

# О МЕТОДАХ СБОРА И АНАЛИЗА ОСНОВНЫХ ХАРАКТЕРИСТИК ТРАНСПОРТНОГО ПОТОКА

DOI: 10.36724/2072-8735-2022-16-2-29-38

Manuscript received 16 January 2022;  
Accepted 10 February 2022

**Мосева Марина Сергеевна,**  
Московский технический университет связи  
и информатики, Москва, Россия,  
[m.s.moseva@mtuci.ru](mailto:m.s.moseva@mtuci.ru)

**Ключевые слова:** мониторинг транспортных потоков, классификация транспортных средств, нейросетевой алгоритм, расчет основных характеристик транспортного потока

Постоянно возрастающая автомобилизация приводит к необходимости решения проблем, связанных с оптимальным движением транспорта, обеспечением его безопасности и улучшением экологической ситуации. Согласно статистике Росстата, количество собственных легковых автомобилей по субъектам Российской Федерации (на 1000 человек населения) возрастает с каждым годом. Актуальными остаются вопросы оптимального управления движением транспортных средств. Моделирование транспортных потоков позволяет определить "узкие места" существующей улично-дорожной сети. В большинстве ситуаций наилучшим решением вышеуказанных проблем является совершенствование существующей транспортной системы. Данный подход является достаточно дорогостоящим. В связи с этим исследования, связанные с разработкой и применением современных и перспективных технологий при создании интеллектуальных транспортных систем различного уровня и назначения, являются актуальными как на сегодняшний день, так и в будущем. Сбор и анализ данных о транспортных потоках позволяют верифицировать модели, а также принимать решения о дальнейшем управлении движением транспортных средств. С развитием вычислительной техники и информационных технологий совершенствовались способы накопления и обработки информации о транспортных потоках. На сегодняшний день становится возможным получать, обрабатывать данные и принимать решения в режиме реального времени. Данное исследование посвящено обзору существующих методов мониторинга и сбора характеристик о состоянии транспортных потоков. Выполнен обзор современных технологий и сенсоров, используемых для сбора информации о дорожном движении. Приводится описание метода сбора данных об участниках дорожного движения. Разработан алгоритм классификации транспортных средств в зависимости от марки транспортного средства. Приводится описание алгоритма трекинга транспортных средств. Описана методика расчета основных характеристик транспортного потока (скорость, плотность, интенсивность) на основе данных из видеоряда.

#### Информация об авторе:

**Мосева Марина Сергеевна,** Кафедра "Математическая кибернетика и информационные технологии", Московский технический университет связи и информатики, Москва, Россия

#### Для цитирования:

Мосева М.С. О методах сбора и анализа основных характеристик транспортного потока // Т-Comm: Телекоммуникации и транспорт. 2022. Том 16. №2. С. 29-38.

#### For citation:

Moseva M.S. (2022) About methods for collecting and analyzing traffic flow characteristics. T-Comm, vol. 16, no.2, pp. 29-38. (in Russian)

**Введение**

Интенсивное развитие автомобильного транспорта и дорожной инфраструктуры привели к увеличению количества происшествий и возникновению значительных задержек при передвижении автотранспортом. Для достижения должного уровня безопасности на дорогах и оптимизации движения транспортных средств, в Российской Федерации и за рубежом проводятся исследования в области управления движением транспорта.

Согласно статистике Росстата, количество собственных легковых автомобилей по субъектам Российской Федерации (на 1000 человек населения) возрастает с каждым годом. Диаграмма роста по федеральным округам представлена на рисунке 1 [1].



**Рис. 1.** Рост количества легковых автомобилей в Российской Федерации

Согласно представленной выше диаграмме видно, что количество транспортных средств за 20 лет возросло примерно в четыре раза.

На рисунке 2 представлено количество легковых автомобилей, грузовых автомобилей и автобусов общего пользования, которые являются участниками дорожного движения [2].

Увеличение количества транспортных средств в городах приводит к увеличению протяженности и количества улично-дорожных сетей, появляются сложные развязки, увеличивается их пропускная способность.

Для принятия решения о построении улично-дорожных сетей и их характеристиках (пропускной способности, протяженности и т.п.) используются различные подходы к моделированию транспортных потоков.



**Рис. 2.** Количество транспортных средств

Моделирование транспортных потоков позволяет определить «узкие места» существующей улично-дорожной сети. В большинстве ситуаций наилучшим решением вышеуказанных проблем является совершенствование существующей

транспортной системы. Данный подход является достаточно дорогостоящим. В связи с этим, исследования, связанные с разработкой и применением современных и перспективных технологий при создании интеллектуальных транспортных систем различного уровня и назначения, являются актуальными как на сегодняшний день, так и на обозримую перспективу.

**Сбор данных для моделирования транспортных потоков**

Система мониторинга транспортных потоков является неотъемлемым компонентом интеллектуальных транспортных систем, который используется для сбора данных о дорожном движении, таких как количество транспортных средств, типы транспортных средств и скорость транспортных средств. Согласно ГОСТ Р 56829-2015 [3] интеллектуальная транспортная система (ИТС) – система управления, интегрирующая современные информационные и телематические технологии и предназначенная для автоматизированного поиска и принятия к реализации максимально эффективных сценариев управления транспортно-дорожным комплексом региона, конкретным транспортным средством или группой транспортных средств с целью обеспечения заданной мобильности населения, максимизации показателей использования дорожной сети, повышения безопасности и эффективности транспортного процесса, комфортности для водителей и пользователей транспорта.

На базе собранных данных подобные системы изучают трафик, чтобы отлично применять дорожные системы, предсказывать состояние потоков автомобильного транспорта и увеличивать безопасность. Транспортные компании выделяют большие средства на разработку, размещение и сервис систем наблюдения за дорожным движением.

Говоря о способах и типах данных, которые могут быть получены о транспортных потоках, можно выделить два подхода: активный и пассивный мониторинг транспортных потоков [4]. Пассивный мониторинг подразумевает, что устройство для сбора и анализа данных о транспортном потоке расположено на проезжей части. Активный мониторинг подразумевает сбор данных с борта участника дорожного движения посредством различных датчиков.

При анализе транспортных потоков нельзя обойтись без моделирования, которое позволяет проанализировать текущее состояние транспортной системы без затрат большого количества ресурсов. Транспортное моделирование позволяет решить проблемы связанные с непредсказуемостью движения каждого участника дорожного движения, большого количества случайных факторов, влияющих на транспортную ситуацию (погодные условия, ДТП и т.д.).

В моделировании транспортных потоков существует два подхода – детерминистический и вероятностный (стохастический). Детерминистические модели подразумевают функциональную зависимость между отдельно взятыми характеристиками транспортного потока. В стохастических моделях транспортный поток представляется в виде вероятностного процесса.

Все модели транспортных потоков можно разбить на три класса [6]: модели-аналоги, модели следования за лидером и вероятностные модели.

В моделях-аналогах транспортный поток рассматривается как какой-либо физический поток (гидро и газодинамические модели). Этот класс моделей принято называть макроэкономическими.

Современные представления, лежащие в основе макроэкономических моделей транспортного потока, начали формироваться с 1980 годов. Первоначально считалось, что поток автомобилей на улично-дорожной сети проявляет воспроизводимые свойства, зависящие не от манеры управления транспортным средством отдельными водителями, а только от технических характеристик автомобилей, расстояния между ними и реакции водителя. Когда дистанция между водителями становится ниже критического значения, задержка реакции водителя приводит к неустойчивости движения – «старт-стоп волнам».

В моделях следования за лидером существенно предположение о наличии связи между перемещением ведомого автомобиля и лидера. По мере развития теории в моделях этой группы учитывалось время реакции водителей, исследовалось движение на многополосных дорогах, изучалась устойчивость движения. Этот класс моделей называют микроскопическими.

В вероятностных моделях транспортный поток рассматривается как результат взаимодействия транспортных средств на элементах транспортной сети. В связи с жестким характером ограничений сети и массовым характером движения в транспортном потоке складываются отчетливые закономерности формирования очередей, интервалов, загрузок по полосам дороги и т. п. Эти закономерности носят существенно стохастический характер.

Сбор и анализ данных о транспортных потоках позволяют верифицировать модели, а также принимать решения о дальнейшем управлении движением транспортных средств. С развитием вычислительной техники и информационных технологий совершенствовались способы накопления и обработки информации о транспортных потоках. На сегодняшний день становится возможным получать, обрабатывать данные и принимать решения в режиме реального времени.

### **Методы и средства пассивного мониторинга транспортных потоков**

Системы пассивного мониторинга можно разделить на три класса в зависимости от того, где система развернута: системы, расположенные на проезжей части, над проезжей частью и сбоку от проезжей части. В каждой из этих систем могут использоваться разные типы датчиков и по-разному анализироваться данные с этих датчиков для дальнейшей классификации транспортных средств.

Системы классификации транспортных средств, развернутые на проезжей части устанавливают датчики на проезжей части или под ней. Для таких систем классификации транспортных средств, используются различные сенсоры, такие как пьезоэлектрические датчики [6], магнитометры [7], датчики вибрации [8], петлевые детекторы [9]. Из данных сенсора может быть получена различная информация, включая длину транспортного средства, количество осей и другие характеристики. Такие системы отличаются высокой точностью классификации транспортных средств, поскольку

находятся близко с проезжающими автомобилями, эффективно определяя характеристики транспортного средства и его движения. Однако серьезным недостатком является высокая стоимость установки и обслуживания таких систем, поскольку для установки датчиков под проезжей частью необходимо взаимодействовать с дорожным покрытием. Также это приводит к увеличению заторов на дорогах и увеличению стоимости работ из-за необходимости обеспечить безопасность для сотрудников дорожных служб.

Системы, расположенные сбоку от проезжей части решают проблему стоимости систем классификации транспортных средств, расположенных на проезжей части, поскольку датчики устанавливаются на обочине дороги, что устраняет необходимость в закрытии полосы движения и строительстве. Подобно системам, устанавливаемым на проезжей части, для классификации транспортных средств используются различные типы сенсоров. Некоторые из наиболее широко используемых датчиков включают магнитометры, акселерометры [10] и акустические датчики [11]. В последнее время используются передовые датчики, такие как лазерное инфракрасное обнаружение и дальность (LIDAR) [12], инфракрасные датчики [13] и трансиверы Wi-Fi [14]. Несмотря на то, что такие сенсоры требуют меньше затрат на установку и снижают стоимости, системы для проезжей части дороги требуют дополнительных усилий для точной настройки и размещения датчиков. Более серьезная проблема заключается в том, что большинство систем не могут точно классифицировать перекрывающиеся транспортные средства. Кроме того, необходима предварительная калибровка алгоритма и сенсоров для уменьшения количества шумных и сбора более точных данных.

Системы, расположенные над проезжей частью позволяют одновременно покрывать несколько полос движения. Например, в этих системах используются беспилотные летательные аппараты (БПЛА) и спутники [15]. Наиболее распространенным способом сбора данных в этом случае являются системы на основе камер [16-17]. Хотя системы на основе камер имеют высокую точность классификации, на точность детектирования и классификации влияют погодные условия и условия освещения. Еще одна важная проблема – это проблема конфиденциальности водителя. Некоторые наземные системы решают проблемы конфиденциальности, используя различные типы датчиков, такие как инфракрасные датчики и лазерный сканер [18].

Поскольку камеры являются наиболее широко используемыми датчиками для этих систем классификации транспортных средств, рассмотрим системы классификации транспортных средств на основе камер. Камера предоставляет обширную информацию для классификации транспортных средств, такую как визуальные характеристики и геометрия проезжающих транспортных средств [19]. По сравнению с системами классификации транспортных средств для движения по дорогам, где требуется несколько датчиков для покрытия нескольких полос движения (т.е., по крайней мере, один датчик для каждой полосы движения), одной камерой достаточно для классификации транспортных средств по нескольким полосам движения. Передовые технологии обработки изображений, поддерживаемые достаточной вычислительной мощностью, позволяют очень быстро и точно классифицировать несколько транспортных средств.

Общая работа системы классификации транспортных средств на основе камеры состоит в том, чтобы захватить изображение проезжающего автомобиля, выделить особенности изображения и запустить алгоритм для выполнения классификации транспортных средств. Таким образом, системы на основе камеры могут быть разделены на категории в зависимости от того, как захватывается изображение транспортного средства (например, методы уменьшения воздействия фонового изображения), типов функций, извлеченных из изображения транспортного средства, и механизмов для выполнения классификации на основе извлеченных признаков. Современная тенденция заключается в том, что все больше и больше методов машинного обучения применяются для автоматического и эффективного извлечения функций и обработки функций для построения моделей классификации. В то время как более ранние системы использовали простые модели классификации, основанные на SVM, kNN и дереве решений, сейчас используются более продвинутые алгоритмы машинного обучения.

### Описание исходного набора данных

Для обучения нейронной сети распознавать объекты нужен набор данных (датасет). Чем больше данных для обучения, тем выше точность распознавания объектов.

Датасет представляет из себя набор обработанных и структурированных данных. Посредством выборки будет осуществляться обучение модели машинного обучения. После обучения можно будет использовать модель для решения реальных практических задач. Для того, чтобы оценить качество модели нужны несколько видов выборки.

Выборка делится на обучающую, валидационную и тестовую. Для каждого типа выборки необходим свой набор данных:

- Обучающая выборка: фактический набор данных, на которых происходит обучение модели.
- Валидационная выборка: набор данных, на которых происходит оценка модели во время обучения. Эти данные применяются для улучшения гиперпараметров модели. Таким образом, эти данные применяются не для обучения модели, а для показания точности модели. То есть, набор косвенно влияет на модель.
- Тестовая выборка: Набор данных, который используется после обучения модели для оценки работы нейронной сети. Тестовый набор в основном используют для определения лучшей модели из всех обученных моделей на каждой эпохе. Иногда валидационную выборку используют для оценки качества модели, но это является плохой практикой, так как во время обучения оценка над валидационной выборкой уже проводилась. Набор тестовой выборки не должен включать в себя данные, содержащиеся в тестовой и валидационной выборке. Обычно тестовая выборка охватывает данные, с которыми модель будет сталкиваться при использовании на реальных задачах.

Для обучения нейронной сети распознавать машины и классифицировать эти машины было собрано чуть больше 16 тысяч изображений. Набор изображений состоит из следующих марок: Audi, Bmw, Chevrolet, Citroen, Daewoo, Ford, Hyundai, Jeep, Kia, Lada, Lexus, Mitsubishi, Nissan, Opel,

Peugeot, Renault, Skoda, Toyota, Volkswagen, Газ, Mercedes-Benz.

Для распознавания каждой модели было собрано по 100 экземпляров каждой модели соответствующей марки. Для автоматизации процесса сбора датасета был разработан парсер фотографий с сайта auto.ru, позволивший автоматизировать процесс сбора изображений. Пример фото, содержащихся в датасете, представлен на рисунке 3.

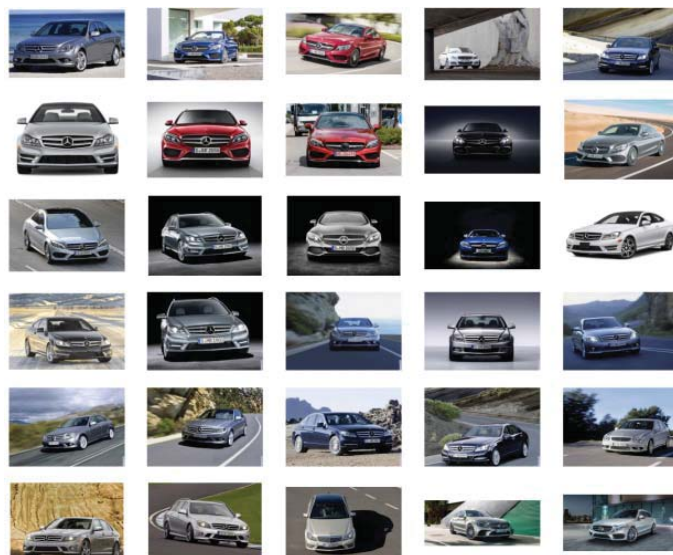


Рис. 3. Пример данных, содержащихся в датасете

Для того чтобы увеличить количество данных для обучения к исходным изображениям была применена аугментация. Аугментация позволяет из исходного набора данных извлечь больше информации посредством дополнений. Эти дополнения искусственно завышают размер обучающего набора данных либо путем искажения данных, либо передискретизации. Аугментации искажения данных преобразуют существующие изображения таким образом, чтобы их метка сохранялась. Существуют различные типы такой аугментации: геометрические и цветовые преобразования, случайное стирание, состязательное обучение и перенос стиля. Аугментации передискретизации создают синтетические экземпляры и добавляют их в обучающий набор. Способы такой аугментации включают в себя: смешивание изображений, увеличение пространства функций и генеративно-состязательные сети (GAN).

Эффективность аугментации данных была показана на основе простых преобразований, таких как горизонтальное отражение, увеличение цветового пространства и случайное кадрирование. Для исходного датасета были применены следующие технологии аугментации данных:

– *Поворот*. Поворот по горизонтальной оси встречается гораздо чаще, чем поворот по вертикальной оси. Такой тип аугментации является одним из самых простых в реализации и доказал свою полезность в таких наборах данных, как CIFAR-10 и ImageNet. Для наборов данных, включающих распознавание текста, таких как MNIST или SVHN, это преобразование не сохраняет метки.

– *Цветовое пространство*. Данные цифрового изображения обычно кодируются как тензор размерности (высота × ширина × цветовые каналы). Наиболее простые цветовые

дополнения включают выделение одного цветового канала, такого как R, G или B. Изображение можно быстро преобразовать в его представление в одном цветовом канале, изолировав эту матрицу и добавив 2 нулевые матрицы из других цветовых каналов. Кроме того, значениями RGB можно легко управлять с помощью простых матричных операций для увеличения или уменьшения яркости изображения. Более продвинутые цветовые дополнения получаются путем получения цветовой гистограммы, описывающей изображение. Изменение значений интенсивности в этих гистограммах приводит к изменению освещения, например, это используется в приложениях для редактирования фотографий.

– *Обрезка.* Обрезку изображений можно использовать в качестве практического шага обработки данных изображений со смешанными размерами высоты и ширины путем обрезки центральной части каждого изображения. Кроме того, можно использовать случайную обрезку для создания эффекта, очень похожего на поворот. Разница между случайным кадрированием и поворотом заключается в том, что кадрирование уменьшает размер входных данных, таких как (256,256)→(224, 224), тогда как повороты сохраняют пространственные размеры изображения. В зависимости от порога уменьшения, выбранного для обрезки, это может не быть преобразованием с сохранением метки.

– *Вращение.* Аугментация при помощи вращения выполняется путем поворота изображения вправо или влево по оси от 1° до 359°. Безопасность аугментаций вращения во многом определяется параметром степени вращения. Небольшие повороты, такие как от 1 до 20 или от -1 до -20, могут быть полезны в задачах распознавания цифр, таких как MNIST, но по мере увеличения степени вращения метка данных больше не сохраняется после преобразования.

– *Фильтры.* Фильтры – очень популярный метод обработки изображений для повышения резкости и размытия изображений. Фильтры работают путем скольжения матрицы  $n \times n$  по изображению либо с фильтром размытия по Гауссу, что приводит к более размытому изображению, либо с высококонтрастным вертикальным или горизонтальным краевым фильтром, который приводит к более четкому изображению по краям.

Интуитивно понятно, что размытие изображений для увеличения данных может привести к более высокой устойчивости к размытию движения во время тестирования. Кроме того, повышение резкости изображений для увеличения данных может привести к инкапсуляции более подробной информации об интересующих объектах.

Разработка алгоритма классификации участников дорожного движения

Mask R-CNN [20] была разработана командой Facebook Research в 2018 году. Данная архитектура в своей основе использует наработки предшествовавших ей архитектур R-CNN, Fast R-CNN и Faster R-CNN и является очередным эволюционным этапом в этой серии. Задача, которую решает Mask R-CNN – сегментация экземпляров, в рамках которой система должна обнаружить экземпляр искомого объекта, определить его границы на изображении и классифицировать его.

Работа Mask R-CNN осуществляется следующим образом: сначала она генерирует предположения насчет участков изображения, где может находиться экземпляр объекта –

выделение так называемых «областей интереса» (с англ. Region of Interest – RoI), после чего прогнозирует класс, к которому может принадлежать находящийся в области интереса объект. На изображении при этом отображается ограничительная рамка, окружающая экземпляр объекта, и маска, которая накрывает все пиксели изображения, которые, по мнению нейронной сети, принадлежат к данному экземпляру. Реализуемая архитектура нейронной сети будет состоять из двух частей. Первая часть необходима для извлечения признаков из изображения. Результатом работы являются регионы изображения, которые с большей вероятностью содержат объекты.

Далее, эти регионы по отдельности параллельно подаются в следующую часть сети. В данной работе применяется архитектура VGG16. Вторая часть необходима для классификации объекта в регионе, коррекции охватывающей рамки, сегментации объектов в регионе. Причем, сегментация производится сразу для всех возможных классов параллельно, и затем просто выбирается маска, соответствующая классу. Функция потерь нейросети строится следующим образом:

$$L = L_{cls} + L_{box} + L_{mask},$$

где  $L_{cls}$  – функция потерь определения класса объекта (кросс-энтропия);  $L_{box}$  – функция потерь определения охватывающей рамки;  $L_{mask}$  – функция потерь определения маски, которая вычисляется как бинарная кросс-энтропия.

Фактически, задачей нейронной сети является классификация каждого пикселя в изображении, отнесение его к некоторому объекту, либо к фону. Для сегментации используется архитектура Fully Convolutional Network (FCN).

Для обучения нейронной сети применяется трансферное обучение, используя веса предварительно обученной модели обнаружения объекта на наборе данных MS COCO.

Трансферное обучение – это повторное использование предварительно обученной модели для решения новой проблемы. В настоящее время оно очень популярно в глубоком обучении, поскольку может обучать глубокие нейронные сети со сравнительно небольшим объемом данных. Это очень полезно в области науки о данных, поскольку большинство реальных проблем обычно не имеют миллионов размеченных точек данных для обучения таких сложных моделей.

Трансферное обучение предполагает, что модель, обученная на большом объеме данных, обучается на целевом наборе данных. Примерная иллюстрация трансферного обучения приведена на рисунке 4.




Рис. 4. Визуализация трансферного обучения

Перед обучением нейронной сети необходимо выбрать количество эпох и шагов в одной эпохе. Для обучения 166 моделей было выбрано 300 эпох и шаг 100. Обучение длилось пять часов и показало плохой результат. Ошибка дошла до разметки 30%, и это является плохим результатом.

График обучения (уменьшения ошибок) отображен на рисунке 5.




Рис. 5. График ошибок для 166 моделей

Для увеличения точности было проведено повторное трансферное обучение с использованием предыдущей модели, увеличив количество шагов в эпохе до 200. График обучения (уменьшения ошибок) отображен на рисунке 6.




Рис. 6. График ошибок с использованием предыдущей обученной модели

Это обучение тоже не показало хороших результатов, как видно на рисунке, ошибка лишь снизилась до 26%.

После исследований был сделан вывод, что 100 изображений каждой модели оказалось недостаточным для обучения 166 моделей. Было решено объединить все изображения моделей по маркам, то есть обучить нейронную сеть распознавать только марку и тип. Таким образом, количество изображений на каждый подкласс увеличилось в несколько раз. Количество подклассов сократилось до 24, а количество изображений в подклассе равнялось примерно 700-1300 вместо 100.

Для очередного трансферного обучения используется натренированная модель СОСО. Количество шагов в каждой эпохе выбирается 1000, а количество эпох 30. Ошибка снизилась до 15%. График отображения ошибок на каждой стадии эпохи показан на рисунке 7.




Рис. 7. График ошибок для 24 марок

После обучения код сохраняет обученную модель с форматом h5. Далее можно использовать эту обученную модель в любой программе.

После обучения нейронной сети готовую модель можно применить на практике. Для использования модели может использоваться видео в формате mp4 или видеопоток с камеры видеонаблюдения. Модель будет производить детектирование в каждом кадре видео и сегментировать, и указывать к какому подклассу относится распознанный объект.

Так как модель обучена на наборе данных состоящим из фотографий автомобилей, которые близко расположены к камере, то обученная нейронная сеть будет распознавать машины лучше, когда видекамера расположено ближе к автомобилю.

Для более точной проверки было подано на вход нейронной сети видео, в котором расстояние от транспортного средства до видекамеры примерно было равно расстоянию от автомобиля до камеры из набора выборки.

### Модель трекинга движущихся объектов

Фильтр Калмана [21] используется в широком диапазоне технологических процессов. В процессе отслеживания и обнаружения этот фильтр смотрит на объект по мере его движения, то есть берет информацию о состоянии объекта в конкретный момент. Затем он использует эту информацию, чтобы предсказать, где находится объект в следующем кадре. Для этого он принимает на вход вектор измерений (положение по x, по y, ширину и высоту объекта). Затем он воздействует на так называемые внутренние параметры (положение, скорость и ускорение по x и y, а также высоту и ширину), чтобы сделать прогноз, а затем оценить их.

Результатом является оценка следующего измерения. В случае слежения за объектом в движении фильтр Калмана позволяет оценить состояния движения объекта. Многие авторы изучали фильтр Калмана в слежении за объектами [22-23]. Реализация фильтра при слежении за движущейся целью выглядит следующим образом.

Сначала инициализируется фильтр Калмана, фиксируется начальное положение движущейся цели, матрица измерений, ковариация ошибок, матрица перехода состояний и ковариация шума, далее прогнозируются переменные состояния движущегося объекта. Переменные состояния и переменные наблюдения на движущейся цели используются в наборе уравнений фильтра Калмана для обновления ковариации ошибок, усиления и прогнозирования положения

текущей цели, а также обновления и повторения состояния фильтра Калмана.

В процессе отслеживания движущейся цели посредством данных с видеокamеры движение цели за единицу времени можно рассматривать как равномерное движение, так что положение и скорость цели в данный момент времени могут использоваться для описания состояния движения объекта. Чтобы упростить вычислительную сложность алгоритма, могут быть разработаны два фильтра Калмана для описания изменений положения объекта и скорости в направлениях оси X и оси Y соответственно. Далее обсуждается применение фильтра Калмана в направлении оси X, и то же самое относится к направлению оси Y.

Перемещение объекта можно описать при помощи следующей системы уравнений:

$$\begin{cases} x_{k+1} = x_k + v_k T \\ v_{k+1} = v_k + a_k T \end{cases} \quad (1)$$

Переменные в системе выше представляют из себя информацию о местоположении, скорости и ускорении объекта в направлении оси X при  $t = k$ .  $x_k$  указывает пройденное расстояние транспортного средства,  $v_k$  представляет мгновенную скорость транспортного средства и  $a_k$  является ускорением.  $T$  как интервал времени между изображением  $k$  кадра и изображением  $k + 1$  кадра может рассматриваться как изменяемое значение. Уравнение можно описать с помощью следующей матрицы:

$$x_k = x_k + (v_{k-1} + a_{k-1}T)T \quad (2)$$

Уравнение состояния системы выглядит следующим образом:

$$X_{k+1} = H(k)X_k + W_k \quad (3)$$

где  $X_k = [x_k + v_k]^T$ , векторы состояния системы фильтров Калмана выглядят следующим образом:

$$H(k) = \begin{pmatrix} 1 & T \\ 0 & 1 \end{pmatrix}, W_k = \begin{pmatrix} 0 \\ a_k T \end{pmatrix} \quad (4)$$

которые являются вектором динамического шума системы. После установления уравнения состояния и уравнения наблюдения вышеупомянутой системы мы можем использовать уравнение фильтрации Калмана для прогнозирования положения цели в следующем кадре методом рекурсии. В момент времени  $t = k$  записывается целевая позиция, идентифицированная алгоритмом распознавания цели на изображении  $k$ -того кадра. Когда объект появляется впервые, она инициализирует фильтр  $= [0]$  в соответствии с наблюдаемым положением цели.

Ковариационная матрица вектора начального состояния системы может иметь большее значение на диагональной линии, и это значение получается в соответствии с реальными измерениями.

Далее вычисляется прогнозируемое положение цели в следующем кадре. Вблизи местоположения ищется локальное изображение следующего кадра и определяется положение

центроида. Далее происходит обновление ковариационной матрицы вектора состояния и вектора состояния, подготовка к предсказанию следующего местоположения и получение нового предсказанного местоположения. Локальный поиск выполняется для получения новой позиции центроида объекта, которая вычисляется итеративно для обеспечения отслеживания объекта.

### Метод расчета основных характеристик транспортного потока

Основными характеристиками транспортного потока, представляющими интерес, являются:

1) интенсивность (количество транспортных средств в единицу времени (секунды, часы, сутки))

$$N = \frac{n_t}{T} \quad (5)$$

где  $n_t$  – число автомобилей, прошедших сечение дороги;  $T$  – время наблюдения.

2) мгновенная скорость (пройденное расстояние в единицу времени)

$$V_t = \frac{\sum v_i}{n} \quad (6)$$

пространственная скорость (м/с, км/ч)

$$V_s = \frac{S}{t} \quad (7)$$

3) занятость (процент времени, в течение которого детектор на дороге занят транспортными средствами)

$$R = \frac{\sum t_0}{T} \quad (8)$$

где  $t_0$  – время занятости детектора;  $T$  – время наблюдения.

4) плотность (количество транспортных средств на единицу расстояния)

$$q = \frac{n_s}{S} \quad (9)$$

где  $n_s$  – число автомобилей на участке дороги,  $S$  – длина участка дороги.

Под интенсивностью транспортного потока понимают число транспортных средств, проезжающих определенную линию дороги за единицу времени. Для расчета интенсивности в качестве единицы измерения выбирают секунды, минуты, часы и так далее. Интенсивность транспортного потока является одним из основных показателей при определении уровня загруженности дорог.

Плотность транспортного потока является пространственной характеристикой, которая измеряется количеством автомобилей, находящихся на протяженности дороги 1 км. Максимальное значение плотности транспортного потока достигается при застывшем состоянии автомобилей, которые расположены близко друг к другу, и составляет пример-

но 170-200 авт./км в зависимости от типов транспортных средств.

Скорость транспортного средства вычисляется отношением пройденного расстояния к времени. Во многих странах, в том числе и в России, скорость измеряется в километрах в час, в некоторых странах, например в США, в качестве единицы измерения используют мили в час.

Интенсивность транспортного потока рассчитывается следующим образом:

- 1) отсчитывается время от запуска программы,
- 2) вычисляется количество всех возникших машин в каждом кадре,
- 3) начиная со второго кадра вычисляется значение интенсивности путем деления количество всех возникших машин на горизонте на пройденное время в текущем кадре.

Таким образом подсчет числа транспортных средств начинается с того места дороги, где камера начинает видеть машины. Вторым реализованным методом подсчета количество транспортных средств является использование виртуальных детекторов.

Плотность транспортного потока рассчитывается следующим образом:

- отсчитывается время от запуска программы,
- вычисляется количество всех распознанных машин на каждом кадре,
- вычисляется длина дороги в метрах,
- вычисляется плотность путем деления количество распознанных машин на текущем кадре на длину дороги.

Расчет скорости движения объекта происходит с использованием виртуальных детекторов. Первоначальным этапом является определение центра тяжести движущегося объекта, после чего происходит фиксация пересечения движущегося объекта черты виртуального детектора.

Расчет характеристик транспортного потока проводится раз в несколько секунд на основе записанных в файле скоростей, скорости записываются, как только они будут зафиксированы.

Логируются все происходящих в системе событий происходит в текстовый файл. Исходя из данных этого файла возможно провести все необходимые расчеты основных характеристик транспортного потока. Погрешность рассчитанной таким образом скорости составляет около 1 км/ч, что допустимо для такой системы.

### Заключение

В работе были рассмотрены основные способы пассивного сбора и обработки данных о транспортных потоках. Были рассмотрены системы, расположенные сбоку, под и над проезжей частью. Наиболее просто реализуемыми являются системы, состоящие из видеокамер и центрального обрабатывающего сервера.

Так же были рассмотрены основные методы анализа данных о транспортных потоках посредством видеокамер. Как видно из обзора исследований по данной тематике, все разработанные системы классифицируют транспортные средства на некоторое небольшое количество классов (максимальное количество – 11).

Описана реализация нейросетевого классификатора, на основе архитектуры Mask R-CNN. За основной компонент,

ответчающий за выделение признаков из кадров видеопотока, в отличие от проанализированных исследований, взята VGG-16. Для обучения классификатора был разработан специализированный парсер фотографий из сети интернет, проведена разметка данных, количество изображений в датасете превышает 16 000 изображений. Стоит отметить, что подобного датасета наиболее часто встречаемых автомобилей в РФ в открытом доступе не существует. Разработанный классификатор позволяет распознавать 166 классов.

Реализована методика определения основных характеристик транспортных потоков на основе видеоизображений. Данные, которые можно извлечь и проанализировать представляют из себя: скорость, плотность, интенсивность, качественный состав транспортного потока за указанный промежуток времени.

На основе разработанного программного обеспечения проводится верификация существующих макроскопических моделей транспортных потоков.

### Литература

1. Число собственных легковых автомобилей на 1000 человек населения по субъектам Российской Федерации. [Электронный ресурс]: Федеральная служба государственной статистики. 2021. URL: <https://rosstat.gov.ru/folder/23455> (дата обращения: 03.09.2021).
2. Наличие транспортных средств по Российской Федерации. [Электронный ресурс]: Федеральная служба государственной статистики. 2021. URL: <https://rosstat.gov.ru/folder/23455> (дата обращения: 03.09.2021).
3. ГОСТ Р 56829-2015 Интеллектуальные транспортные системы. Термины и определения. М.: Стандартинформ, 2018. 10 с.
4. *Городничев М.Г.* Информационные и математические аспекты модели следования за лидером : дис. ... канд. техн. наук : 05.13.17 / Городничев Михаил Геннадьевич. М., 2015. 120 с.
5. *Брайловский Н.О., Грановский Б.И.* Моделирование транспортных систем. М.: Транспорт, 1978. 125 с.
6. *Rajab S.A., Mayeli A., Refai H.H.* Vehicle classification and accurate speed calculation using multi-element piezoelectric sensor // 2014 IEEE Intelligent Vehicles Symposium Proceedings. IEEE, 2014, pp. 894-899.
7. *Xu C., Wang Y., Bao X., Li F.* Vehicle classification using an imbalanced dataset based on a single magnetic sensor // Sensors, vol. 18, no. 6, p. 1690, 2018.
8. *Stocker M., Rönkkö M., Kolehmainen M.* Situational knowledge representation for traffic observed by a pavement vibration sensor network // IEEE Transactions on Intelligent Transportation Systems, vol. 15, no. 4, pp. 1441-1450, 2014.
9. *Meta S., Cinsdikici M.G.* Vehicle-classification algorithm based on component analysis for single-loop inductive detector // IEEE Transactions on Vehicular Technology, vol. 59, no. 6, pp. 2795-2805, 2010.
10. *Yang B., Lei Y.* Vehicle detection and classification for low-speed congested traffic with anisotropic magnetoresistive sensor // IEEE Sensors Journal, vol. 15, no. 2, pp. 1132-1138, 2015.
11. *Ma W., Xing D., McKee A., Bajwa R., Flores C., Fuller B., Varaiya P.* A wireless accelerometer-based automatic vehicle classification prototype system // IEEE Transactions on Intelligent Transportation Systems, vol. 15, no. 1, pp. 104-111, 2014.
12. *George J., Mary L., Riyas K.* Vehicle detection and classification from acoustic signal using ANN and KNN // Control Communication and Computing (ICCC), 2013 International Conference on. IEEE, 2013, pp. 436-439.
13. *Lee H., Coifman B.* Using LIDAR to validate the performance of vehicle classification stations // Journal of Intelligent Transportation Systems, vol. 19, no. 4, pp. 355-369, 2015.



14. Odat E., Shamma J. S., Claudel C. Vehicle classification and speed estimation using combined passive infrared/ultrasonic sensors // IEEE Transactions on Intelligent Transportation Systems, 2017.
15. Won M., Zhang S., Son S.H. WiTraffic: Low-cost and non-intrusive traffic monitoring system using WiFi // 2017 26th International Conference on Computer Communication and Networks (ICCCN). IEEE, 2017, pp. 1-9.
16. Tang T., Zhou S., Deng Z., Lei L., Zou H. Arbitrary-oriented vehicle detection in aerial imagery with single convolutional neural networks // Remote Sensing, vol. 9, no. 11, p. 1170, 2017.
17. Chen Z., Ellis T., Velastin S.A. Vehicle detection, tracking and classification in urban traffic // 2012 15th International IEEE Conference on Intelligent Transportation Systems. IEEE, 2012, pp. 951-956.
18. Bautista C.M., Dy C.A., Mañalac M.L., Orbe R.A., Cordel M. Convolutional neural network for vehicle detection in low resolution traffic videos // Region 10 Symposium (TENSymp), IEEE, 2016, pp. 277-281.
19. Chidlovskii B., Csurka G., Rodriguez-Serrano J. Vehicle type classification from laser scans with global alignment kernels // 17th International IEEE Conference on Intelligent Transportation Systems (ITSC). IEEE, 2014, pp. 2840-2845.
20. He K., Gkioxari G., Dollár P., Girshick R. Mask R-CNN // 2017 IEEE International Conference on Computer Vision (ICCV), 2017, pp. 2980-2988, doi: 10.1109/ICCV.2017.322
21. Lin J., Qi W.D., Liu P. Bias-compensation Kalman filter algorithm for AoA-ToA target tracking // Information and Control, vol. 49, no. 6, pp. 657-666, 2020.
22. Liu D., Zhao Y.B., Yuan Z.Q. et al. Target tracking methods based on a signal-to-noise ratio model // Frontiers of Information Technology & Electronic Engineering, vol. 21, no. 12, pp. 1804-1814, 2020.
23. Chen F.L., Ding Q.H., Luo H.B. Anti-occlusion real time target tracking algorithm employing spatio-temporal context // Infrared and Laser Engineering, vol. 50, no. 1, Article ID 20200105, pp. 1-11, 2021.

## ABOUT METHODS FOR COLLECTING AND ANALYZING TRAFFIC FLOW CHARACTERISTICS

*Marina S. Moseva, Moscow Technical University of Communications and Informatics, Moscow, Russia, [m.s.moseva@mtuci.ru](mailto:m.s.moseva@mtuci.ru)*

### Abstract

The ever-increasing motorization leads to the need to solve problems related to the optimal movement of transport, ensuring its safety and improving the environmental situation. According to Rosstat statistics, the number of own cars in the constituent entities of the Russian Federation (per 1,000 people) is increasing every year. The issues of optimal control of the movement of vehicles remain topical. Modeling of traffic flows allows you to determine the "bottlenecks" of the existing road network. In most situations, the best solution to the above problems is to improve the existing transport system. This approach is quite expensive. In this regard, studies related to the development and application of modern and promising technologies in the creation of intelligent transport systems of various levels and purposes are relevant both today and in the future. The collection and analysis of data on traffic flows allows you to verify the models, as well as make decisions about the further management of the movement of vehicles. With the development of computer technology and information technology, methods for accumulating and processing information about traffic flows have been improved. Today it becomes possible to receive, process data and make decisions in real time. This study is devoted to an overview of existing methods for monitoring and collecting characteristics about the state of traffic flows. A review of modern technologies and sensors used to collect traffic information is made. The method for collecting data on road users is described. An algorithm for classifying vehicles depending on the brand of the vehicle has been developed. The description of the vehicle tracking algorithm is given. The method for calculating the main characteristics of the traffic flow (speed, density, intensity) based on data from the video sequence is described.

**Keywords:** traffic flow monitoring, vehicle classification, neural network algorithm, calculation of traffic flow characteristics.

## References

1. The number of own cars per 1000 people in the constituent entities of the Russian Federation. [Electronic resource]: Federal State Statistics Service. 2021. URL: <https://rosstat.gov.ru/folder/23455> (accessed 03.09.2021).
2. Availability of vehicles in the Russian Federation. [Electronic resource]: Federal State Statistics Service. 2021. URL: <https://rosstat.gov.ru/folder/23455> (accessed 03.09.2021).
3. GOST R 56829-2015 Intelligent transport systems. Terms and Definitions. Moscow: Standartinform, 2018. 10 p.
4. M.G. Gorodnichev (2015). Informational and Mathematical Aspects of the Leader-Following Model: Cand. ... cand. tech. Sciences: 05.13.17 / Gorodnichev Mikhail Gennadevich. Moscow. 120 p.
5. N.O. Brailovsky, B.I. Granovsky (1978). Modeling of transport systems. Moscow: Transport. 125 p.
6. S.A. Rajab, A. Mayeli, and H.H. Refai. (2014). Vehicle classification and accurate speed calculation using multi-element piezoelectric sensor," in 2014 IEEE Intelligent Vehicles Symposium Proceedings. IEEE, pp. 894-899.
7. C. Xu, Y. Wang, X. Bao, and F. Li (2018). Vehicle classification using an imbalanced dataset based on a single magnetic sensor. *Sensors*, vol. 18, no. 6, p. 1690.
8. M. Stocker, M. Ronkko, and M. Kolehmainen (2014). Situational knowledge representation for traffic observed by a pavement vibration sensor network. *IEEE Transactions on Intelligent Transportation Systems*, vol. 15, no. 4, pp. 1441-1450.
9. S. Meta and M. G. Cinsdikici (2010). Vehicle-classification algorithm based on component analysis for single-loop inductive detector. *IEEE Transactions on Vehicular Technology*, vol. 59, no. 6, pp. 2795-2805.
10. B. Yang and Y. Lei (2015). Vehicle detection and classification for low-speed congested traffic with anisotropic magneto-resistive sensor. *IEEE Sensors Journal*, vol. 15, no. 2, pp. 1132-1138.
11. W. Ma, D. Xing, A. McKee, R. Bajwa, C. Flores, B. Fuller, and P. Varaiya (2014). A wireless accelerometer-based automatic vehicle classification prototype system. *IEEE Transactions on Intelligent Transportation Systems*, vol. 15, no. 1, pp. 104-111.
12. J. George, L. Mary, and K. Riyas (2013). Vehicle detection and classification from acoustic signal using ANN and KNN. *Control Communication and Computing (ICCC), 2013 International Conference*. IEEE, pp. 436-439.
13. H. Lee and B. Coifman (2015). Using LIDAR to validate the performance of vehicle classification stations. *Journal of Intelligent Transportation Systems*, vol. 19, no. 4, pp. 355-369.
14. E. Odat, J. S. Shamma, and C. Claudel (2017). Vehicle classification and speed estimation using combined passive infrared/ultrasonic sensors. *IEEE Transactions on Intelligent Transportation Systems*.
15. M. Won, S. Zhang, and S. H. Son (2017). WiTraffic: Low-cost and non-intrusive traffic monitoring system using WiFi. *2017 26th International Conference on Computer Communication and Networks (ICCCN)*. IEEE, pp. 1-9.
16. T. Tang, S. Zhou, Z. Deng, L. Lei, and H. Zou (2017). Arbitrary-oriented vehicle detection in aerial imagery with single convolutional neural networks. *Remote Sensing*, vol. 9, no. 11, p. 1170.
17. Z. Chen, T. Ellis, and S. A. Velastin (2012). Vehicle detection, tracking and classification in urban traffic. *2012 15th International IEEE Conference on Intelligent Transportation Systems*. IEEE, pp. 951-956.
18. C.M. Bautista, C.A. Dy, M.I. Manalac, R. A. Orbe, and M. Cordel (2016). Convolutional neural network for vehicle detection in low resolution traffic videos. *Region 10 Symposium (TENSYP)*, IEEE, pp. 277-281.
19. B. Chidlovskii, G. Csurka, and J. Rodriguez-Serrano (2014). Vehicle type classification from laser scans with global alignment kernels. *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*. IEEE, pp. 2840-2845.
20. K. He, G. Gkioxari, P. Dollar and R. Girshick (2017). Mask R-CNN. *2017 IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 2980-2988. doi: 10.1109/ICCV.2017.322
21. J. Lin, W. D. Qi, and P. Liu (2020). Bias-compensation Kalman filter algorithm for AoA-ToA target tracking. *Information and Control*, vol. 49, no. 6, pp. 657-666.
22. D. Liu, Y. B. Zhao, Z. Q. Yuan et al. (2020). Target tracking methods based on a signal-to-noise ratio model. *Frontiers of Information Technology & Electronic Engineering*, vol. 21, no. 12, pp. 1804-1814.
23. F.L. Chen, Q.H. Ding, and H.B. Luo (2021). Anti-occlusion real time target tracking algorithm employing spatio-temporal context. *Infrared and Laser Engineering*, vol. 50, no. 1, Article ID 20200105, pp. 1-11.

## Information about author:

**Marina S. Moseva**, Department of Mathematical Cybernetics and Information Technologies, Moscow Technical University of Communications and Informatics, Moscow, Russia