

Лебедева Ольга Анатольевна,
к.т.н., доцент, Ангарский государственный технический университет,
e-mail: kravhome@mail.ru

Савватеева Екатерина Юрьевна,
бакалавр, Ангарский государственный технический университет,
e-mail: savvateeva.ket@gmail.com

МЕТОДИКА ОЦЕНКИ ИНТЕНСИВНОСТИ ДВИЖЕНИЯ НА ОСНОВЕ ДАННЫХ ВИДЕОНАБЛЮДЕНИЯ

Lebedeva O.A., Savvateeva E.Yu.

METHODOLOGY FOR ASSESSING TRAFFIC INTENSITY ON THE BASIS OF VIDEO SURVEILLANCE DATA

Аннотация. В работе приведен подход, основанный на передовых алгоритмах машинного обучения, целью которого является оценка транспортного потока на улично-дорожной сети. Данные получают с дорожных камер, расположенных в ограниченном количестве мест. Рассмотрен вероятностный алгоритм подсчета транспортных средств по некачественным изображениям, относящийся к категории неконтролируемого обучения.

Ключевые слова: видеонаблюдение, интенсивность движения, алгоритмы оптимизации.

Abstract. The paper presents an approach to intelligent transport systems based on advanced machine learning algorithms, the purpose of which is to estimate the traffic flow on the road network. Data is obtained from traffic cameras located in a limited number of places. The approach includes two main algorithms. The first is a probabilistic algorithm for counting vehicles from low-quality images, which belongs to the category of unsupervised learning.

Keywords: video surveillance, traffic intensity, optimization algorithms.

Транспортные заторы на улично-дорожной сети являются проблемой в городских районах развивающихся стран, где обнаруживаются несоответствия между экономикой и муниципальной инфраструктурой. Интеллектуальные транспортные системы (ИТС) обеспечивают базу для управления дорожным движением. Городам с быстрым темпом экономического роста требуется облегченная ИТС для адаптации к динамично меняющейся среде, которая проста в развертывании, имеет минимальные начальные затраты и предлагает достаточно хорошие функциональные возможности. В качестве альтернативы существующим полномасштабным системам возможен мониторинг на основе веб-камер. В целях городского планирования и оптимизации потока необходимо извлечь ключевую информацию о транспортных потоках из изображений с веб-камеры для всего городского пространства.

Проведено множество исследований мониторинга потока с помощью веб-камер: распознавание транспортных средств для оценки объема потока и регрессионное моделирование для подсчета транспортных средств внесли значительный вклад в решение ряда технических вопросов, однако можно выделить следующие не решенные задачи [1, 2].

Первая задача возникает при обработке изображения низкого качества. Из-за стоимости оборудования и его сохранности использование специальных камер ближнего обзора нецелесообразно. С другой стороны, применение камер общего назначения без специальных осветительных приборов ухудшает стандартные технологии распознавания объектов (при распознавании номерных знаков).

Вторая задача заключается в том, как исключить трудоемкий этап калибровки камеры при обработке изображений. Большинство исследований ИТС на основе видео сосредоточено на алгоритмах калибровки, когда камеры наблюдения не позволяют выполнять аппаратную калибровку. Распознавание транспортных средств выполняется на изображениях, требуется точная настройка камеры на основе геометрической конфигурации камер и улично-дорожной сети. Использование регрессионных моделей может снизить нагрузку, но для их применения требуются подсчитанные вручную или распознанные изображения.

Третья задача заключается в том, как получить информацию с ограниченного числа веб-камер. Моделирование оптимизации городского планирования требует оценки интенсивности движения на каждом отдельном звене дорожной сети.

Рассмотрим оценку потока на основе изображений. Актуальной тематикой исследований является замена традиционных дорогостоящих инфраструктур сбора данных более дешевыми альтернативными методами. На сегодняшний день в основном изучены два метода: GPS (глобальная система позиционирования) и камеры наблюдения. GPS это мощный инструмент сбора информации о дорожном движении на обширной территории. Помимо качества, серьезной проблемой является доступность данных GPS, которые являются собственностью компаний, владеющих коммуникационной инфраструктурой. Это мотивирует органы дорожного движения, не имеющие непосредственного доступа к устройствам GPS, искать другую альтернативу. Таким образом, использование камер наблюдения можно рассматривать как основное направление разработки облегченных ИТС.

Задача определения типичного размера транспортных средств на изображениях с учетом расстояния и углов до места наблюдения является актуальной в рамках мониторинга потока. Эти исследования основаны на стратегии индивидуального распознавания транспортных средств, что неосуществимо при некачественном изображении с веб-камер. Еще одна важная проблема, связанная с традиционным анализом потока на основе изображений, — это стоимость подготовки изображений с правильной маркировкой.

Задача оценки потока на сетевом уровне по частичным наблюдениям основана на двух подходах.

Первый подход – минимизация функции ошибки между наблюдаемыми и оцененными объемами при соблюдении условий сохранения потока.

Второй подход – использование байесовских сетей с использованием графической модели Гаусса. Эти подходы основаны на обоснованной теории GGM, одним из практических недостатков является отсутствие масштабируемости. Глобальное гауссовское предположение трудно применить к большим сетям из-за его вычислительной стоимости и численной нестабильности; таким образом, это вариант не подходит для общегородского мониторинга.

Подход к безкалибровочному анализу изображений низкого качества для подсчета транспортных средств состоит из двух этапов: извлечение данных и их подсчет. Так как веб-камеры анализируются независимо, алгоритм разберём для изображений с одной веб-камеры [3, 4].

Первый этап – извлечение данных. Пусть N – количество обучающих изображений камеры (все изображения имеют одинаковые M пикселей, и каждый из пикселей принимает целое число из 256 уровней яркости). Набор данных представлен как:

$$\mathcal{D}_0 = \{z^{(n)} \in \{0,1,2, \dots, 255\}^M | n = 1, \dots, N\} \quad (1)$$

Для каждого изображения в качестве предварительной обработки вычитаем медиану по M пикселям, чтобы обработать вариации (между ночным и дневным временем). Целью этапа является извлечение данных $x \in R$ из необработанного изображения $z \in \{0, \dots, 255\}^M$ такого, что x соответствует грубой оценке количества транспортных средств. Исходное изображение переводят в бинарное. После этого функция x вычисляется как отношение белых пикселей к общему количеству пикселей:

$$x = \frac{1}{M} \sum_{i=1}^M I(z_i \geq k^*), \quad (2)$$

где k^* – порог бинаризации, а $I(\cdot)$ – индикаторная функция, которая дает 1, когда аргумент верен, и 0 в противном случае.

Для нахождения порога k^* в обучающихся данных \mathcal{D}_0 определяем:

$$p_l \equiv \frac{1}{MN} \sum_{n=1}^N \sum_{i=1}^M I(z_i^{(n)} = l), \quad (3)$$

что можно рассматривать, как вероятность пикселя принимать значение яркости l . С этой вероятностью мы можем вычислить средние значения яркости как $\bar{\ell} \equiv \sum_{l=0}^{255} p_l l$. Точно так же средние значения яркости для черного и белого классов соответственно равны:

$$\ell_1(k) \equiv \frac{1}{P_1(k)} \sum_{l=0}^{k-1} p_l l, \quad \ell_2(k) \equiv \frac{1}{P_2(k)} \sum_{l=k}^{255} p_l l, \quad (4)$$

где $P_1(k) \equiv \sum_{l=0}^{k-1} p_l$ и $P_2(k) \equiv \sum_{l=k}^{255} p_l$ – функции порога k .

Оптимальный порог k^* определяется путем решения следующей оптимизационной задачи:

$$k^* = \arg \max_k \left[[\ell_1(k) - \bar{\ell}]^2 P_1(k) + [\ell_2(k) - \bar{\ell}]^2 P_2(k) \right], \quad (5)$$

где ℓ – значение яркости; $\bar{\ell}$ – средние значения яркости.

Эту задачу можно решить, оценив целевую функцию для всех 256 различных значений и выбрав то, которое дает максимум.

Схема вероятностного подсчета сводится к следующему. Учитывая оптимизированный порог k^* , обучающие данные \mathcal{D}_0 теперь преобразуются в:

$$\mathcal{D} \equiv \{x^{(n)} \in R | n = 1, \dots, N\} \quad (6)$$

На практике рекомендуется дополнительно стандартизировать функцию, поскольку $x^{(n)} \leftarrow 2[x^{(n)}/\max_{n'} x^{(n')}] - 1$ до подгонки модели. В общегородском мониторинге дорожного движения с использованием камер низкого качества задача сбора подсчитанных вручную изображений для каждой камеры является достаточно затратной. Рассматриваемый выше вариант – полностью неконтролируемый подход к подсчету транспортных средств.

Часть подсчета транспортных средств состоит из двух подэтапов. Во-первых, мы находим прогностическое распределение для признака x в форме смешанной модели Гаусса.

Во-первых, находим прогностическое распределение x в форме смешанной модели Гаусса:

$$p(x/\mathcal{D}) = \sum_{d=0}^{\mathcal{D}} \pi_d(x) \mathcal{N}(x | m^\top \phi_d, \sigma_d^2) \quad (7)$$

где d – количество транспортных средств, \top – транспонирование, $\phi_d \equiv \left(\frac{1}{d}\right)^\top$, \mathcal{N} — Гауссово распределение; $\pi_d(x)$ – стробирующая функция, m – коэффициенты.

Количество вариантов \mathcal{D} рассматривается как заданная константа и в дальнейшем фиксируется как $\mathcal{D} = \mathcal{N}$, чтобы задать его достаточно большим; дисперсия σ_d^2 задается как функция других параметров модели a , b и Σ как:

$$\sigma_d^2 = \frac{b}{a-1} + \phi_d^\top \Sigma \phi_d \quad (8)$$

После того, как прогностическая модель учтена в решении нахождение числа d' становится тривиальным. Для нового наблюдения $x = x'$ соответствующее количество транспортных средств d' определяется выражением:

$$d' = \arg \max_d \{\pi_d(x') \mathcal{N}(x' | m^\top \phi_d, \sigma_d^2)\} \quad (9)$$

В результате байесовского обучения компоненты, не относящиеся к данным, автоматически удаляются из модели. Функция \max оценивает одномерную функцию всего около десяти раз, что незначительно с точки зрения вычислительных затрат. Алгоритм может работать в режиме реального времени при обновлении изображения, которое обычно происходит каждые несколько секунд.

Изучение прогностической модели является сложной задачей в связи с взаимозаменяемостью кластеров в смешанной модели. Эту проблему можно решить вводя априорное распределение. Уравнения для нахождения параметров модели включают только простые операции с матрицей и вектором, которые чрезвычайно легко реализовать на языке программирования.

ЛИТЕРАТУРА

1. **Лебедева, О. А.** Повышение эффективности работы транспортной сети посредством применения интеллектуальных систем / О. А. Лебедева // Вестник Ангарского государственного технического университета. 2018. № 12. С. 189-191.

2. **Лебедева, О. А.** Байесовский метод оценки матрицы корреспонденций / О. А. Лебедева, А. Ю. Михайлов // Сборник научных трудов № 6 «Технология, организация и управление автомобильными перевозками. Теория и практика». ФГБОУ ВПО «СибАДИ». 2013. С. 56-58.

3. **Ide, T.** City-wide traffic flow estimation from limited number of low quality cameras / T. Ide, T. Katsuki, T. Morimura, R. Morris // IEEE Transactions on Intelligent Transportation Systems 18(4): pp. 1-10, 2016.

4. **Zuylen, H. J. V.** The most likely trip matrix estimated from traffic counts / H. J. V. Zuylen, L. G. Willumsen // Transportation Research Part B: Methodological, vol. 14, no. 3, pp. 281–293, 1980.