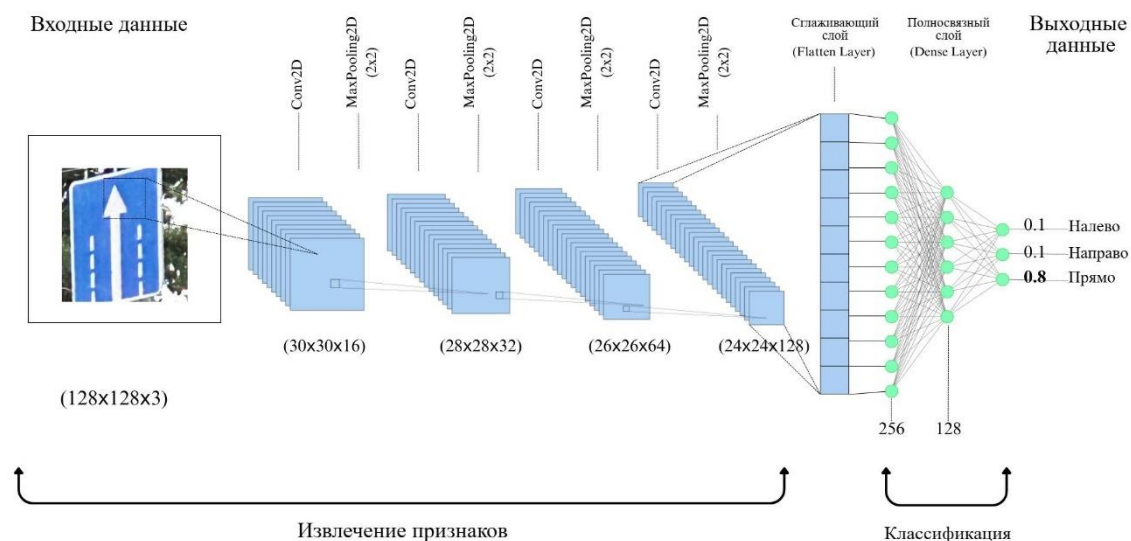


Рис. 1. Архитектура нейронной сети для классификации дорожных знаков
Секция 3 «Цифровая обработка сигналов и машинное обучение»

Сначала при обучении модели использовались полносвязные слои (Dense layer), но валидационная точность модели не поднималась выше 90%. Использование только Dense-слоёв без добавления 2D Convolutional Layer приводит к упущению важных пространственных особенностей изображения, так как такие слои не учитывают связи между соседними пикселями. После добавления 2D Convolutional Layer, точность повысилась до 94%.

В рамках проекта был применён механизм Dropout для улучшения обобщающей способности модели. Изначально точность сети составляла 94%, однако возникла проблема переобучения (overfitting): нейроны слишком точно подстраивались под конкретные детали изображений, такие как отдельные линии или контуры, что снижало способность модели к обобщению и ограничивало её эффективность в распознавании новых знаков. Чтобы устранить это, было внедрено случайное отключение части нейронов, побуждая модель искать общие признаки изображений, а не запоминать их отдельные детали. Благодаря этому точность сети увеличилась до 97%, и её устойчивость к новым изображениям значительно возросла.

В данном проекте по классификации дорожных знаков был использован метод оптимизации Adam (Adaptive Moment Estimation) Это оказалось особенно полезным при работе с разнообразными данными, где модель должна была учитывать множество признаков, таких как формы и цветовые различия знаков. Применение Adam помогло избежать застревания модели в локальных минимумах, позволяя ей более плавно и точно улучшить свои предсказания, что, в конечном итоге, повысило точность классификации.

Была использована функция потерь `sparse_categorical_crossentropy`, которая позволила эффективно оценивать точность модели, сравнивая её предсказания с фактическими метками. Для улучшения процесса обучения также был применен механизм Early Stopping. Он позволил контролировать производительность на проверочных данных и автоматически останавливать обучение, если улучшений не наблюдалось в течение 50 итераций. Механизмы Early Stopping и Dropout помогли предотвратить переобучение модели, улучшив её способность обобщать на новых данных [7].

Благодаря этим настройкам, модель смогла сохранить оптимальные параметры, что повысило её точность и устойчивость, обеспечив успешную классификацию дорожных знаков в различных условиях.

Заключение

Модель классификации дорожных знаков продемонстрировала точность 97%, благодаря использованию сверточных нейронных сетей и методов предобработки данных. Эти результаты создают надежную основу для дальнейших исследований. В настоящее время продолжается сбор датасета, и в будущем планируется расширение эксперимента с учетом более разнообразных знаков и сложных условий, таких как плохая видимость, низкое освещение и другие факторы окружающей среды. Результаты проекта могут быть применены для разработки систем помощи водителю и в автоматизированных транспортных системах, что подчеркивает актуальность внедрения технологий глубокого обучения в транспортную сферу и повседневную жизнь.

Список использованных источников

1. Traffic Signs Dataset <https://www.kaggle.com/datasets/madinaakpaeva/traffic-signs-dataset/>.
2. Shaiakhmetov D. et al. Morphological classification of galaxies using SpinalNet //2021 16th International Conference on Electronics Computer and Computation (ICECCO). – IEEE, 2021. – С. 1-5.
3. Toktosunova A. et al. Developing an Artificial Intelligence Tool for Image Generation Using a Unique Dataset with Image-to-Image Functionality //Proceedings of the International Conference on Computer Systems and Technologies 2024. – 2024. – С. 132-136.
4. Sadriddin Z., Mekuria R. R., Gaso M. S. Machine Learning Models for Advanced Air Quality Prediction //Proceedings of the International Conference on Computer Systems and Technologies 2024. – 2024. – С. 51-56.
5. Gaso M. S. et al. Utilizing Machine and Deep Learning Techniques for Predicting Re-admission Cases in Diabetes Patients //Proceedings of the International Conference on Computer Systems and Technologies 2024. – 2024. – С. 76-81.
6. Zhu Y., Yan W. Q. Traffic sign recognition based on deep learning //Multimedia Tools and Applications. – 2022. – Т. 81. – №. 13. – С. 17779-17791.
7. Lim X. R. et al. Recent advances in traffic sign recognition: approaches and datasets //Sensors. – 2023. – Т. 23. – №. 10. – С. 4674.