

УДК 004.932

DOI: [10.26102/2310-6018/2023.40.1.016](https://doi.org/10.26102/2310-6018/2023.40.1.016)

## Программный комплекс поддержки принятия решений для определения факта нарушения ПДД по траектории транспортного средства на видеоизображении

Р.Н. Минниханов<sup>1</sup>, И.В. Аникин<sup>2</sup>, М.В. Дагаева<sup>1</sup>, П.А. Чернышевский<sup>1</sup>,  
А.Р. Кадыров<sup>1</sup>

<sup>1</sup>ГБУ «Безопасность дорожного движения», Казань, Российская Федерация

<sup>2</sup>Казанский национальный исследовательский технический университет им. А.Н.

Туполева-КАИ, Казань, Российская Федерация

[anikinigor777@mail.ru](mailto:anikinigor777@mail.ru)

**Резюме.** В работе представлен подход к определению факта нарушения правил дорожного движения на основании анализа траектории транспортного средства на видеоизображении. В качестве примера в статье исследовался факт запрещенного левого поворота. Данный подход реализован в соответствующем программном комплексе поддержки принятия решений. В качестве детектора объектов в предложенном подходе применена архитектура нейронной сети YOLO, для распознавания номерных знаков применена нейронная сеть LPRNet, для ускорения вычислений путем прореживания точек траекторий использован алгоритм Рамера-Дугласа-Пекера. На примере запрещенного левого поворота исследован ряд классификаторов: SVM, GaussianNB, алгоритм k-средних, деревья решений, Random Forest. Указанные классификаторы могут быть применены для определения принадлежности траекторий к классу траекторий, нарушающих правила дорожного движения. По результатам вычислительных экспериментов установлено, что метод опорных векторов имеет наибольшую точность среди исследуемых классификаторов (около 95 %). Отмечено снижение вычислительных затрат за счет использования алгоритма прореживания траектории и легковесных моделей нейронных сетей. На примере детекции факта левого поворота представлены возможности интеграции разработанной системы поддержки принятия решений в работу Центров автоматизированной фиксации административных правонарушений.

**Ключевые слова:** интеллектуальные транспортные системы, система поддержки принятия решений, обработка видеоизображений, машинное обучение, нейронные сети, классификация траекторий.

**Для цитирования:** Минниханов Р.Н., Аникин И.В., Дагаева М.В., Чернышевский П.А., Кадыров А.Р. Программный комплекс поддержки принятия решений для определения факта нарушения ПДД по траектории транспортного средства на видеоизображении. *Моделирование, оптимизация и информационные технологии.* 2023;11(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1311> DOI: 10.26102/2310-6018/2023.40.1.016

## Decision support system for detecting traffic violations based on vehicle's trajectory

R.N. Minnikhanov<sup>1</sup>, I.V. Anikin<sup>2</sup>, M.V. Dagaeva<sup>1</sup>,  
P.A. Chernyshevskij<sup>1</sup>, A.R. Kadyrov<sup>1</sup>

<sup>1</sup>Road Safety State Company, Kazan, Russian Federation

<sup>2</sup>Kazan National Research Technical University named after A.N.Tupolev-KAI, Kazan,  
Russian Federation

[anikinigor777@mail.ru](mailto:anikinigor777@mail.ru)

**Abstract.** The paper proposes the approach for detecting the traffic violations based on illegal vehicle's trajectory on video streams. As an example of such violations, illegal left turn is considered. This approach was implemented in a decision support system. YOLO neural network was employed as an object detector as part of the approach, LPRNet network for license plate recognition, and Ramer-Douglas-Pecker algorithm for the trajectory thinning. Using the example of the illegal left turn, a number of classifiers was studied: SVM, GaussianNB, KNeighbors, Decision Tree, Random Forest classifiers. These classifiers can be utilized to identify trajectories that violate road traffic regulations. Numerical experiments demonstrate that the SVM has about 95 % of classification accuracy among other algorithms. The computational cost also decreased due to the use of the trajectory thinning algorithm and lightweight neural network models. The capabilities of decision support system integration into the Centre for Automated Recording of Traffic Offences were illustrated by the example of left turn detection.

**Keywords:** intelligent transport system, decision support system, video image processing, machine learning, neural networks, trajectory classification.

**For citation:** Minnikhanov R.N., Anikin I.V., Dagaeva M.V., Chernyshevskij P.A., Kadyrov A.R. Decision support system for detecting traffic violations based on vehicle's trajectory. *Modeling, Optimization and Information Technology*. 2023;11(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1311> DOI: 10.26102/2310-6018/2023.40.1.016 (In Russ.).

## Введение

Устойчивый рост и развитие транспорта в России и все возрастающая потребность в транспортных услугах сопряжены со многими проблемами, среди которых не последнее место занимает вопрос безопасности движения. Повышение уровня безопасности, снижение показателей аварийности и смертности является одной из ключевых задач работы государственных и муниципальных органов.

Внедрение интеллектуальных транспортных систем позволяет эффективно и с минимальными затратами решать актуальные проблемы транспортной отрасли, в том числе касающиеся безопасности. Появление автоматизированных систем фотовидеофиксации (ФВФ) нарушений ПДД, автоматизированных систем весогабаритного контроля и установка адаптивных светофорных объектов позволяет напрямую или косвенно улучшить дорожную ситуацию. В качестве примера можно рассмотреть опыт внедрения ИТС в Республике Татарстан, где после начала эксплуатации комплексов ФВФ более чем в два раза сократилось число погибших в ДТП [1-2].

В настоящий момент ведутся работы над расширением возможностей применения интеллектуальных технологий в сфере транспортного регулирования и мониторинга с целью автоматизации процесса принятия решений. Одним из направлений исследований в этой области является интеллектуальная аналитика видеопотоков, получаемых с обзорных камер, в частности, выявление аномальных траекторий движения транспортных средств [3-7]. Результаты видеоаналитики можно использовать при поддержке принятия решений в центрах автоматизированной фиксации административных правонарушений (ЦАФАП). В перечень задач таких центров входит, в том числе, обнаружение факта нарушения проезда, например, запрещенного левого поворота в неполюженном месте, с дальнейшим вынесением постановления сотрудником ГИБДД. Автоматизация выявления фактов нарушения ПДД с помощью систем поддержки принятия решений позволит повысить эффективность работы операторов, снизить количество ошибок при вынесении постановлений. В связи с этим в современных ЦАФАП наблюдается тенденция к полной или частичной автоматизации работы операторов по проверке корректности получаемых материалов, обращений к базам данных и подготовки проектов постановлений.

В работе представлен подход по определению факта нарушения правил дорожного движения на основании анализа траектории транспортного средства на видеоизображении. Данный подход реализован в соответствующем программном комплексе поддержки принятия решений.

### 1. Выявление и анализ аномальных траекторий

Под траекторией движения  $\tau$  в данной работе будем понимать последовательность упорядоченных троек вида (1):

$$(x_i, y_i, t_i), \quad i = \overline{1, n}, \quad (1)$$

в которых  $x_i$  и  $y_i$  являются двумерными координатами некоторого транспортного средства на изображении, а компонент  $t_i$  отвечает за время обнаружения. Соответственно, под аномальной траекторией понимается та, у которой элементы последовательности (1) сильно отличаются от большинства других. Такое отклонение может свидетельствовать, например, о произошедшем ДТП или о нарушении правил дорожного движения.

В литературе [5, 8-9] выделяют следующие типы аномалий:

- пространственные аномалии (например, разворот автомобиля);
- временные аномалии, определяемые путем анализа только лишь временных характеристик траектории, таких как длительность и время обнаружения движения (например, дорожная пробка);
- смешанные пространственно-временные аномалии, определяемые посредством анализа и пространственных, и временных координат одновременно (например, некоторые виды ДТП).

В настоящей работе будем рассматривать только пространственные аномалии.

Для детектирования аномальных траекторий движения транспортных средств (ТС), представленных в виде последовательностей (1), предлагается подход, основные этапы которого представлены на Рисунке 1. Получение последовательностей вида (1) из исходного видеопотока представляет собой комплексную задачу, включающую детекцию объектов, их распознавание и отслеживание (трекинг). Полученные траектории служат основой для проведения дальнейшего анализа и выявления аномальных движений среди полученного набора траекторий.

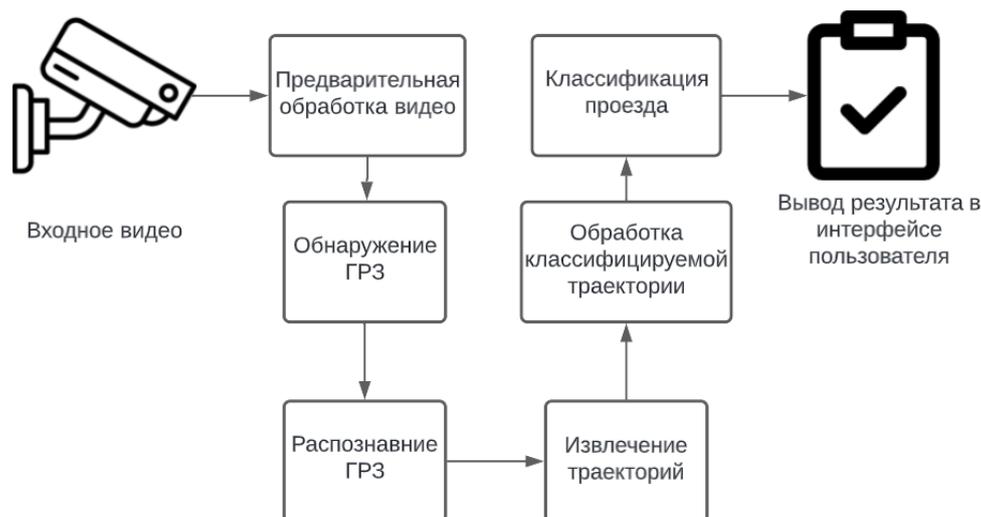


Рисунок 1 – Основные этапы предлагаемого подхода  
 Figure 1 – Main steps of the proposed method

На этапе предварительной обработки видео могут решаться задачи по улучшению качества изображения и удалению шумов. Одним из перспективных подходов при этом является использование генеративно-состязательных нейронных сетей [18].

Для обнаружения государственных регистрационных знаков (ГРЗ) в подходе предлагается использовать архитектуру YOLO [10], построенную на основе сверточных нейронных сетей, дообученную непосредственно для поиска ГРЗ на исходном изображении вместо поиска самого транспортного средства (ТС). Такой подход требует формирования дообучающей выборки, однако позволяет достичь более высокой скорости работы за счет устранения избыточных операций по нахождению ТС, что позволяет применять подход на устройствах невысокой производительности. В работе осуществлялось дообучение модели YOLOv4 tiny на выборке, состоящей из более чем 150 тыс. изображений ТС и соответствующих уникальных изображений ГРЗ, зафиксированных комплексами ФВФ.

Дообучающая выборка формировалась следующим образом.

1. Осуществлялся поиск ключевых точек изображения ТС и изображения ГРЗ, а также вычисление их дескрипторов с помощью алгоритма SIFT [11]. Ключевыми называются точки изображения, которые с большой долей вероятности будут обнаружены на других изображениях рассматриваемого класса. Дескриптором называют идентификатор ключевой точки, который выделяет ее из оставшейся массы.

2. Найденные дескрипторы изображения ТС и ГРЗ попарно сравнивались с целью поиска общих признаков. В результате были оставлены только близкие ключевые точки.

3. Фильтрация близких ключевых точек. Производилось удаление точек-выбросов с применением алгоритма плотностной кластеризации DBSCAN [12]. Кластер, включающий в себя максимальное количество ключевых точек, выбирался в качестве искомого кластера, а входящие в него ключевые точки оставлялись для дальнейшего анализа.

4. Определение координат ГРЗ на основе усредненной разницы расстояний между ключевыми точками изображения ТС и соответствующих им ключевыми точками изображения ГРЗ.

Для распознавания ГРЗ использовалась предварительно обученная нейросеть архитектуры LRPNet [13], позволяющая распознавать номерные знаки с высокой точностью и минимальными затратами вычислительных ресурсов.

В качестве точек  $(x_i, y_i)$  последовательности (1) будем рассматривать центры рамок ГРЗ. Тогда последовательность (1) формируется путем распознавания ГРЗ на последовательных изображениях видеопотока. В данном случае уникальность ГРЗ не требует применения специальных трекеров для отслеживания ТС.

Последовательность (1) формирует траекторию движения ТС. «Сырые» траектории имеют множество шумов, связанных с пространственной перспективной изображением, неравномерной скоростью движения ТС. Такие траектории часто имеют «рваный» вид, а также включают области с «облаками» точек. В связи с этим «сырые» траектории вида (1) требуют обработки для возможности дальнейшего их анализа и классификации. Кроме этого, для уменьшения вычислительных затрат при сравнении траекторий необходимо использовать алгоритмы по сокращению числа анализируемых точек (прореживанию). Эти задачи решаются на этапе обработки классифицируемой траектории.

В работе авторами [5] исследовалось 2 подхода для прореживания траекторий путем поиска точек, являющихся ключевыми для их классификации: применение полиномиальной аппроксимации последовательности (1) с последующим выделением точек с нулевыми первой и второй производными, а также алгоритм Рамера-Дугласа-Пекера [14]. Второй подход позволяет уменьшить число точек анализируемой кривой

так, чтобы результирующая ломаная линия сглаживала исходную с требуемой точностью. В настоящей работе для прореживания траектории был применен модернизированный алгоритм Рамера-Дугласа-Пекера, гарантирующий сохранение максимального числа точек аппроксимации [5].

Далее осуществляется классификация проезда. Полученный набор траекторий можно анализировать на наличие отклонений (аномалий) несколькими способами. Подходы, основанные на алгоритмах классификации, различают нормальные и аномальные траектории путем присвоения соответствующей метки класса [15]. Для реализации при этом необходимо построить обучающее множество с заранее размеченными по принадлежности к классам объектами. В работе [9] исходные данные содержат нормальные и аномальные траектории, но в [8] показано, что если обучающее множество содержит примеры только стандартных траекторий, то в дальнейшем отклонениями можно считать траектории, не принадлежащие ни к одному из рассматриваемых нормальных классов.

В случае, если мы можем измерять меру схожести между объектами, то задачу выявления аномалий можно решить исходя из предположения, что нормальные траектории располагаются достаточно близко в терминах выбранной метрики [8-9, 15]. Здесь также применимы методы кластеризации, разделяющие исходные данные на группы схожих между собой объектов [5, 16]. Если есть уверенность, что данные распределены согласно неким статистическим законам, то можно построить модель, описывающую объекты с достаточной точностью [17]. В перечисленных подходах наличие обучающих множеств не требуется.

В настоящей работе ставится задача выявления нарушений ПДД, поэтому нам точно известно, какие траектории движения мы будем считать аномальными, а значит, можно применить подход на основе классификаторов.

## **2. Разработка программного комплекса поддержки принятия решений**

В работе разработан программный комплекс поддержки принятия решений для определения факта нарушения ПДД (запрещенного левого поворота на перекрестке) по траектории транспортного средства на видеоизображении. Общая блок-схема работы программного комплекса представлена на Рисунке 2. В качестве языка программирования использован Python, все расчеты проведены на ноутбуке DELL G5 15 (Intel Core i5 2.3 GHz, RAM 8 GB, HDD 1000 GB, GeForce GTX 1050).

После получения видеопотока программным комплексом, он предварительно обрабатывается. Предварительная обработка включает в себя разбивку на кадры, приведение разрешения кадров к единому размеру (в данной работе 1920x1280), а также перевод в градации серого, удаление шума.

Далее, с помощью нейросетевой модели YOLOv4 tiny выполняется поиск всех ГРЗ на кадре (Рисунок 3) с дальнейшим их распознаванием нейросетью LPRNet. Базовый блок архитектуры LPRNet включает 4 операции свертки (Рисунок 4). В модели используется операция MaxPool для уменьшения выборки карт объектов, а между конечной и предпоследней операциями свертки вводится коэффициент отсева 0,5.

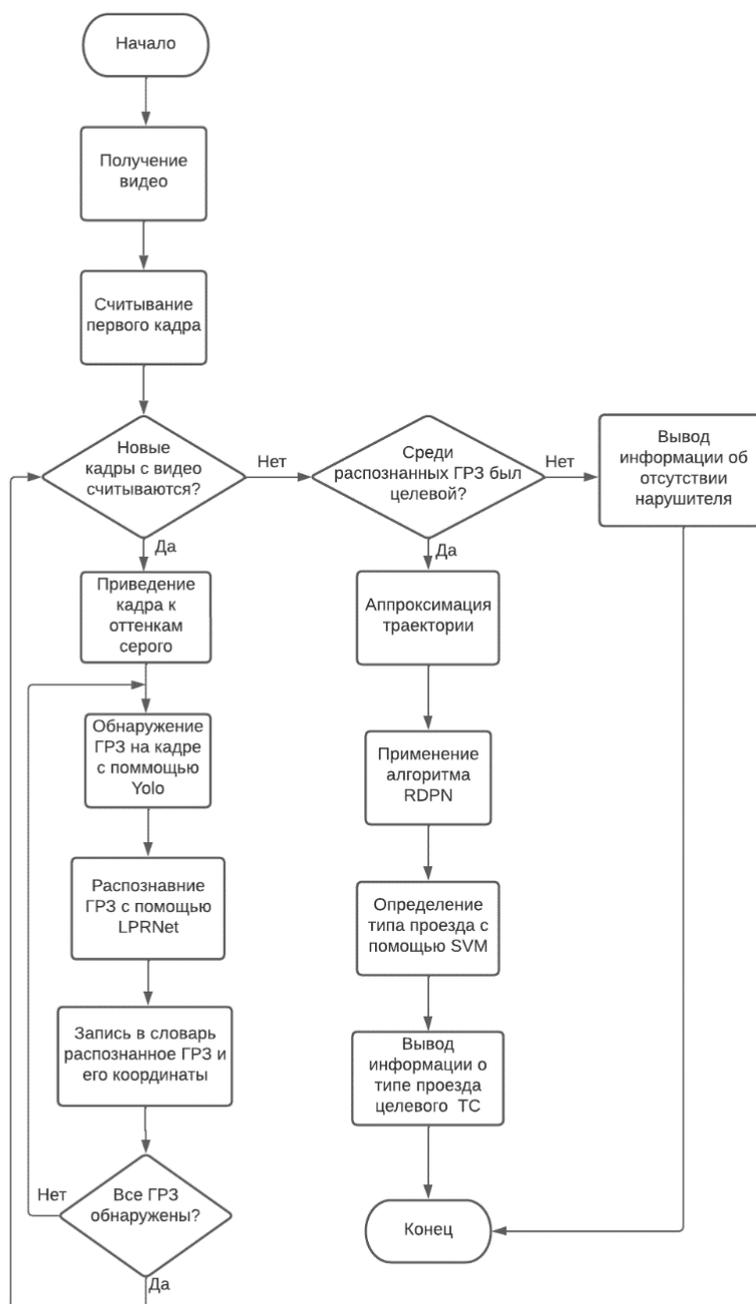


Рисунок 2 – Блок-схема работы программного комплекса  
 Figure 2 – Block diagram of the developed software

Вся информация о проездах ТС заносится в словарь, каждая запись которого имеет вид, представленный на рисунке 5. Каждая такая запись содержит координаты проезда, которые формируют первичную траекторию движения (Рисунок 6). Далее к траектории применяется метод сплайн-аппроксимации и функция равномерно распределенных по сплайну точек траектории (Рисунок 7). Для прореживания числа точек применяется алгоритм Рамера-Дугласа-Пекера с 8 ключевыми точками (Рисунок 8).

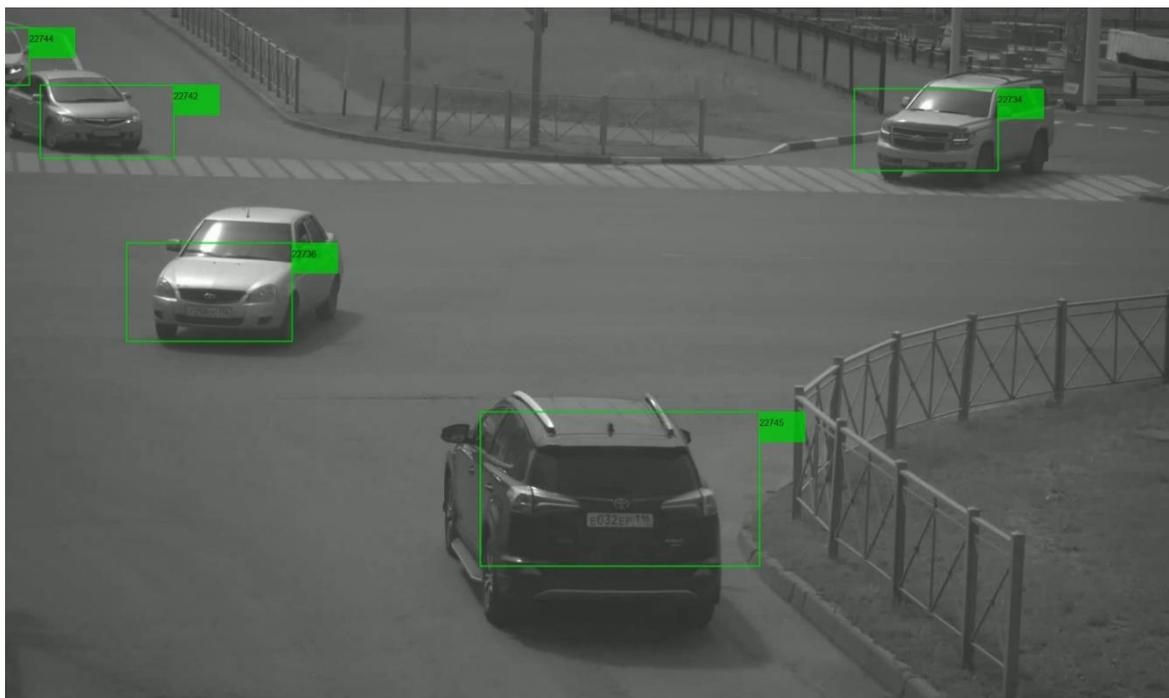


Рисунок 3 – Поиск ГРЗ на изображении  
Figure 3 – LP detection on image

| Layer Type  | Parameters/Dimensions                   |
|-------------|---|
| Input       | $C_{in} \times H \times W$ feature map  |
| Convolution | $\# C_{out}/4$ 1x1 stride 1             |
| Convolution | $\# C_{out}/4$ 3x1 strideh=1, padh=1    |
| Convolution | $\# C_{out}/4$ 1x3 stridew=1, padw=1    |
| Convolution | $\# C_{out}$ 1x1 stride 1               |
| Output      | $C_{out} \times H \times W$ feature map |

Рисунок 4 – Базовый блок LPRNET  
Figure 4 – LPRNet base block

```

{"3.0":
{"CENTRES": [[1408.0, 468.0], [1404.0, 467.0], ..., [1891.0, 746.0]],
"KADRSFIRST": 248,
"KADRSLAST": 895,
"COORSFIRST": [1278.5, 445.6, 1400.1, 492.4],
"COORSLAST": [1841.5, 717.8, 1941.9, 774.2],
"GRZ": "A895MT716"}
}

```

– идентификатор ТС  
– считанные координаты ТС  
– номер первого кадра  
– номер последнего кадра  
– координаты вершин (левой нижней и правой верхней) рамки первого обнаружения ГРЗ  
– координаты вершин (левой нижней и правой верхней) рамки последнего обнаружения ГРЗ  
– распознанный ГРЗ

Рисунок 5 – Структура записи проезда ТС в словаре  
Figure 5 – Structure of the vehicle single record in the dictionary



Рисунок 6 – Первичная траектория ТС  
Figure 6 – Initial vehicle trajectory



Рисунок 7 – Равномерное распределение точек траектории  
Figure 7 – Uniformly distributed trajectory coordinates



Рисунок 8 – Аппроксимация и прореживание траектории с помощью алгоритма Рамера-Дугласа-Пекера (N=8)  
Figure 8 – Trajectory thinning with RDP N (N=8)

В работе исследовались различные алгоритмы классификации траектории, реализованные в библиотеке «sklearn»: метод опорных векторов (SVM), гауссовский наивный байесовский классификатор (GaussianNB), алгоритм  $k$ -ближайших соседей (KNeighborsClassifier), дерево принятия решений (DecisionTreeClassifier) и классификатор случайного леса (RandomForestClassifier). Предварительно были выбраны следующие их параметры:

- для SVM параметр регуляризации  $C = 0.25$ , тип ядра «linear», оценка вероятности «True»;
- для KNeighborsClassifier значение ближайших соседей «3»;
- для DecisionTreeClassifier значение максимальной глубины дерева «5»;
- для RandomForestClassifier значение максимальной глубины дерева «5», количество деревьев в лесу – «10».

Обучение модели происходит при выполнении функции «.fit( $X, y$ )» и подаче на классификатор обучающих векторов ( $X$ ) и целевых значений ( $y$ ). Обучающие вектора ( $X$ ) представляют собой траектории ГРЗ, представленные в виде фиксированного количества координат (16 значений): [ $x_1, y_1, x_2, y_2 \dots x_8, y_8$ ]. Целевые значения ( $y$ ) – представляют собой тип проезда. Метка «0» – разворот, движение прямо с небольшими перестроениями. Метка «1» – поворот налево на перекрестке.

Оценка точности обученной модели выполняется с помощью функции «.score( $X, y$ )», на вход которой подаются значения тестовой выборки.

Обученная модель сохраняется для дальнейшего использования программным комплексом на этапе классификации траекторий с помощью функции «.predict( $X$ )».

### 3. Вычислительные эксперименты

Тестирование программного комплекса производилось с помощью набора данных, состоящего из 472 видеозаписей, размеченных специалистами, – из них 232 включали в себя подтвержденные повороты налево и 240 отмененные повороты (движение с перестроением или разворот). В качестве примера в Таблице 1 представлены вероятности определения факта левого поворота различными классификаторами для траекторий с различными ID.

Таблица 1 – Вероятность определения факта левого поворота разными классификаторами  
Table 1 – Probability of detecting the traffic violation (left-turn) by different classifiers

| ID | SVM   | <i>GaussianNB</i> | <i>Kneighbors</i> | <i>DecisionTree</i> | <i>RandomForest</i> |
|----|-------|-------------------|-------------------|---------------------|---------------------|
| 1  | 0.092 | 0.123             | 0.142             | 0.129               | 0.101               |
| 2  | 0.172 | 0.168             | 0.205             | 0.321               | 0.259               |
| 3  | 0.682 | 0.725             | 0.739             | 0.752               | 0.782               |
| 4  | 0.232 | 0.321             | 0.259             | 0.318               | 0.319               |
| 5  | 0.879 | 0.752             | 0.792             | 0.742               | 0.852               |

Был проведен анализ эффективности работы моделей классификаторов для распознавания каждого типа проезда по метрикам *Accuracy*, *Precision*, *Recall*,  $F_1$ . Итоговые результаты представлены в Таблице 2.

Таблица 2 – Расчет метрик эффективности классификаторов  
Table 2 – Classifiers efficiency metrics estimation

| № | Классификатор          | <i>Precision</i> | <i>Recall</i> | $F_1$         | <i>Accuracy</i> |
|---|------------------------|------------------|---------------|---------------|-----------------|
| 1 | SVM                    | <b>0.9485</b>    | <b>0.9526</b> | <b>0.9505</b> | <b>0.9513</b>   |
| 2 | GaussianNB             | 0.8917           | 0.8917        | 0.9068        | 0.9068          |
| 3 | KNeighborsClassifier   | 0.9114           | 0.9125        | 0.9211        | 0.9216          |
| 4 | DecisionTreeClassifier | 0.9191           | 0.9208        | 0.9251        | 0.9258          |
| 5 | RandomForestClassifier | 0.9316           | 0.9333        | 0.9356        | 0.9364          |

Установлено, что метод опорных векторов имеет наилучшую эффективность среди прочих алгоритмов классификации.

### 4. Практическое использование программного комплекса

Разработанный программный комплекс поддержки принятия решений можно эффективно интегрировать в работу ЦАФАП. В настоящее время неавтоматизированный алгоритм вынесения постановления о правонарушении представлен на Рисунке 10. Проверку каждого правонарушения в ручном режиме осуществляет ответственное лицо (оператор) ЦАФАП, визуально оценивая общее качество изображения, осуществляя проверку правильности данных комплекса ФВФ и формируя проект постановления. Проект постановления затем подписывает ответственный сотрудник ГИБДД. После этого ЦАФАП осуществляет вынесение постановления об административном правонарушении (официальную регистрацию в базах данных ГИБДД) и рассылку копии постановления владельцу ТС.

В данной схеме на оператора ЦАФАП возлагается ряд рутинных, тем не менее ключевых задач, эффективное решение которых не представляется возможным организационными мерами. При необходимости увеличения парка используемых

комплексов или при постоянном увеличении количества нарушений должен быть пропорционально увеличен штат операторов. На работу операторов оказывает влияние человеческий фактор, вследствие чего ряд выносимых постановлений содержит ошибки.

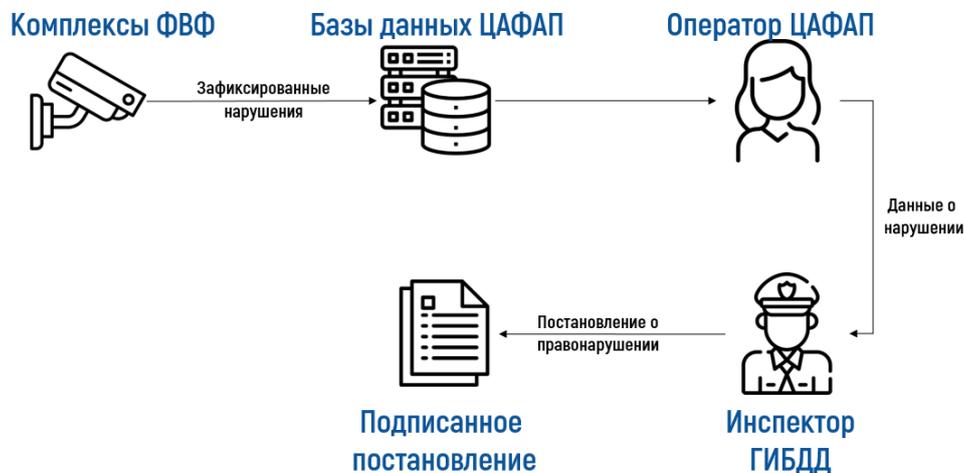


Рисунок 10 – Неавтоматизированный алгоритм вынесения постановления о правонарушении  
Figure 10 – Initial traffic offense decision manual algorithm

Интеграция разработанного программного комплекса в виде системы поддержки принятия решений оператора ЦАФАП позволит облегчить работу оператора по выявлению нарушений. В данном случае автоматизированный алгоритм вынесения постановления о правонарушении будет выглядеть в виде, представленном на Рисунке 11. Система поддержки принятия решений получает видеозаписи проездов потенциальных нарушителей из баз данных, расположенных в ЦАФАП. После обработки видеоматериала при достаточной уверенности классификатора в определении факта левого поворота информация направляется сразу инспектору ГИБДД для вынесения постановления о правонарушении. В случае недостаточной уверенности классификатора, видеозаписи повторно просматриваются операторами ЦАФАП как и в случае неавтоматизированного алгоритма вынесения постановлений.



Рисунок 11 – Автоматизированный алгоритм вынесения постановления о правонарушении  
Figure 11 – Process of delivering a ruling on a traffic offense with the integrated decision support system

## Заключение

В работе представлен подход по определению факта нарушения правил дорожного движения на основании анализа траектории транспортного средства на видеоизображении (на примере неразрешенного левого поворота). Данный подход реализован в соответствующем программном комплексе поддержки принятия решений, который может быть интегрирован в работу ЦАФАП и использован в качестве советующей системы для оператора. Для выявления ГРЗ на видеоизображении использована дообученная нейронная сеть YOLOv4 tiny. Для распознавания номерных знаков применена нейронная сеть LPRNet, для ускорения вычислений путем прореживания точек траекторий использован алгоритм Рамера-Дугласа-Пекера. На примере запрещенного левого поворота исследован ряд классификаторов для определения принадлежности траекторий к классу нарушающих правила дорожного движения, тем самым выявляющий нарушение правил дорожного движения. По результатам вычислительных экспериментов установлено, что метод опорных векторов имеет наибольшую точность среди исследуемых классификаторов (около 95 %).

## СПИСОК ИСТОЧНИКОВ

1. Минниханов Р.Н., Махмутова А.З., Сабиров А.И. ИТС среда Республики Татарстан для обеспечения безопасности дорожного движения. *Современная наука*. 2021;3:92–96.
2. Габдурахманов Л.Р., Минниханов Р.Н., Тинчурин Р.Ф. Интеллектуальные транспортные системы – современная концепция обеспечения безопасности дорожного движения. *Научный портал МВД России*. 2022;1:41–50.
3. Аникин И.В., Минниханов Р.Н., Дагаева М.В., Махмутова А.З., Марданова А.Р. Анализ траекторий движения автотранспортных средств на потоковом видео. *Вестник НЦБЖД*. 2021;4:24–33.
4. Аникин И.В., Марданова А.Р. Выявление аномальных траекторий движения транспортных средств на видеоизображениях. *Математические методы в технологиях и технике*. 2021;1:83–87.
5. Minnikhanov R.N., Anikin I.V., Mardanova A.R., Dagaeva M.V., Makhmutova A.Z., Kadyrov A.R. Evaluation of the Approach for the Identification of Trajectory Anomalies on CCTV Video from Road Intersections. *Mathematics*. 2022;10(388):1–20.
6. Koetsier C., Busch S., Sester M. Trajectory Extraction for Analysis of Unsafe Driving Behaviour. *ISPRS-Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* 2019;42:1573–1578.
7. Ahmed S.A., Dogra D.P., Kar S., Roy P.P. Trajectory-Based Surveillance Analysis: A Survey. *IEEE Trans. Circuits Syst. Video Technol.* 2019;29:1985–1997.
8. Chandola V., Banerjee A., Kumar V., Anomaly Detection: A Survey. *ACM Comput. Surv.* 2009;41:1–58.
9. Santhosh K.K., Dogra D.P., Roy P.P. Anomaly Detection in Road Traffic Using Visual Surveillance: A Survey. *ACM Comput. Surv.* 2021;54:1–26.
10. Redmon J., Divvala S., Girshick R., Farhadi A. *You Only Look Once: Unified, Real-Time Object Detection*. 2016. Доступно по: <https://export.arxiv.org/abs/1506.02640v5> (дата обращения: 10.09.2022).
11. Lowe D.G. Object recognition from local scale-invariant features. *Proceedings of the International Conference on Computer Vision*. 1999;2:1150–1157.
12. Ester M., Krieger H.P., Sander J., Xiaowei Xu A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. *Proceedings of 2nd International Conference on Knowledge Discovery and Data Mining*. 1996:226–231.

13. Zherzdev S., Gruzdev A. LPRNet: License Plate Recognition via Deep Neural Networks; 2018. Доступно по: <https://export.arxiv.org/abs/1806.10447> (дата обращения: 10.09.2022).
14. Douglas D.H., Peucker T.K. Algorithms for the reduction of the number of points required to represent a digitized line or its caricature. *Cartogr. Int. J. Geogr. Inf. Geovisualization*. 1973;10:112–122.
15. Liu S.W.T.T., Ngan H.Y.T., Ng M.K., Simske S.J. Accumulated Relative Density Outlier Detection for Large Scale Traffic Data. *Electron. Imaging*. 2018;9:1–10.
16. D’Acierno A., Saggese A., Vento M. Designing Huge Repositories of Moving Vehicles Trajectories for Efficient Extraction of Semantic Data. *IEEE Trans. Intell. Transp. Syst.* 2015;16:2038–2049.
17. Lam P., Wang L., Ngan H.Y.T., Yung N.H.C., Yeh A.G.O. Outlier Detection in Large-scale Traffic Data by Naïve Bayes Method and Gaussian Mixture Model Method. *IS&T Int’l Sym. Electronic Imaging*. 2017;6:73–78.
18. Khasanova A., Makhmutova A., Anikin I. Image denoising for video surveillance cameras based on deep learning techniques. *Proceedings – 2021 International Conference on Industrial Engineering, Applications and Manufacturing, ICIEAM 2021*. 2021:713–718.

## REFERENCES

1. Minnikhanov R.N., Makhmutova A.M., Sabirov A.I. ITS Environment of the Republic of Tatarstan to ensure road safety. *Sovremennaja nauka = Modern Science*. 2021;(3):92–96. (In Russ.).
2. Gabdurahmanov L.R., Minnikhanov R.N., Tinchurin R.F. Intelligent transport systems as a modern concept of road safety. *Nauchnyj portal MVD Rossii = Scientific portal of the Russia Ministry of the Interior*. 2022;(1):41–50. (In Russ.).
3. Anikin I.V., Minnikhanov R.N., Dagaeva M.V., Makhmutova A.Z., Mardanova A.R. Analysis of vehicle trajectories on streaming video. *Vestnik NCBZhD = Journal «Vestnik NTsBZhD»*. 2021;(4):24–33. (In Russ.).
4. Anikin I.V., Mardanova A.R. Identification of vehicle’s trajectory anomalies on streaming video. *Matematicheskie metody v tehnologijah i tehnike = Mathematical methods in technology and technique*. 2021;(1):83–87. (In Russ.).
5. Minnikhanov R.N., Anikin I.V., Mardanova A.R., Dagaeva M.V., Makhmutova A.Z., Kadyrov A.R. Evaluation of the Approach for the Identification of Trajectory Anomalies on CCTV Video from Road Intersections. *Mathematics*. 2022;10(388):1–20.
6. Koetsier C., Busch S., Sester M. Trajectory Extraction for Analysis of Unsafe Driving Behaviour. *ISPRS-Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* 2019;42:1573–1578.
7. Ahmed S.A., Dogra D.P., Kar S., Roy P.P. Trajectory-Based Surveillance Analysis: A Survey. *IEEE Trans. Circuits Syst. Video Technol.* 2019;29:1985–1997.
8. Chandola V., Banerjee A., Kumar V., Anomaly Detection: A Survey. *ACM Comput. Surv.* 2009;41:1–58.
9. Santhosh K.K., Dogra D.P., Roy P.P. Anomaly Detection in Road Traffic Using Visual Surveillance: A Survey. *ACM Comput. Surv.* 2021;54:1–26.
10. Redmon J., Divvala S., Girshick R., Farhadi A. *You Only Look Once: Unified, Real-Time Object Detection*. 2016. Available from: <https://export.arxiv.org/abs/1506.02640v5> (accessed on 10.09.2022).
11. Lowe D.G. Object recognition from local scale-invariant features. *Proceedings of the International Conference on Computer Vision*. 1999;2:1150–1157.

12. Ester M., Kriegel H.P., Sander J., Xiaowei Xu A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. *Proceedings of 2nd International Conference on Knowledge Discovery and Data Mining*. 1996:226–231.
13. Zherzdev S., Gruzdev A. LPRNet: License Plate Recognition via Deep Neural Networks; 2018. Available from: <https://export.arxiv.org/abs/1806.10447> (accessed on 10.09.2022).
14. Douglas D.H., Peucker T.K. Algorithms for the reduction of the number of points required to represent a digitized line or its caricature. *Cartogr. Int. J. Geogr. Inf. Geovisualization*. 1973;10:112–122.
15. Liu S.W.T.T., Ngan H.Y.T., Ng M.K., Simske S.J. Accumulated Relative Density Outlier Detection for Large Scale Traffic Data. *Electron. Imaging*. 2018;9:1–10.
16. D’Acierno A., Saggese A., Vento M. Designing Huge Repositories of Moving Vehicles Trajectories for Efficient Extraction of Semantic Data. *IEEE Trans. Intell. Transp. Syst.* 2015;16:2038–2049.
17. Lam P., Wang L., Ngan H.Y.T., Yung N.H.C., Yeh A.G.O. Outlier Detection in Large-scale Traffic Data by Naïve Bayes Method and Gaussian Mixture Model Method. *IS&T Int’l Sym. Electronic Imaging*. 2017;6:73–78.
18. Khasanova A., Makhmutova A., Anikin I. Image denoising for video surveillance cameras based on deep learning techniques. *Proceedings – 2021 International Conference on Industrial Engineering, Applications and Manufacturing, ICIEAM 2021*. 2021:713–718.

#### ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

**Минниханов Рифкат Нурғалиевич**, доктор технических наук, профессор, директор, ГБУ «Безопасность дорожного движения», Казань, Российская Федерация.

*e-mail:* [Priemnaya.Minnihanov@tatar.ru](mailto:Priemnaya.Minnihanov@tatar.ru)

ORCID: [0000-0001-9166-2955](https://orcid.org/0000-0001-9166-2955)

**Rifkat Nurgalievich Minnikhanov**, Doctor of Technical Sciences, Professor, Director, Road Safety State Company, Kazan, Russian Federation.

**Аникин Игорь Вячеславович**, доктор технических наук, профессор, заведующий кафедрой систем информационной безопасности, Казанский национальный исследовательский технический университет им. А.Н. Туполева-КАИ, Казань, Российская Федерация.

*e-mail:* [anikinigor777@mail.ru](mailto:anikinigor777@mail.ru)

ORCID: [0000-0001-9478-4894](https://orcid.org/0000-0001-9478-4894)

**Igor Vjacheslavovich Anikin**, Doctor of Technical Sciences, Professor, Head of Information Security Systems Department, Kazan National Research Technical University named after A.N. Tupolev-KAI, Kazan, Russian Federation.

**Дагаева Мария Витальевна**, начальник центра интеллектуальных транспортных систем, ГБУ «Безопасность дорожного движения», Казань, Российская Федерация.

*e-mail:* [dagaevam@rambler.ru](mailto:dagaevam@rambler.ru)

ORCID: [0000-0002-5444-9669](https://orcid.org/0000-0002-5444-9669)

**Maria Vitalievna Dagaeva**, Head of Intelligent Transport Systems Center, Road Safety State Company, Kazan, Russian Federation.

**Чернышевский Павел Андреевич**, специалист первой категории центра разработки и сопровождения информационных систем, ГБУ «Безопасность дорожного движения», Казань, Российская Федерация.

*e-mail:* [pavelcomm@mail.ru](mailto:pavelcomm@mail.ru)

**Pavel Andreevich Chernyshevskij**, 1<sup>st</sup> Category Specialist at the Information Systems Development and Maintenance Center, Road Safety State Company, Kazan, Russian Federation.

ORCID: [0000-0001-5036-6375](https://orcid.org/0000-0001-5036-6375)

**Кадыров Азат Русланович**, специалист первой категории центра разработки и сопровождения информационных систем, ГБУ «Безопасность дорожного движения», Казань, Российская Федерация.

*e-mail*: [azat1706@gmail.com](mailto:azat1706@gmail.com)

ORCID: [0000-0002-2833-4147](https://orcid.org/0000-0002-2833-4147)

**Azat Ruslanovich Kadyrov**, 1<sup>st</sup> Category Specialist at the Information Systems Development and Maintenance Center, Road Safety State Company, Kazan, Russian Federation.

*Статья поступила в редакцию 19.01.2023; одобрена после рецензирования 31.01.2023; принята к публикации 02.03.2023.*

*The article was submitted 19.01.2023; approved after reviewing 31.01.2023; accepted for publication 02.03.2023.*