

РАСПОЗНАВАНИЕ ДОРОЖНЫХ ЗНАКОВ СЕТЯМИ YOLO В УСЛОВИЯХ ОПТИЧЕСКИХ ИСКАЖЕНИЙ

Исследована проблема распознавания дорожных знаков Республики Беларусь в сложных метеорологических и оптических условиях нейронными сетями архитектуры YOLO. Сформирован уникальный набор данных методом краудсорсинга. Проведено стресс-тестирование модели при воздействии тумана, дождя, солнечной засветки и ночного освещения. Выявлены факторы деградации точности детекции. Предложены методы повышения отказоустойчивости автоматизированных транспортных систем за счет мультиспектральных камер, аугментации данных и оптимизации вычислительных узлов.

Введение

Надежное машинное зрение – критический элемент интеллектуальных транспортных систем (ИТС) и концепции автономного вождения. Существующие открытые наборы данных, такие как German Traffic Sign Recognition Benchmark (GTSRB), не учитывают специфику ГОСТов дорожных знаков Республики Беларусь, а также особенности их видимости в локальных климатических условиях.

Цель исследования формирование релевантного и сбалансированного датасета, обучение модели детекции на базе современных сверточных нейронных сетей и комплексный анализ ее производительности при плохой видимости для последующего проектирования автономных узлов видеофиксации.

I. Методология сбора и подготовки данных

Для решения проблемы "domain shift" (смещения домена) методом краудсорсинга был сформирован набор данных, включающий более 15 000 изображений белорусских дорожных знаков, снятых с видеорегистраторов в различных регионах страны.

Разметка объектов (bounding boxes) производилась вручную с присвоением классов согласно ПДД РБ. Массив был разделен на обучающую (70%), валидационную (20%) и тестовую (10%) выборки. Для повышения робастности модели применялись методы искусственной аугментации: Mosaic, MixUp, а также фильтры, имитирующие размытие в движении (Motion Blur) и изменение цветовой температуры.

Основой для детекции выступила архитектура семейства YOLO (You Only Look Once) [1], оптимизированная для задач реального времени. Выбор обусловлен ее способностью выполнять глобальный анализ изображения за один проход, что критично для устройств с ограниченными вычислительными ресурсами.

Качество детекции алгоритма оценивалось с помощью коэффициента Жаккара (Intersection over Union, IoU), метрики точности (Precision, P) и средней точности (Mean Average Precision, mAP):

$$IoU = \frac{|A \cap B|}{|A \cup B|}, \quad P = \frac{TP}{TP + FP} \quad (1)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (2)$$

где A – предсказанная рамка, B – истинная рамка, TP – истинно-положительные, FP – ложноположительные срабатывания, N – количество классов. В идеальных условиях базовая модель продемонстрировала $mAP@0.5$ свыше 92%.

II. Аппаратная реализация и ускорение

Для практического применения разработан автономный узел видеонаблюдения. Аппаратная база реализована на микрокомпьютере Raspberry Pi 4 Model B (4 ГБ RAM) в связке с высокочувствительным CMOS-сенсором.

Поскольку инференс глубоких нейронных сетей на CPU микрокомпьютера не позволяет достичь необходимой частоты кадров (FPS), архитектура была усилена тензорным ускорителем (NPU) по USB-интерфейсу (например, Google Coral Edge TPU). Модель YOLO была квантована до целочисленного формата INT8 с использованием фреймворка TensorRT, что позволило снизить задержку обработки кадра до 30-40 мс без критической потери точности.



Рис. 1 – Архитектура и компоненты аппаратно-программного комплекса системы распознавания на базе микрокомпьютера

III. Стресс-тестирование в сложных условиях

Основной фокус исследования направлен на оценку отказоустойчивости нейросети в сложных оптических условиях. В изолированной тестовой среде были смоделированы четыре сценария деградации визуального сигнала.

При плотной атмосферной дымке (туман) из-за эффекта рассеяния Рэля снижался контраст между объектом и фоном. Средний показатель уверенности модели падал до 75%. Наличие капель на объективе и стекающей воды на знаках (дождь) искажало геометрию объектов, действуя как микролинзы, роняя mAP до 60%.

Встречные солнечные лучи вызывали критическую засветку матрицы камеры ($P \approx 45\%$). Наиболее сложным паттерном оказалась ночь: при освещении знака исключительно фарами автомобиля на фоне темноты уверенность классификации падала до 35%.



Рис. 2 – Тестирование распознавания дорожных знаков в условиях оптических искажений

Выявлена нетипичная корреляция: дорожные знаки с новой световозвращающей пленкой алмазного типа распознавались хуже старых. Это связано с интенсивным отражением пучка света обратно в объектив, вызывающим локальный пересвет (клиппинг пикселей) на матрице камеры и "стирание" внутреннего контура знака.

IV. Методы компенсации и оптимизации

Для решения описанных проблем предложен комплексный подход:

Василевский Владислав Валерьевич, студент кафедры информационных технологий автоматизированных систем, БГУИР, vlad.vasilevskiy.07@gmail.com.

Рында Роман Дмитриевич, студент кафедры информационных технологий автоматизированных систем, БГУИР, romarynda1@gmail.com.

Павлов Евгений Александрович, студент кафедры информационных технологий автоматизированных систем, БГУИР.

Яцков Андрей Андреевич, студент кафедры информационных технологий автоматизированных систем, БГУИР.

Хмыз Дарья Дмитриевна, магистрант кафедры информационных технологий автоматизированных систем, БГУИР.

Научный руководитель: Шилин Леонид Юрьевич, доктор технических наук, профессор кафедры ИТАС, БГУИР, shilin@bsuir.by.

1. Программная компенсация: внедрение алгоритмов предварительной обработки изображений (алгоритм ретинекс для выравнивания освещенности) и расширенная аугментация обучающей выборки генеративно-состязательными сетями (GAN) для имитации капель воды.

2. Аппаратная модернизация: интеграция дополнительных каналов машинного зрения (инфракрасного диапазонов). Мультиспектральная съемка позволяет нивелировать влияние видимого спектра фар и полностью исключить слепоту камер от бликов световозвращающей пленки [2].

Заключение

Разработанная аппаратно-программная модель Edge-вычислений успешно справляется с детекцией дорожных знаков в стандартных условиях, однако анализ выявил критические уязвимости архитектуры YOLO к нелинейным оптическим искажениям. Внедрение мультиспектральных камер в связке с алгоритмами fusion-слияния датчиков на аппаратном узле является обязательным шагом для коммерциализации подобных систем. Полученные метрики и датасет имеют высокую практическую значимость для развития беспилотного транспорта в СНГ.

Список литературы

1. Redmon, J. YOLOv3: An Incremental Improvement / J. Redmon, A. Farhadi // arXiv preprint arXiv:1804.02767. – 2018.
2. Соколов, А. В. Методы цифровой обработки изображений в системах машинного зрения / А. В. Соколов. – М.: Техносфера, 2021. – 320 с.
3. Stallkamp, J. The German Traffic Sign Recognition Benchmark: A multi-class classification competition / J. Stallkamp [et al.] // IEEE International Joint Conference on Neural Networks. – 2011. – P. 1453-1460.
4. Bochkovskiy, A. YOLOv4: Optimal Speed and Accuracy of Object Detection / A. Bochkovskiy, C.-Y. Wang, H.-Y. Mark Liao // arXiv preprint arXiv:2004.10934. – 2020.