

*И. Н. Пугачев, В. С. Тормозов*

## РАЗРАБОТКА И АНАЛИЗ СИСТЕМЫ МОНИТОРИНГА ДОРОЖНОГО ДВИЖЕНИЯ, ОСНОВАННОЙ НА ТЕХНОЛОГИЯХ МАШИННОГО ЗРЕНИЯ И МЕТОДАХ КЛАСТЕРНОГО АНАЛИЗА

**Аннотация.** В данной статье представлена система мониторинга дорожного движения, основанная на принципах машинного зрения. В основе системы лежат простые веб-камеры, установленные над дорожным полотном, которые фиксируют изображения транспортных средств. Далее, с применением алгоритмов обработки изображений и методов машинного обучения, система осуществляет определение количества и классификацию транспортных средств на дороге.

Система включает в себя несколько ключевых модулей: модуль вычитания фона, модуль сегментации переднего плана, модуль получения контуров, модуль обучения и классификации контуров, модуль выделения свойств и модуль кластеризации. Каждый из этих модулей выполняет специфические функции, направленные на обеспечение точного и надежного обнаружения транспортных средств. Система была протестирована на изображениях дорожного движения. Результаты тестирования подтверждают способность системы адаптироваться к различным условиям и сценариям, что является критически важным для систем видеонаблюдения и управления дорожным движением.

В статье также обсуждаются перспективы дальнейшего развития системы, включая возможность использования более сложных архитектур нейронных сетей и интеграции с другими системами.

**Ключевые слова:** мониторинг дорожного движения, машинное зрение, обработка изображений, машинное обучение, классификация транспортных средств.

**Для цитирования:** Пугачев, И. Н. Разработка и анализ системы мониторинга дорожного движения, основанной на технологиях машинного зрения и методах кластерного анализа / И. Н. Пугачев, В. С. Тормозов // Вестник Ростовского государственного университета путей сообщения. – 2024. – № 4. – С. 134–145. – DOI 10.46973/0201-727X\_2024\_4\_134.

### **Введение**

Мониторинг дорожного движения на густонаселенных городских улицах с помощью камер наблюдения – это сложная задача, требующая поиска эффективных и универсальных решений. Современные методы, такие как ручной подсчет транспортных средств и использование магнитных петель на дороге, хоть и являются дорогими, имеют ограничения в функциональности. Они позволяют лишь определить количество автомобилей на дороге, но не предоставляют информации о их классификации, скорости и размерах.

В этой работе предлагается более дешевая и универсальная система мониторинга дорожного движения, основанная на методах машинного зрения. В основе системы лежат простые веб-камеры, расположенные над дорожным полотном и обеспечивающие полный обзор. Большинство существующих исследований и приложений по мониторингу транспорта сосредоточены на наблюдении за автомобилями на шоссе, в то время как мониторинг движения в густонаселенных городских районах представляет собой гораздо более сложную задачу.

Цель данной работы – исследовать применимость и эффективность методов машинного зрения в разрабатываемой системе мониторинга транспорта. Эти методы включают в себя алгоритмы распознавания транспортных средств, анализа их скорости и классификации по различным параметрам. Внедрение таких технологий значительно улучшит качество и точность мониторинга дорожного движения, что, в свою очередь, повысит безопасность и эффективность транспортных потоков в городских условиях.

Разработка системы мониторинга дорожного движения с использованием методов машинного зрения требует решения ряда задач. Во-первых, необходимо обеспечить высокую точность распознава-

ния транспортных средств на изображениях, полученных с видеокамер. Для этого используются алгоритмы обработки изображений, которые позволяют выделить контуры автомобилей и определить их тип.

Во-вторых, важно разработать алгоритмы анализа скорости транспортных средств. Это включает в себя определение средней скорости движения по кадрам видео и выявление аномалий, таких как резкое ускорение или торможение.

В-третьих, необходимо классифицировать транспортные средства по различным параметрам, таким как тип автомобиля (легковой, грузовик, автобус и т.д.), размер и другие характеристики. Это позволит более точно анализировать транспортные потоки и принимать меры для их оптимизации.

Для решения этих задач применяются современные методы машинного обучения и обработки данных. Алгоритмы глубокого обучения обеспечивают высокую точность распознавания транспортных средств, а методы кластеризации и классификации помогают анализировать большие объемы информации и выявлять закономерности в поведении транспортных потоков.

Использование методов машинного зрения в системе мониторинга дорожного движения не только повышает точность и качество мониторинга, но и снижает затраты на его проведение. Веб-камеры, применяемые для наблюдения за дорожным движением, являются относительно недорогими устройствами, а алгоритмы машинного зрения позволяют автоматизировать процесс обработки данных и анализа транспортных потоков.

Таким образом, разработка системы мониторинга дорожного движения с использованием методов машинного зрения представляет собой перспективное направление, которое значительно улучшает качество транспортной инфраструктуры и повысит безопасность дорожного движения в городских условиях. Однако для успешного внедрения данной системы необходимо решить ряд технических и организационных задач, таких как обеспечение высокой точности распознавания транспортных средств, разработка алгоритмов анализа скорости и классификации, а также интеграция системы с существующими инфраструктурами и сервисами.

В заключение можно сказать, что разработка и внедрение системы мониторинга дорожного движения с использованием методов машинного зрения являются важным шагом на пути к созданию более эффективных и безопасных транспортных систем в городских условиях. Эта система позволит не только улучшить качество мониторинга и анализа транспортных потоков, но и снизить затраты на проведение этих работ. Важно отметить, что разработка и внедрение такой системы требует комплексного подхода, включающего в себя не только технические аспекты, но и организационные и правовые меры. Необходимо учитывать специфику городских условий, включая различные типы транспортных средств, интенсивность движения и особенности дорожной инфраструктуры.

Одним из ключевых аспектов успешной реализации проекта является обеспечение высокой точности и надежности системы мониторинга. Это требует использования современных технологий и методов обработки данных, а также проведения тщательного тестирования и верификации системы.

Кроме того, необходимо обеспечить интеграцию системы мониторинга с существующими инфраструктурами и сервисами, такими как системы управления дорожным движением и системы оповещения о чрезвычайных ситуациях. Это позволит создать единое информационное пространство, которое будет способствовать более эффективному управлению транспортными потоками и повышению безопасности дорожного движения.

В перспективе разработка системы мониторинга дорожного движения с использованием методов машинного зрения может стать основой для создания более интеллектуальных и адаптивных транспортных систем. Такие системы будут способны автоматически адаптироваться к изменениям в дорожной ситуации, прогнозировать возможные заторы и предлагать оптимальные маршруты движения. Это, в свою очередь, позволит значительно повысить эффективность использования транспортных ресурсов и снизить негативное воздействие транспорта на окружающую среду. Внедрение подобных технологий будет способствовать созданию более комфортных и безопасных условий для всех участников дорожного движения, включая пешеходов, велосипедистов и водителей транспортных средств.

### ***Обзор системы***

В современном мире, где эффективное управление дорожным движением является ключевым аспектом обеспечения безопасности и комфорта граждан, разработка инновационных технологий для подсчета транспортных средств приобретает особую значимость. Одной из таких технологий является система, предназначенная для точного и надежного подсчета количества транспортных средств определенной категории по снимку с камеры наблюдения, установленной над дорожным полотном.

Процесс разработки данной системы включает в себя использование передовых алгоритмов обработки изображений и современных технологий компьютерного зрения. Это позволяет достичь высокой точности и надежности подсчета, что является критически важным для эффективного управления дорожным движением. Особое внимание уделяется оптимизации системы для работы в режиме реального времени, что обеспечивает оперативное получение данных о количестве транспортных средств на дороге и их использование для различных аналитических целей.

Система поддерживает подсчет следующих категорий транспорта: автобус, грузовик, легковой автомобиль и мотоцикл. Это позволяет охватить широкий спектр транспортных средств и использовать полученные данные для разработки более эффективных стратегий управления дорожным движением.

Интеграция разрабатываемой системы с существующими системами управления дорожным движением и мониторинга транспортной инфраструктуры способствует созданию более эффективной и интегрированной системы управления. Результатом обработки снимка является таблица, содержащая распределение количества транспорта по вышеуказанным категориям. Это позволяет получить детальную информацию о транспортной нагрузке на различных участках дороги и использовать ее для принятия обоснованных решений.

Схема работы системы представлена на рис. 1. Она включает в себя несколько этапов: захват изображения камерой наблюдения, обработка изображения с использованием передовых алгоритмов, подсчет количества транспортных средств определенной категории и вывод результатов в удобной для анализа форме. Такая схема работы позволяет системе эффективно функционировать и обеспечивать высокую точность подсчета.



Рис. 1. Схема работы системы

**Вычитание фона** является важным этапом в процессе обнаружения автомобилей на изображении. Прежде чем приступить к непосредственному поиску транспортных средств, необходимо определить, какие объекты находятся на переднем плане, а какие – на заднем. Хотя теоретически систему можно было бы построить и без этой операции, вычитание фона значительно повышает надежность и эффективность поиска, ограничивая область, в которой нужно искать автомобили.

В разработанной системе вычитание фона реализовано с использованием модели гауссовых функций [1] и медианного фильтра. Эти алгоритмы позволяют выделить объекты на переднем плане, минимизируя влияние фона. Результаты их работы в виде масок переднего плана объединяются с помощью операции AND. Затем на полученной маске удаляются мелкие пятна, а сама маска подвергается дополнительной обработке с использованием последовательной дилатации и эрозии [2].

**Сегментация переднего плана** – это важный этап в обработке изображений, который позволяет выделить отдельные объекты на фоне и существенно улучшить качество картинки. В условиях, когда машины движутся близко друг к другу, они могут сливаться в одну область на маске переднего плана. Чтобы их разделить, необходимо провести сегментацию по цвету.

Сегментация – это не просто механическое разделение изображения на части. Это сложный процесс, требующий глубокого анализа и внимания к мельчайшим деталям. Каждый сегмент должен быть однородным по цвету и текстуре, что делает задачу сегментации весьма сложной. Существует

множество методов, используемых для сегментации изображений, таких как кластеризация, применение гистограммы и выделение краев.

Кластеризация – один из самых распространенных методов сегментации. Он основан на группировке пикселей в кластеры на основе их схожести. Гистограмма также широко применяется для сегментации, так как позволяет анализировать распределение цветов на изображении и выявлять закономерности. Выделение краев – это еще один важный метод, который помогает определить границы объектов на картинке и сделать их более четкими. Методами сегментации изображений являются: методы, основанные на кластеризации [3–7], методы с использованием гистограммы [8], методы выделения краев [9], и другие.

Таким образом, сегментация переднего плана представляет собой сложный и многогранный процесс, требующий использования различных методов и подходов. Несмотря на свою сложность, она является неотъемлемой частью обработки изображений и играет ключевую роль в повышении их качества.

### ***Получение контуров***

В результате сегментации переднего плана происходит значительное упрощение анализа изображения. Этот процесс заключается в разделении изображения на отдельные области, где цвет и текстура каждого сегмента имеют схожие характеристики. Для более точного определения границ между этими областями применяется метод разрезания графа, который позволяет учесть все нюансы и детали изображения.

После того как сегменты разделены на области, начинается процесс их объединения. Это делается для того, чтобы создать более крупные области, которые можно рассматривать как отдельные объекты. Для этого используется алгоритм, который анализирует цветовые характеристики каждого сегмента и объединяет их с другими сегментами, имеющими схожие параметры.

Затем для каждой объединенной области извлекается контур, который и будет являться ее границей. Этот процесс включает несколько этапов, начиная с сегментации и заканчивая извлечением контуров. Каждый этап важен для достижения точного результата и правильного определения границ объектов на изображении.

На первом этапе происходит предварительная обработка изображения, которая включает фильтрацию шума и улучшение контрастности. Затем происходит сегментация, где изображение делится на области с одинаковыми характеристиками. После этого применяется метод разрезания графа, который позволяет более точно определить границы между сегментами.

На следующем этапе происходит объединение сегментов в более крупные области, что позволяет создать более точные контуры объектов. Для этого используется алгоритм, который анализирует цветовые характеристики сегментов и объединяет их с другими сегментами, имеющими схожие параметры.

После этого извлекаются контуры для каждой объединенной области. Этот процесс включает использование различных методов, таких как анализ границ, выделение контуров и их аппроксимация. В результате получается набор контуров, которые представляют собой границы объектов на изображении [10–12].

Таким образом, процесс получения контуров объектов включает несколько этапов, каждый из которых важен для достижения точного и надежного результата. Сегментация переднего плана позволяет упростить анализ изображения, а метод разрезания графа и объединение сегментов позволяют более точно определить границы объектов. Извлечение контуров является заключительным этапом процесса и позволяет получить точные границы объектов, которые могут быть использованы для различных задач, таких как распознавание объектов, классификация изображений и другие [13].

Схема процесса получения контуров объектов представлена на рис. 2.

В рамках подсистемы осуществляется комплексный анализ и обработка контуров, полученных на предыдущем этапе. Этот процесс включает в себя детальное изучение ключевых характеристик и параметров каждого контура, что позволяет определить его принадлежность к определенной категории транспортных средств. Для достижения этой цели применяются различные методы и алгоритмы машинного обучения, которые обеспечивают эффективную классификацию контуров.

Подсистема также учитывает возможность того, что некоторые контуры могут быть нераспознаны или классифицированы неправильно. В таких случаях система выдает соответствующий результат, что позволяет оператору принять необходимые меры. Важно отметить, что процесс обучения и классификации контуров требует тщательной настройки параметров и алгоритмов для обеспечения высокой точности и надежности результатов. Это включает в себя сбор и анализ значительного объема данных, а также проведение множества экспериментов и тестирование различных подходов.



Рис. 2. Схема получения контуров объектов

### **Обучение и классификация контуров**

Для повышения точности и надежности результатов подсистема использует современные методы машинного обучения, такие как нейронные сети и алгоритмы глубокого обучения. Эти методы позволяют более точно распознавать и классифицировать контуры, что особенно важно в условиях высокой скорости и сложных погодных условий.

Кроме того, подсистема учитывает возможность появления новых категорий транспортных средств, что требует постоянного обновления и адаптации алгоритмов. Это позволяет системе оставаться актуальной и эффективной в условиях постоянно меняющейся дорожной обстановки. Таким образом, подсистема представляет собой сложный и многофункциональный инструмент, который обеспечивает высокую точность и надежность при анализе и обработке контуров транспортных средств. Ее использование позволяет значительно повысить безопасность и эффективность дорожного движения, а также оптимизировать работу служб безопасности и контроля.

Схема работы подсистемы представлена на рис. 3.

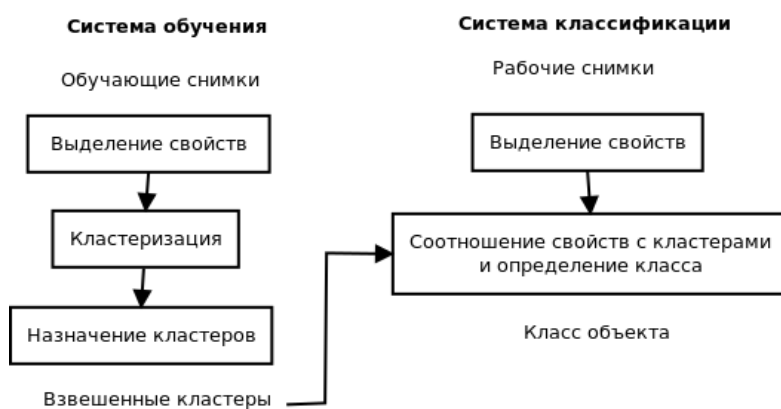


Рис. 3. Подсистема обучения и классификации

### **Выделение свойств**

В процессе выделения свойств важно отметить значимость характеристического вектора в определении формы контура. Этот вектор, разработанный в системе Sakbot [10], является фундаментальным элементом для анализа и обработки изображений. Его использование в системе Sakbot [10] обеспечивает высокую точность и надежность в распознавании контуров, что делает его незаменимым инструментом в области компьютерного зрения.

Кроме того, характеристический вектор обладает уникальными свойствами, позволяющими ему быть инвариантным к масштабированию и повороту объектов. Это позволяет эффективно применять алгоритм в различных условиях и с различными параметрами, что значительно расширяет его возможности и применимость.

Однако стоит отметить, что процесс получения характеристического вектора является сложным и требует тщательной настройки параметров. Несмотря на это, благодаря своей универсальности

и надежности, этот алгоритм стал неотъемлемой частью многих систем компьютерного зрения, значительно улучшая качество и точность анализа изображений.

### **Кластеризация**

В процессе кластеризации характеристических векторов контуров учебной выборки каждый контур приобретает специфические черты, характерные для его кластера. Это позволяет более детально исследовать структуру данных и выявлять скрытые закономерности, которые могут быть неочевидны при поверхностном анализе.

Алгоритм кластеризации K-means, выбранный в данном исследовании, является одним из наиболее распространенных и эффективных методов. Он позволяет разделить данные на заранее определенное количество кластеров, минимизируя внутрикластерные расстояния и максимизируя межкластерные расстояния. Это способствует достижению оптимальной группировки объектов, что, в свою очередь, способствует более глубокому пониманию данных.

В результате процедуры каждый кластер становится более однородным и четко выраженным, что упрощает интерпретацию результатов. Кластеризация также выявляет скрытые взаимосвязи и зависимости между объектами, которые могут быть неочевидны при простом анализе данных. Это открывает новые перспективы для дальнейших исследований и разработки инновационных подходов к решению задач. В данном исследовании используется формула для вычисления центроида кластера  $c_k$  в алгоритме K-means:

$$c_k = \frac{1}{|C_k|} \sum_{i \in C_k} x_i,$$

где  $C_k$  – множество точек, принадлежащих  $k$ -му кластеру,  $x_i$  –  $i$ -я точка данных, а  $|C_k|$  – количество точек в  $C_k$ .


Таким образом, объединение характеристических векторов контуров в кластеры с использованием алгоритма K-means способствует более глубокому и всестороннему анализу данных, что может привести к новым открытиям и инновациям в различных областях науки и техники.

### **Назначение кластеров классам транспорта**

В ходе выполнения процедуры кластеризации группы схожих контуров были успешно сформированы. Однако на текущем этапе не удалось однозначно определить, к какой категории транспорта относится каждая из этих групп. Для достижения этой цели необходимо провести назначение кластеров, чтобы идентифицировать наиболее вероятную категорию транспорта для каждого кластера. Схема данного процесса подробно представлена на рис. 4.

Для начала из обучающей выборки для каждого из классов были отобраны несколько примеров. Затем каждый из этих примеров был тщательно сравнен с каждым кластером. Каждому кластеру и каждой категории транспорта было присвоено значение  $W_{A,X} = \frac{m}{n}$ , которое отражает степень сходства контуров кластера  $X$  с примерами из выборки класса  $A$ . После этого для каждого кластера был определен класс, для которого значение  $W_{A,X}$  оказалось максимальным. Этот класс был признан наиболее схожим с контурами в кластере  $A$  и получил обозначение  $class_X$  [14].

Этот подход позволяет систематизировать и классифицировать группы контуров, что является важным шагом в процессе идентификации категорий транспорта.



**Рис. 4. Схема процесса назначения кластеров**

### **Соотношение свойств с кластерами и определение класса**

В рамках исследования данных, полученных из контура неопознанного объекта, необходимо

учитывать различные параметры и факторы, которые могут влиять на точность классификации. Одним из ключевых этапов данного процесса является сопоставление характеристического вектора с каждым кластером. Если вектор соответствует кластеру  $X$ , то это указывает на наиболее вероятный класс объекта –  $class_x$ . В случае, если вектор не принадлежит ни одному из кластеров, объект остается неопределенным. В таких ситуациях система должна применять дополнительные методы для определения наиболее вероятного класса [15].

При анализе данных, особенно когда объект относится к кластеру, включающему множество других классов, важно учитывать степень сходства с другими объектами в данном кластере. Это позволяет системе более точно определить наиболее вероятный класс. Однако следует учитывать, что классификация может быть подвержена ошибкам вследствие шума или недостатка данных. Для повышения надежности классификации рекомендуется применять дополнительные методы и алгоритмы.

Таким образом, тщательный анализ и сопоставление данных являются ключевыми этапами в процессе классификации [16–21]. Они способствуют обеспечению точности и надежности результатов. Важно учитывать все возможные факторы, влияющие на классификацию, и применять соответствующие методы для минимизации погрешностей.

Процесс классификации данных требует внимательного и тщательного подхода. Только так можно достичь высокой точности и надежности результатов. Следует помнить, что классификация представляет собой сложный процесс, включающий учет множества факторов и применение различных методов и алгоритмов.

### ***Исследование функционирования программного обеспечения***

Исследование функционирования программного обеспечения для анализа дорожных снимков осуществлялось на основе изображений дорожного движения города Владивостока, полученных каждые 30 секунд в дневное время при ясной атмосфере. Процесс включал несколько этапов, каждый из которых был тщательно спланирован и реализован.

На первом этапе массив изображений был разделен на обучающую и тестовую выборки. Из обучающей выборки были выделены характерные контуры различных классов транспортных средств, что способствовало улучшению способности системы к их распознаванию и классификации в дальнейшем.

На последующем этапе система прошла обучение, в рамках которого проводился анализ и классификация транспортных средств с использованием выделенных контуров. Этот процесс был необходим для того, чтобы система научилась идентифицировать и корректно классифицировать различные виды транспорта.

По завершении обучения система была применена к тестовой выборке изображений, где выполнялся их анализ с последующим распределением транспортных средств по категориям. Полученные результаты были сопоставлены с эталонными распределениями, сохраненными в специальном файле. Это позволило оценить точность и эффективность функционирования системы.

Для оценки эффективности подсчета и классификации транспортных средств использовались два критерия: погрешность подсчета и погрешность классификации. Эти показатели позволили определить степень точности системы в выполнении задачи и выявить области, требующие дальнейшего совершенствования. Исследование функционирования программного обеспечения для анализа дорожных снимков представляет собой значимый шаг в развитии технологий, направленных на повышение безопасности и эффективности дорожного движения. Результаты данного исследования могут быть использованы для разработки новых методик и алгоритмов, которые улучшат качество анализа и классификации транспортных средств. Погрешность подсчета автомобильного транспорта определялась как отношение разности между общим количеством подсчитанного транспорта и количеством транспорта на изображении к последнему:

$$M_{\text{подс}} = \frac{|K_{\text{подс}} - K_{\text{общ}}|}{K_{\text{общ}}},$$

где  $M_{\text{подс}}$  – метрика погрешности подсчета по снимку;  $K_{\text{подс}}$  – общее количество подсчитанного транспорта;  $K_{\text{общ}}$  – количество транспорта, изображенного на снимках.

Погрешность классификации автомобильного транспорта вычислялась как отношение разности между векторами количеств подсчитанного и реального транспорта по категориям к вектору реальных количеств:

$$M_{\text{класс}} = \frac{|\bar{a} - \bar{b}|}{|\bar{b}|},$$

где  $M_{\text{класс}}$  – метрика погрешности классификации по снимку;  $\bar{a}$  – вектор количеств подсчитанного транспорта по категориям;  $\bar{b}$  – вектор количеств транспорта на снимке по категориям.

В процессе тестирования были проведены эксперименты с различными параметрами системы, включая разрешение изображений, уровень освещенности и временные интервалы. Результаты экспериментов показали высокую точность подсчета и классификации, особенно при хорошем освещении и высоком разрешении изображений.

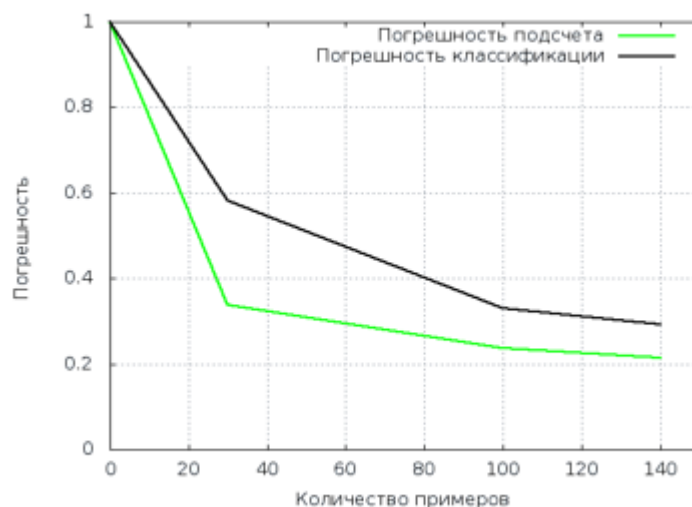
Дополнительно были проведены тесты на реальных данных, собранных в различных погодных условиях и в разное время суток. Эти тесты подтвердили способность системы адаптироваться к разнообразным условиям и выдавать точные результаты.

В дальнейшем планируется усовершенствование системы за счет внедрения новых алгоритмов и методов обработки изображений, а также увеличения объема обучающих данных для повышения точности классификации.

Система успешно справилась с задачей подсчета и классификации транспортных средств на различных последовательностях изображений дорожного движения. Это свидетельствует о ее способности адаптироваться к разнообразным условиям и сценариям, что является критически важным для систем видеонаблюдения и управления дорожным движением.

### **Результаты тестирования**

На рис. 5 представлены графики зависимости погрешностей подсчета и классификации от количества примеров, использованных в процессе обучения модели. Наблюдается снижение погрешностей с увеличением объема данных, что указывает на способность модели к обучению и повышению производительности.



**Рис. 5. Графики зависимостей погрешностей подсчета и классификации от числа примеров**

Для обучающей выборки погрешность составила 21 %, что является сравнительно низким значением, учитывая сложность задачи. Это свидетельствует о хорошем усвоении моделью закономерностей и её способности эффективно обобщать полученные знания на новые данные.

Для тестовой выборки погрешность при 140 примерах составила 32,4 %. Это указывает на способность модели достигать высокой точности на новых данных, однако дальнейшее обучение необходимо для улучшения результатов.

Результаты тестирования подтверждают высокую эффективность системы в подсчете и классификации транспортных средств. Зависимость погрешностей от объема данных показывает, что модель может значительно улучшить свою производительность с увеличением количества примеров. Это открывает перспективы для дальнейшего обучения и разработки более точных моделей, которые смогут эффективно работать в реальных условиях дорожного движения. Важно отметить, что результаты

могут варьироваться в зависимости от качества и разнообразия данных, используемых для обучения. Поэтому важно продолжать работу над улучшением качества данных и разработкой более сложных моделей, способных учитывать различные сценарии и условия дорожного движения.

### *Заключение*

В данной работе представлены общие принципы работы системы мониторинга транспорта, использующей технологии машинного зрения. Данная система является не только эффективным и экономичным способом мониторинга транспорта, она также дает возможности для исследований в области машинного зрения.

Механизмы классификации контуров с использованием кластерного анализа, предложенные в этой работе, являются в своем роде уникальными и открывают еще одну нишу для исследований в области машинного зрения.

Тем не менее, несмотря на достигнутые результаты, модель все еще нуждается в доработке для повышения точности и надежности. В частности, необходимо уделить внимание оптимизации параметров модели и улучшению алгоритмов обработки изображений. Кроме того, важным аспектом является сбор и анализ дополнительных данных, которые могут улучшить обобщающую способность модели.

Одним из возможных направлений для дальнейших исследований является использование более сложных архитектур нейронных сетей, таких как сверточные нейронные сети (CNN) или рекуррентные нейронные сети (RNN). Эти архитектуры могут обеспечить более глубокое понимание пространственных и временных зависимостей в данных, что может привести к улучшению результатов.

Кроме того, стоит рассмотреть возможность интеграции модели с другими системами, такими как системы управления дорожным движением или системы мониторинга окружающей среды. Это позволит создать более комплексную и эффективную систему, способную решать широкий спектр задач в области анализа дорожного движения.

### Список литературы

- 1 **Bouwman, T.** Background Modeling using Mixture of Gaussians for Foreground Detection / T. Bouwman, F. El Baf, B. Vachon. – A Survey. – Recent Patents on Computer Science. – November 2008. – DOI 10.2174/1874479610801030219.
- 2 **Smids, M.** Background Subtraction for Urban Traffic Monitoring using Webcams / M. Smids. – P. 1–43. – Universiteit van Amsterdam, FNWI, 2006.
- 3 Синергия подходов к совершенствованию интеллектуальных транспортных систем городов в России и Белоруссии / И. Н. Пугачев, Д. В. Капский, Д. В. Навой [и др.]. – Хабаровск : Тихоокеанский государственный университет, 2020. – 230 с. – ISBN 978-5-7389-3154-3.
- 4 **Пугачев, И. Н.** Совершенствование методов оценки качества и безопасности дорожного движения / И. Н. Пугачев, Н. Г. Шешера, А. В. Каменчуков. – Хабаровск : Изд-во Тихоокеанского государственного университета, 2018. – 160 с.
- 5 **Бурков, С. М.** Задачи системного анализа и методология формирования интеллектуальной системы управления транспортным комплексом города / С. М. Бурков, Г. Я. Маркелов, И. Н. Пугачёв // Вестник Тихоокеанского государственного университета. – 2013. – № 4. – С. 83–90. – ISSN 1996-3440.

### References

- 1 **Bouwman, T.** Background Modeling using Mixture of Gaussians for Foreground Detection / T. Bouwman, F. El Baf, B. Vachon. – A Survey. – Recent Patents on Computer Science. – November 2008. – DOI 10.2174/1874479610801030219.
- 2 **Smids, M.** Background Subtraction for Urban Traffic Monitoring using Webcams / M. Smids. – P. 1–43. – Universiteit van Amsterdam, FNWI, 2006.
- 3 Synergy of approaches to improving intelligent transport systems of cities in Russia and Belarus / I. N. Pugachev, D. V. Kapsky, D. V. Navoy [et al.]. – Khabarovsk : Pacific State University, 2020. – 230 p. – ISBN 978-5-7389-3154-3.
- 4 **Pugachev, I. N.** Improving methods for assessing the quality and safety of road traffic / I. N. Pugachev, N. G. Sheshera, A. V. Kamenchukov. – Khabarovsk : Publishing house of the Pacific State University, 2018. – 160 p.
- 5 **Burkov, S. M.** Tasks of system analysis and methodology for the formation of an intelligent control system for the city transport complex / S. M. Burkov, G. Ya. Markelov, I. N. Pugachev // Bulletin of the Pacific State University. – 2013. – No. 4. – P. 83–90. – ISSN 1996-3440.

6 **Pham, D. L.** Current methods in medical image segmentation / D. L. Pham, C. Xu, J. L. Prince // *Annu Rev Biomed Eng.* 2000;2 : 315-37. – DOI 10.1146/annurev.bioeng.2.1.315.

7 **Koenderink, J. J.** The structure of images / J. J. Koenderink // *Biol Cybern.* 1984 ; 50(5) : 363-70. – DOI 10.1007/BF00336961.

8 **Тормозов, В. С.** Подсчет и распознавание автомобилей на спутниковых снимках / В. С. Тормозов // *Ученые заметки ТОГУ.* – 2017. – Т. 8. – № 3. – С. 126–134. – ISSN 2079-8490.

9 **Barrow, H. G.** Interpreting line drawings as three-dimensional surfaces / H. G. Barrow, J. M. Tenenbaum // *Artificial Intelligence*, 17(1–3), 75–116. – DOI 10.1016/0004-3702(81)90021-7.

10 **Тормозов, В. С.** Метод детектирования и классификации транспортных средств на спутниковых снимках сверхвысокого разрешения / В. С. Тормозов // *Промышленные АСУ и контроллеры.* – 2019. – № 6. – С. 18–24. – DOI 10.25791/asu.06.2019.678.

11 **Пугачев, И. Н.** Методика подсчета транспортных средств с использованием космических снимков высокого пространственного разрешения / И. Н. Пугачев, Г. Я. Маркелов, В. С. Тормозов // *Вестник Тихоокеанского государственного университета.* – 2017. – № 2 (45). – С. 13–20. – EDN ZEGASL. – ISSN 1996-3440.

12 **Пугачев, И. Н.** Ускорение алгоритма детектирования транспортных средств на спутниковых снимках с помощью процедуры фильтрации гипотез / И. Н. Пугачев, Г. Я. Маркелов, В. С. Тормозов // *Вестник Российского нового университета. Серия : Сложные системы : модели, анализ и управление.* – 2019. – № 1. – С. 130–139. – DOI 10.25586/RNU.V9187.19.01.P.130.

13 **Vezhnevets, A.** Avoiding boosting overfitting by removing confusing samples / A. Vezhnevets, O. Barinova // *Lecture Notes in Computer Science.* – 2007. – Vol. 4701 LNAI. – P. 430–441. – DOI 10.1007/978-3-540-74958-5\_40.

14 **Suzuki, S.** Topological Structural Analysis of Digitized Binary Images by Border Following / S. Suzuki, K. Abe // *Computer Vision, Graphics, and Image Processing. Volume 30, Issue 1, April 1985.* – P. 32–46. – URL: [https://doi.org/10.1016/0734-189X\(85\)90016-7](https://doi.org/10.1016/0734-189X(85)90016-7).

15 **Золкин, А. Л.** Интеллектуальная программно-информационная система для диагностирования и прогнозирования технического состояния тяговых электродвигателей / А. Л. Золкин, В. С. Тормозов, Д. В. Гридина // *Известия Самарского научного центра Российской академии наук.* – 2020. – Т. 22. – № 4. – С. 92–97. – DOI 10.37313/1990-5378-2020-22-4-92-97.

6 **Pham, D. L.** Current methods in medical image segmentation / D. L. Pham, C. Xu, J. L. Prince // *Annu Rev Biomed Eng.* 2000;2:315-37. – DOI 10.1146/annurev.bioeng.2.1.315.

7 **Koenderink, J. J.** The structure of images / J. J. Koenderink // *Biol Cybern.* 1984 ; 50(5) : 363-70. – DOI 10.1007/BF00336961.

8 **Tormozov, V. S.** Counting and recognition of cars on satellite images / V. S. Tormozov // *Scientific notes of PSU.* – 2017. – Vol. 8. – No. 3. – P. 126–134. – ISSN 2079-8490.

9 **Barrow, H. G.** Interpreting line drawings as three-dimensional surfaces / H. G. Barrow, J. M. Tenenbaum // *Artificial Intelligence*, 17(1–3), 75–116. – DOI 10.1016/0004-3702(81)90021-7.

10 **Tormozov, V. S.** Method of detection and classification of vehicles on ultra-high-resolution satellite images / V. S. Tormozov // *Industrial ACS and controllers.* – 2019. – No. 6. – P. 18–24. – DOI 10.25791/asu.06.2019.678.

11 **Pugachev, I. N.** Methodology for counting vehicles using high spatial resolution satellite images / I. N. Pugachev, G. Ya. Markelov, V. S. Tormozov // *Bulletin of the Pacific State University.* – 2017. – No. 2 (45). – P. 13–20. – EDN ZEGASL. – ISSN 1996-3440.

12 **Pugachev, I. N.** Acceleration of the algorithm for detecting vehicles on satellite images using the hypothesis filtering procedure / I. N. Pugachev, G. Ya. Markelov, V. S. Tormozov // *Bulletin of the Russian New University. Series : Complex Systems : Models, Analysis and Control.* – 2019. – No. 1. – P. 130–139. – DOI 10.25586/RNU.V9187.19.01.P.130.

13 **Vezhnevets, A.** Avoiding boosting overfitting by removing confusing samples / A. Vezhnevets, O. Barinova // *Lecture Notes in Computer Science.* – 2007. – Vol. 4701 LNAI. – P. 430–441. – DOI 10.1007/978-3-540-74958-5\_40.

14 **Suzuki, S.** Topological Structural Analysis of Digitized Binary Images by Border Following / S. Suzuki, K. Abe // *Computer Vision, Graphics, and Image Processing. Volume 30, Issue 1, April 1985.* – P. 32–46. – URL: [https://doi.org/10.1016/0734-189X\(85\)90016-7](https://doi.org/10.1016/0734-189X(85)90016-7).

15 **Zolkin, A. L.** Intelligent software and information system for diagnostics and forecasting the technical condition of traction electric motors / A. L. Zolkin, V. S. Tormozov, D. V. Gridina // *Proceedings of the Samara Scientific Center of the Russian Academy of Sciences.* – 2020. – Vol. 22. – No. 4. – P. 92–97. – DOI 10.37313/1990-5378-2020-22-4-92-97.

16 Shadow detection algorithms for traffic flow analysis : a comparative study / A. Prati, I. Mikic, C. Grana, M. M. Trivedi. – ITSC 2001. 2001 IEEE Intelligent Transportation Systems. Proceedings (Cat. No.01TH8585), Oakland, CA, USA, 2001. – P. 340–345. – DOI 10.1109/ITSC.2001.948680.

17 **Тормозов, В. С.** Улучшение работы алгоритма детектирования и классификации транспортных средств на спутниковых снимках путем сокращения области поиска с использованием геоинформации о дорогах / В. С. Тормозов // Вестник Российского нового университета. Серия : Сложные системы : модели, анализ и управление. – 2019. – № 2. – С. 56–63. – DOI 10.25586/RNU.V9187.19.02.P.056.

18 **Лукьяница, А. А.** Цифровая обработка видеозображений / А. А. Лукьяница, А. Г. Шишкин. – Москва : Ай-Эс-Эс-Пресс, 2009. – 518 с. – ISBN 978-5-9901899-1-1.

19 **Ng, J. Y.** Image-based Vehicle Classification System / J. Y. Ng, Y. H. Tay // The 11th Asia-Pacific ITS Forum and Exhibition (ITS-AP 2011), Kaoshiung, Taiwan. June 8–11, 2011. – URL: <https://doi.org/10.48550/arXiv.1204.2114>.

20 Numerical evaluation of the traffic flow indicators using super-resolution satellite imagery / N. Pugachev, G. Ya. Markelov, V. S. Tormozov, A. O. Nosenko // In the collection : 2019 International Multi-Conference on Industrial Engineering and Modern Technologies, FarEastCon 2019. – 2019. – DOI 10.1109/FarEastCon.2019.8934802.

21 **Пугачев, И. Н.** Обучение и использование сверточной нейронной сети для детектирования и классификации транспортных средств на спутниковых снимках высокого разрешения / И. Н. Пугачев, Г. Я. Маркелов, В. С. Тормозов // Промышленные АСУ и контроллеры. – 2019. – № 10. – С. 20–25. – DOI 10.25791/asu.10.2019.933.

16 Shadow detection algorithms for traffic flow analysis : a comparative study / A. Prati, I. Mikic, C. Grana, M. M. Trivedi. – ITSC 2001. 2001 IEEE Intelligent Transportation Systems. Proceedings (Cat. No.01TH8585), Oakland, CA, USA, 2001. – P. 340–345. – DOI 10.1109/ITSC.2001.948680.

17 **Tormozov, V. S.** Improving the performance of the algorithm for detecting and classifying vehicles in satellite images by reducing the search area using geoinformation about roads / V. S. Tormozov // Bulletin of the Russian New University. Series : Complex systems : Models, Analysis and Control. – 2019. – No. 2. – P. 56–63. – DOI 10.25586/RNU.V9187.19.02.P.056.

18 **Lukyanitsa, A. A.** Digital processing of video images / A. A. Lukyanitsa, A. G. Shishkin. – Moscow : ISS-Press, 2009. – 518 p. – ISBN 978-5-9901899-1-1.

19 **Ng, J. Y.** Image-based Vehicle Classification System / J. Y. Ng, Y. H. Tay // The 11th Asia-Pacific ITS Forum and Exhibition (ITS-AP 2011), Kaoshiung, Taiwan. June 8–11, 2011. – URL: <https://doi.org/10.48550/arXiv.1204.2114>.

20 Numerical evaluation of the traffic flow indicators using super-resolution satellite imagery / N. Pugachev, G. Ya. Markelov, V. S. Tormozov, A. O. Nosenko // In the collection : 2019 International Multi-Conference on Industrial Engineering and Modern Technologies, FarEastCon 2019. – 2019. – DOI 10.1109/FarEastCon.2019.8934802.

21 **Pugachev, I. N.** Training and using a convolutional neural network for detecting and classifying vehicles in high-resolution satellite images / I. N. Pugachev, G. Ya. Markelov, V. S. Tormozov // Industrial ACS and Controllers. – 2019. – No. 10. – P. 20–25. – DOI 10.25791/asu.10.2019.933.

*I. N. Pugachev, V. S. Tormozov*

## **DEVELOPMENT AND ANALYSIS OF A ROAD TRAFFIC MONITORING SYSTEM BASED ON MACHINE VISION TECHNOLOGIES AND CLUSTER ANALYSIS METHODS**

**Abstract.** This article presents a traffic monitoring system based on the principles of machine vision. The system is based on simple webcams mounted above the roadbed that capture images of vehicles. Further, using image processing algorithms and machine learning methods, the system determines the number and classification of vehicles on the road. The system includes several key modules: a background subtraction module, a foreground segmentation module, a contour acquisition module, a contour training and classification module, a property allocation module and a clustering module. Each of these modules performs specific functions aimed at ensuring accurate and reliable vehicle detection. The system has been tested on traffic images. The test results confirm the system's ability to adapt to various conditions and scenarios, which is critically important for video surveillance and traffic management systems. The article also discusses the prospects for further development

of the system, including the possibility of using more complex neural network architectures and integration with other systems.

**Keywords:** traffic monitoring, machine vision, image processing, machine learning, vehicle classification.

**For citation:** Pugachev, I. N. Development and analysis of a road traffic monitoring system based on machine vision technologies and cluster analysis methods / I. N. Pugachev, V. S. Tormozov // Vestnik Rostovskogo Gosudarstvennogo Universiteta Putey Soobshcheniya. – 2024. – No. 4. – P. 134–145. – DOI 10.46973/0201-727X\_2024\_4\_134.

#### Сведения об авторах

##### **Пугачев Игорь Николаевич**

Хабаровский Федеральный  
исследовательский центр Дальневосточного  
отделения Российской академии наук  
(ХФИЦ ДВО РАН),  
заместитель директора по научной работе,

Дальневосточный государственный  
университет путей сообщения (ДВГУПС),  
кафедра «Изыскания и проектирования  
железных и автомобильных дорог»,  
доктор технических наук, профессор,  
e-mail: ipugachev64@mail.ru

##### **Тормозов Владимир Сергеевич**

Тихоокеанский государственный  
университет,  
кандидат технических наук, доцент высшей  
школы кибернетики и цифровых  
технологий,  
e-mail: 007465@pnu.edu.ru

#### Information about the authors

##### **Pugachev Igor Nikolaevich**

Khabarovsk Federal Research Center  
Far Eastern Branch of the Russian Academy  
of Sciences (KhRC FEB RAS),  
Deputy Director for Research,

Far Eastern State Transport University  
(FESTU),  
Chair «Surveying and Design of Railways  
and Highways»,  
Doctor of Engineering Sciences, Professor,  
e-mail: ipugachev64@mail.ru

##### **Tormozov Vladimir Sergeevich**

Pacific National University,  
Candidate of Engineering Sciences,  
Associate Professor of the Higher School  
of Cybernetics and Digital Technologies,  
e-mail: 007465@pnu.edu.ru