ТЕХНИКАЛЫҚ ҒЫЛЫМДАР
ТЕХНИЧЕСКИЕ НАУКИ
TECHNICAL SCIENCE

CENTRAL ASIAN SCIENTIFIC JOURNAL
ISSN 3135-3061
2026. №4 (32), Том 3. С. 66–71
DOI: https://doi.org/10.5281/zenodo.24622538
Сайт журнала: https://cajournal.kz

УДК 004.93

МОДЕЛИРОВАНИЕ ВЕРОЯТНОСТИ И ДАЛЬНОСТИ РАСПОЗНАВАНИЯ ДОРОЖНЫХ ЗНАКОВ ДЛЯ СИСТЕМ ПОМОЩИ ВОДИТЕЛЮ

Д.Е. Жомартбек
Евразийский национальный университет им. Л.Н. Гумилева, Астана, Казахстан

Жомартбек Досжан Ердосұлы — Студент 2 курса магистратуры образовательной программы «Транспорт, транспортной техники и технологии», Евразийский национальный университет им. Л.Н. Гумилева, Астана, Казахстан.

Научный руководитель: Тогизбаева Баглан Болсыновна — д.т.н., профессор, Евразийский национальный университет им. Л.Н. Гумилева, Астана, Казахстан.

© Д.Е. Жомартбек, 2026

Аннотация: В статье предложена комплексная модель оценки дальности и вероятности распознавания дорожных знаков бортовой системой технического зрения. Модель объединяет геометрическую зависимость размера изображения знака от расстояния и параметров камеры, временную модель наблюдения при движении автомобиля и вероятностную модель накопления решений по нескольким кадрам. Параметризация выполнена по результатам вычислительного эксперимента с классификатором CNN-M на наборе GTSRB. Точность базовой модели на официальной тестовой выборке составила 98,59%. Для камеры с шириной кадра 1920 пикселей и углом обзора 60° голосование по пяти кадрам обеспечило вероятность правильного решения не ниже 0,99 на расстоянии около 100 м. Исследование искажений показало, что наиболее опасными факторами являются сильный шум и частичное перекрытие изображения знака.

Ключевые слова: дорожные знаки, компьютерное зрение, ADAS, сверточная нейронная сеть, геометрическая модель, вероятностная модель, дальность распознавания.

Введение

Надёжное распознавание дорожных знаков является одной из базовых функций систем помощи водителю. Оно используется для информирования водителя, ограничения скорости, поддержки принятия решений и формирования входных данных для автоматизированных функций управления. В отличие от лабораторной классификации изображений, автомобильная система должна работать при изменении расстояния до знака, скорости движения, освещённости, наличии тумана, шума, смаза и частичного перекрытия объекта.

Большинство экспериментальных оценок качества нейросетевых классификаторов выполняется на фиксированных наборах данных. Такой подход позволяет сравнивать архитектуры, но не отвечает на инженерный вопрос: на каком расстоянии и с какой вероятностью система сформирует правильное решение в конкретной конфигурации камеры и при заданной скорости автомобиля. Цель настоящего исследования состоит в построении модели, связывающей параметры наблюдения, характеристики классификатора и правило накопления решений с дальностью уверенного распознавания.

Материалы и методы

В качестве исходного набора данных использован German Traffic Sign Recognition Benchmark (GTSRB), содержащий изображения 43 классов дорожных знаков. Для обучения применялись 23 976 изображений, для валидации – 2 664 изображения, а для итоговой оценки – 12 630 изображений официальной тестовой выборки. Изображения приводились к размеру 32×32 пикселя и нормализовались по каналам. Для повышения устойчивости использовалась аугментация с поворотом, сдвигом, масштабированием и изменением яркости, контраста и насыщенности.

Базовый классификатор CNN-M включает три сверточных блока с ядрами 3×3, пакетной нормализацией, функцией ReLU, субдискретизацией и прореживанием, а также двухслойный полносвязный классификатор. Число обучаемых параметров составляет 823 051. Эксперимент проводился на центральном процессоре без графического ускорителя, что приближает условия оценки к ограниченным вычислительным ресурсам бортовых систем.

Геометрическая модель формирования изображения

В модели камеры-обскуры фокусное расстояние в пикселях определяется через ширину кадра W и горизонтальный угол обзора φ:

$$f = W / (2\tan(\varphi/2)) \qquad (1)$$

Если физический размер дорожного знака равен D, а расстояние до камеры равно d, то размер изображения знака в пикселях можно оценить выражением:

$$s(d) = fD/d \qquad (2)$$

Таким образом, требование к минимальному размеру изображения, необходимому для заданной точности классификатора, преобразуется в требование к дальности распознавания. Для CNN-M экспериментально получены ориентиры: точность 90% достигается при размере изображения около 10,8 пикселя, 95% – при 12,9 пикселя, а 98% – при 20,1 пикселя.

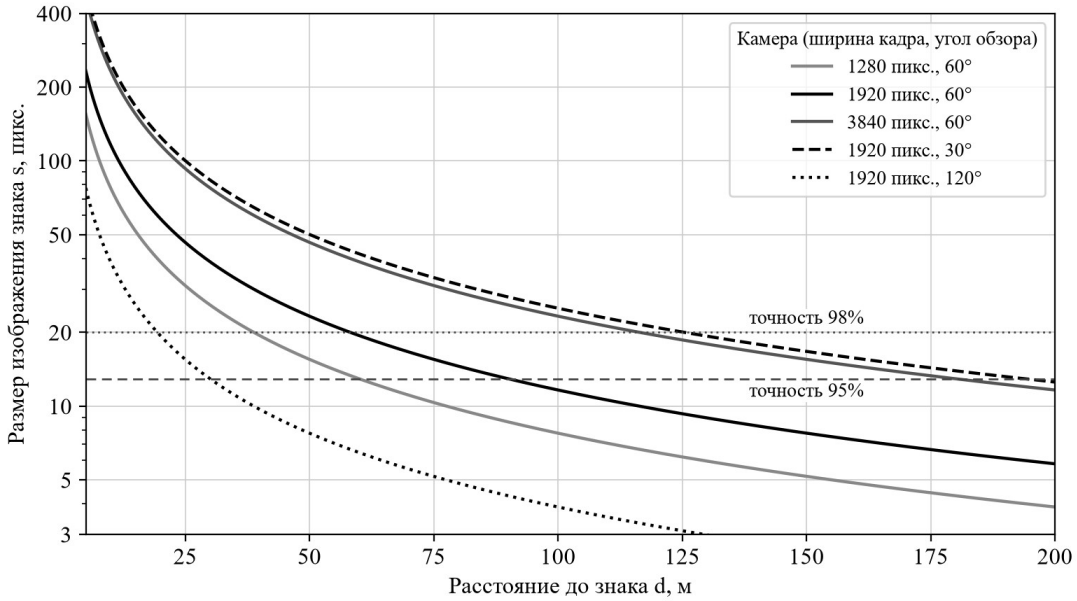


Рисунок 1 - Зависимость размера изображения знака от расстояния для различных параметров камеры

Из рисунка 1 видно, что увеличение ширины кадра при сохранении угла обзора повышает дальность, на которой знак сохраняет требуемый размер. Сужение угла обзора также увеличивает дальность, однако уменьшает минимальное расстояние наблюдения и ограничивает область сцены. Поэтому для дорожных знаков рациональны камеры среднего или узкого угла обзора, а широкоугольные камеры целесообразно использовать совместно с другими сенсорами.

© Central Asian Scientific Journal, 2026

Временная и вероятностная модели

При частоте кадров fc и скорости автомобиля v расстояние между положениями автомобиля на соседних кадрах определяется выражением:

$$\Delta d = v / fc \qquad (3)$$

Латентность τ включает экспозицию, считывание и передачу кадра, работу детектора, классификатора и модуля накопления решений. За время τ автомобиль проходит путь vτ, поэтому задержка обработки непосредственно уменьшает запас времени до проезда знака.

Покадровое решение не позволяет в общем случае достичь требуемой надёжности, поскольку вероятность правильной классификации ограничена характеристикой классификатора p(s). Для повышения надёжности используется голосование по n кадрам. С учётом прореживания соседних кадров через коэффициент к вероятность правильного итогового решения определяется как вероятность того, что число правильных решений M превысит половину окна голосования:

$$P_n = Pr(M > n/2) \qquad (4)$$

Прореживание необходимо для более осторожной оценки, поскольку соседние кадры содержат близкую информацию и ошибки классификации на них могут быть коррелированы. В качестве основного показателя рассматривается дальность уверенного распознавания DP, при которой Pn достигает заданного уровня P.

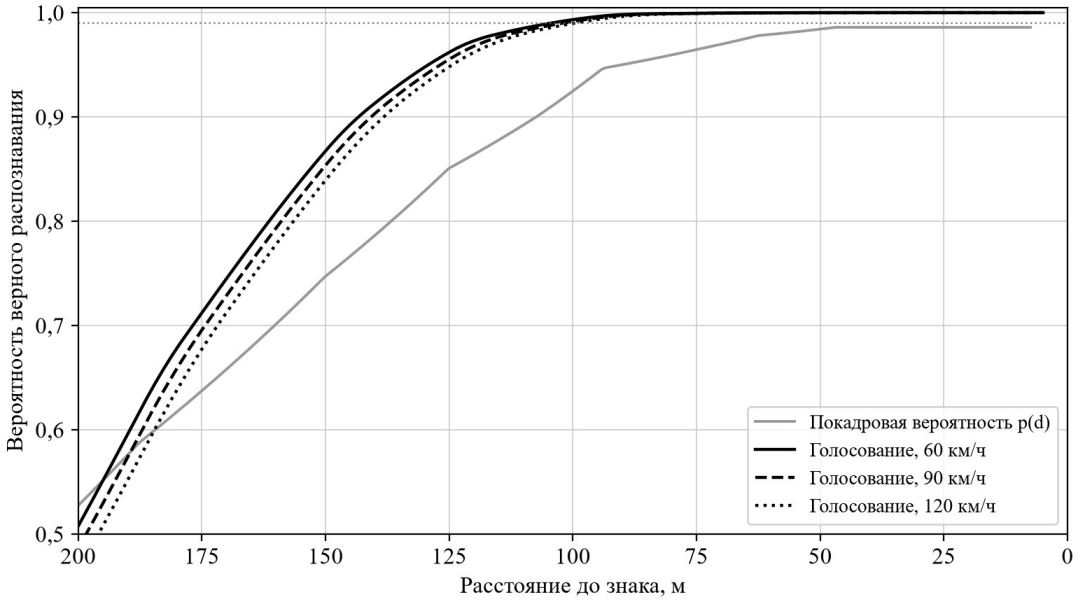


Рисунок 2 - Вероятность правильного распознавания в зависимости от расстояния при голосовании по кадрам

Результаты вычислительного эксперимента

Таблица 1 – Основные результаты эксперимента

Показатель	Значение
Точность CNN-M на тестовой выборке	98,59%
Средняя F1-мера по классам	97,63%
Размер изображения для точности 95%	около 12,9 пикселя
Камера базового варианта	1920 пикселей, 60°
Правило накопления решений	5 кадров, к = 3
Дальность при P ≥ 0,99	около 100 м

Базовая модель CNN-M достигла точности 98,59% и превзошла облегчённую модель CNN-S, точность которой составила 94,80%. Снижение размера изображения знака приводит к нелинейному падению качества: при 12 пикселях точность составила 94,7%, а при 5 пикселях – 31,5%. Поэтому оценка только по средней точности на крупномасштабных изображениях недостаточна для проектирования автомобильной системы.

Для базовой камеры покадровая классификация не обеспечивает вероятность правильного решения 0,99. После перехода к голосованию по пяти кадрам уровень 0,99 становится достижимым на расстоянии около 100 м. При скорости 90 км/ч расчётная дальность составляет 101,7 м, что соответствует запасу времени около 4,1 с до проезда знака. Увеличение окна голосования до девяти кадров повышает дальность примерно на 15 м.

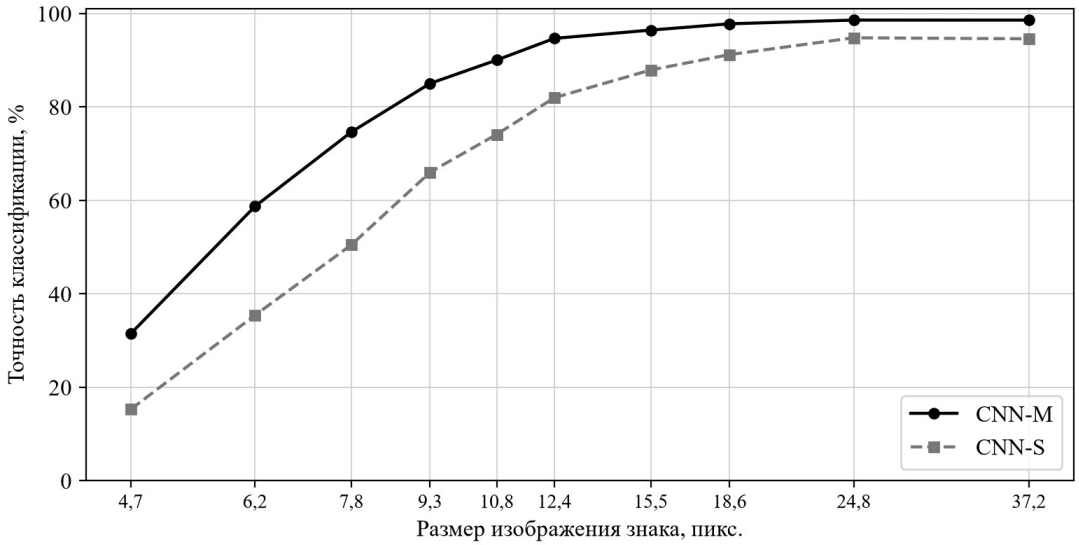


Рисунок 3 - Зависимость точности классификации от размера изображения знака для моделей CNN-M и CNN-S

Устойчивость к искажениям

Для оценки устойчивости к условиям эксплуатации в тестовые изображения вносились шум, смаз движения, затемнение, туман и частичное перекрытие. Умеренное затемнение и смаз движения снизили точность незначительно. Туман с долей 0,6 уменьшил точность до 92,6%, а гауссов шум с $\sigma = 0,2$ – до 70,8%. Наиболее сильное влияние оказало перекрытие: при закрытии 25% площади изображения точность снизилась до 38,9%.

© Central Asian Scientific Journal, 2026

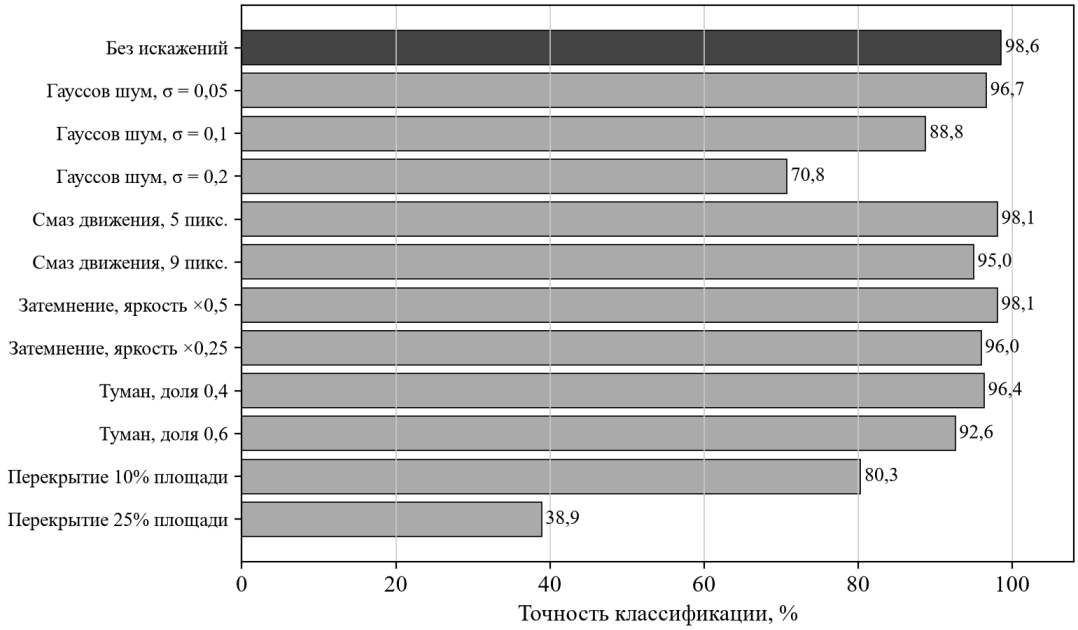


Рисунок 4 - Точность классификации при различных искажениях изображения

Полученные результаты показывают, что обучающие данные для автомобильной системы должны включать не только обычные изменения яркости и масштаба, но и сценарии частичного перекрытия, сильного шума, тумана, загрязнения и сезонных условий. Для Казахстана дополнительно важны снегопад, метель и пыльная буря. При этом требования следует проверять по отдельным классам: средняя точность скрывает случаи, когда отдельные сложные знаки распознаются существенно хуже.

Обсуждение

Предложенная модель позволяет связать три уровня описания системы. Геометрический уровень определяет, сколько пикселей занимает знак на заданном расстоянии. Временной уровень показывает, сколько кадров доступно для принятия решения и какой путь проходит автомобиль за время обработки. Вероятностный уровень оценивает эффект накопления решений и позволяет сравнивать правила голосования. Такое объединение превращает требования к системе из набора отдельных характеристик в проверяемую зависимость между камерой, классификатором и условиями движения.

Модель имеет ограничения. В ней не учитываются ошибки детектора, ошибки сопровождения и полная зависимость между соседними кадрами. Кроме того, зависимость p(s) усредняется по классам знаков, хотя отдельные классы могут иметь значительно более низкую полноту. Поэтому для внедрения необходимы натурные испытания, расширение набора данных и уточнение вероятностной модели на основе реальных последовательностей кадров.

Заключение

В работе разработана и параметризована комплексная модель системы распознавания дорожных знаков для современных автомобилей. Модель объединяет геометрическую, временную и вероятностную составляющие и позволяет оценивать дальность уверенного распознавания при заданных параметрах камеры, скорости и правилах накопления решений. Эксперимент на наборе GTSRB показал точность CNN-M 98,59%. Для камеры 1920 пикселей с углом обзора 60° голосование по пяти кадрам с учётом корреляции соседних кадров обеспечивает вероятность правильного решения не ниже 0,99 на расстоянии около 100 м.

Практически значимыми параметрами проектирования являются разрешение камеры, угол обзора, латентность всей цепочки обработки и размер окна голосования. Для повышения надёжности необходимо формировать обучающие данные с учётом национальных и климатических особенностей, контролировать качество по каждому классу знаков и дополнять модель ошибками детектора и результатами натурных испытаний.

Список литературы:

1. Stallkamp J., Schlipsing J., Salmen J., Igel C. Man vs. Computer: Benchmarking Machine Learning Algorithms for Traffic Sign Recognition // Neural Networks. 2012. Vol. 32. P. 323–332.

2. Cireşan D., Meier U., Masci J., Schmidhuber J. Multi-Column Deep Neural Network for Traffic Sign Classification // Neural Networks. 2012. Vol. 32. P. 333–338.

3. Paszke A., Gross S., Massa F. et al. PyTorch: An Imperative Style, High-Performance Deep Learning Library // NeurIPS 2019. P. 8024–8035.

4. Hartley R., Zisserman A. Multiple View Geometry in Computer Vision. 2nd ed. Cambridge: Cambridge University Press, 2004.

5. Zhang Z. A Flexible New Technique for Camera Calibration // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2000. Vol. 22, No. 11. P. 1330–1334.

6. González R. C., Woods R. E. Digital Image Processing. 4th ed. Pearson, 2018.

7. Yurtsever E., Lambert J., Carballo A., Takeda K. A Survey of Autonomous Driving: Common Practices and Emerging Technologies // IEEE Access. 2020. Vol. 8. P. 58443–58469.

8. SAE International. Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles. SAE J3016, 2021.

9. ISO 21448:2022. Road Vehicles – Safety of the Intended Functionality. Geneva: ISO, 2022.

10. Shorten C., Khoshgoftaar T. M. A Survey on Image Data Augmentation for Deep Learning // Journal of Big Data. 2019. Vol. 6. Art. 60.

© Central Asian Scientific Journal, 2026