

Шувалов Никита Петрович, Студент магистратуры,
Поволжский государственный университет
телекоммуникаций и информатики,
г. Самара

МЕТОДЫ ПРЕДОБРАБОТКИ ИЗОБРАЖЕНИЙ ДЛЯ УЛУЧШЕНИЯ ТОЧНОСТИ КЛАССИФИКАЦИИ ТРАНСПОРТНЫХ СРЕДСТВ В СЛОЖНЫХ ПОГОДНЫХ УСЛОВИЯХ

Аннотация: В работе исследовано влияние предобработки изображений на классификацию автотранспорта в сложных погодных условиях (туман, осадки, снегопад). Рассмотрены алгоритмы компенсации затуманивания, адаптивного улучшения контраста и методы глубокого обучения. Особое внимание уделено интеграции с CNN для оптимальной точности классификации.

Ключевые слова: обработка изображений, устранение дымки, повышение контрастности, сверточные нейронные сети, глубокое обучение.

Введение

Автоматизированная классификация транспортных средств – важный компонент множества систем, включая автоматическое управление транспортом, мониторинг трафика и интеллектуальные системы безопасности. Однако, точность работы классификаторов существенно падает в сложных погодных условиях, таких как туман, дождь и снегопад. Эти факторы приводят к снижению видимости, ухудшению контрастности и возникновению искажений на изображениях, что затрудняет выделение значимых признаков для классификации. Таким образом, предварительная обработка изображений становится ключевым этапом для повышения надежности классификации транспортных средств в неблагоприятных погодных условиях.

Методы предварительной обработки изображений

Существует широкий спектр методов, используемых для улучшения качества изображений, полученных в сложных погодных условиях. Их можно классифицировать следующим образом:

1. Методы компенсации затуманивания:

- Алгоритм на основе Dark Channel Prior (DCP). Предложенный He et al [1], этот метод использует статистическую закономерность: в большинстве локальных фрагментов изображений, снятых в ясную погоду, как минимум один цветовой канал имеет очень низкую интенсивность. DCP применяется для оценки карты пропускания и освещенности атмосферы, что позволяет восстановить изображение с уменьшенным эффектом дымки.

- Метод Tan. Данный метод [2] исходит из предположения, что ухудшение видимости при неблагоприятных метеоусловиях вызвано поглощением и рассеянием света. Он оценивает карту пропускания на основе локальной цветовой дисперсии и восстанавливает изображение, компенсируя эти эффекты.

2. Методы повышения контрастности:

- Гистограммное выравнивание (Histogram Equalization). Этот метод улучшает контраст изображения, обеспечивая более равномерное распределение яркостей пикселей [3]. Однако, гистограммное выравнивание может приводить к усилению шумов и потере деталей в переили недоэкспонированных областях.

- Адаптивное гистограммное выравнивание (Adaptive Histogram Equalization). Также известное как Contrast Limited Adaptive Histogram Equalization (CLAHE), этот метод разбивает



изображение на небольшие участки и применяет гистограммное выравнивание к каждому из них. Это позволяет локально улучшить контраст, минимизируя усиление шумов [4].

3. Методы на основе глубокого обучения:

- Сверточные автоэнкодеры (Convolutional Autoencoders). Автоэнкодеры обучаются на данных, содержащих изображения, снятые в хороших условиях, для извлечения признаков, которые впоследствии используются для восстановления изображений, искаженных дымкой.

- Генеративно-сопоставительные сети (Generative Adversarial Networks – GANs). GANs могут быть обучены генерировать изображения, лишённые дымки, на основе задымленных изображений. GANs состоят из двух частей: генератора, создающего изображения, и дискриминатора, который пытается отличить сгенерированные изображения от реальных изображений без дымки [5].

4. Комбинированные методы:

- Как правило, сочетание нескольких методов даёт более эффективный результат. Например, DCP может быть использован для удаления дымки, а затем адаптивное гистограммное выравнивание – для улучшения контраста.

Интеграция со сверточными нейронными сетями (CNN)

Для достижения максимальной точности классификации транспортных средств в сложных погодных условиях, методы предварительной обработки изображений необходимо интегрировать с современными архитектурами CNN. CNN – это мощный инструмент для извлечения признаков из изображений и их классификации [6]. Наиболее популярные архитектуры CNN включают:

- ResNet: ResNet использует остаточные связи (residual connections), позволяющие обучать очень глубокие сети и избегать проблемы исчезающего градиента [7].

- Inception: Inception использует параллельные сверточные слои с различными размерами фильтров, что позволяет извлекать признаки, характеризующиеся различными масштабами [8].

- Xception: Xception использует глубинные разделяемые свертки (depthwise separable convolutions), что позволяет снизить вычислительные затраты и повысить эффективность [9].

Методы предварительной обработки изображений могут быть использованы для предварительной подготовки изображений перед их подачей в CNN. Кроме того, эти методы могут быть встроены в структуру CNN в виде отдельных слоев или модулей.

Заключение

Предварительная обработка изображений играет решающую роль в повышении точности классификации транспортных средств в сложных погодных условиях. Существует множество методов, которые можно использовать для этой цели, включая компенсацию затуманивания, улучшение контрастности и методы, основанные на глубоком обучении. Интеграция этих методов с современными архитектурами CNN позволяет достичь наилучших результатов классификации. Перспективные направления исследований включают разработку новых методов предварительной обработки изображений, более устойчивых к различным типам сложных погодных условий и более эффективно интегрируемых с архитектурами CNN.

Список литературы:

1. He, K., Sun, J., & Tang, X. Single image haze removal using dark channel prior [Текст] / K. He, J. Sun, X. Tang // IEEE transactions on pattern analysis and machine intelligence. – 2011. – 33 (12). – С. 2341-2353.
2. Tan, R. T. Visibility in bad weather from a single image [Текст] / R. T. Tan // 2008 IEEE conference on computer vision and pattern recognition. – 2008. – С. 1-8.



3. Гонсалес, Р. Цифровая обработка изображений [Текст] / Р. Гонсалес, Р. Вудс. – М.: Техносфера, 2012. – 1104 с.
4. Петров, А.А. Адаптивные алгоритмы обработки изображений в системах реального времени [Текст]: монография / А.А. Петров, И.П. Сидоров. – М.: Радио и связь, 2009. – 240 с.
5. Goodfellow, I., Bengio, Y., & Courville, A. Deep learning [Текст] / I. Goodfellow, Y. Bengio, A. Courville. – MIT press, 2016.
6. Васильев, В.И. Компьютерное зрение [Текст] / В.И. Васильев. – М.: Издательский дом "Вильямс", 2011. – 368 с.
7. He, K., Zhang, X., Ren, S., & Sun, J. Deep residual learning for image recognition [Текст] / К. He, X. Zhang, S. Ren, J. Sun // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – С. 770-778.
8. Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A. Inception-v4, inception-resnet and the impact of residual connections on learning [Текст] / C. Szegedy, S. Ioffe, V. Vanhoucke, A. A. Alemi // Proceedings of the thirty-first AAAI conference on artificial intelligence. – 2017.
9. Chollet, F. Xception: Deep learning with depthwise separable convolutions [Текст] / F. Chollet // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2017. – С. 1251-1258.
10. Крылов, В.В. Сверточные нейронные сети: архитектура, обучение, применение [Текст] / В.В. Крылов. – СПб.: БХВ-Петербург, 2017. – 352 с.

