

ИМИТАЦИОННОЕ МОДЕЛИРОВАНИЕ ДЕВИАНТНОГО ПОВЕДЕНИЯ В АВТОМОБИЛЬНОМ ТРАНСПОРТНОМ ПОТОКЕ

Н.В. Быков^{1,2}
М.А. Костров²
М.С. Товарнов²

bykov@bmstu.ru
maks.kostrow@yandex.ru
tovarnov@bmstu.ru

¹ РУТ (МИИТ), Москва, Российская Федерация

² МГТУ им. Н.Э. Баумана, Москва, Российская Федерация

Аннотация

Предложена имитационная компьютерная модель гетерогенного транспортного потока, основанная на подходе клеточных автоматов. В модели присутствуют три типа агентов — участников дорожного движения: транспортные средства, управляемые человеком, беспилотные и девиантные транспортные средства. В основе динамики движения лежат правила поведения, сформулированные в усовершенствованной модели S-NFS. Предложены и проанализированы три правила поведения девиантных агентов: два правила связаны с перестроением, и одно — с намеренным снижением скорости. Показано, что при средней плотности транспортного потока на него в основном влияют девиантные транспортные средства. Рассмотрена задача выявления девиантного поведения в транспортных потоках с использованием нейронных сетей. Исследование проводилось на созданной обучающей выборке, которая получена с помощью разработанной имитационной модели. Наблюдения в выборке включали в себя данные о скорости отслеживаемого транспортного средства, относительных положениях и скоростях соседних транспортных средств, а также информацию о перестроениях. Эти данные организованы в виде матриц, что позволило эффективно внедрить их в архитектуру нейронной сети. Полученные результаты демонстрируют, что нейронные сети, даже с относительно простой архитектурой, эффективно классифицируют транспортные средства в потоке и выявляют их девиантное пове-

Ключевые слова

Транспортные потоки, клеточные автоматы, девиантные агенты, мультиагентные системы, нейронные сети

Работа выполнена при финансовой поддержке РФФ (грант № 24-21-00306)

Введение. В последние годы стремительное развитие беспилотных автомобильных транспортных средств (БАТС) существенно повлияло на дорожное движение, поскольку эти технологии все активнее интегрируются в существующие транспортные сети [1, 2]. Исследования показывают, что внедрение БАТС может привести к уменьшению числа дорожно-транспортных происшествий, заторов и повышению общей эффективности транспортных систем. Однако при интеграции БАТС в смешанные транспортные потоки возникают новые задачи, особенно в области обеспечения безопасности и надежности [3, 4].

Актуальной проблемой является наличие транспортных средств (ТС) в потоке, поведение которых отклоняется от нормы [5]. Такие ТС часто совершают опасные маневры, недостаточно адекватно реагируют на изменения дорожной обстановки или придерживаются других необычных поведенческих паттернов. В настоящей работе такие ТС, независимо от того, управляются они человеком или являются беспилотными, называются девиантными. Их поведение отличается от большинства участников транспортного потока и может негативно сказываться на общей производительности транспортной системы, что делает их обнаружение и анализ важной задачей.

В настоящее время распознавание и идентификация отдельных участников дорожного движения достигаются с помощью различных технологий и алгоритмов. Наиболее распространенным подходом является компьютерное зрение, которое анализирует видеопотоки для выявления специфических признаков, характеризующих ТС [6, 7]. Эти признаки могут включать в себя форму, размер, цвет ТС, номерной знак и другие атрибуты [8]. Нейросетевые алгоритмы также широко применяются для распознавания ТС, что позволяет системам идентифицировать автомобили по заданным параметрам и классифицировать их по типу, марке, модели и другим параметрам [9]. Еще один подход — использование радаров и лидаров [10], которые основаны на отражении радиоволн или лазерных лучей от поверхностей ТС для определения их размеров, скорости и расстояния до камеры [11]. Системы видеонаблюдения часто используют гибридные методы, комбинируя несколько технологий и алгоритмов, таких как компьютерное зрение с радаром или нейросетевые алгоритмы с лидаром.

Эти технологии в различных комбинациях эффективно используются в системах управления БАТС, поэтому задачу распознавания отдельных участников дорожного движения можно считать во многом решенной.

Результаты анализа поведения агентов на дорогах привлекают внимание разных исследователей [12]. Однако большинство исследований сосредоточено на поведении человека-водителя, в то время как задачи выявления аномального поведения остаются недостаточно изученными. Существует необходимость разработки интеллектуальных систем, способных выявлять нарушителей правил дорожного движения (ТС, управляемых человеком, и БАТС) в общем потоке участников дорожного движения на основе методов наблюдения за транспортным потоком. Особый интерес представляет выявление вышедших из строя БАТС, которые продолжают двигаться в транспортном потоке, и при этом негативно на него влияют.

Для решения задачи обнаружения девиантных БАТС на основе анализа поведения агентов в транспортных потоках предлагаются методы машинного обучения с использованием рекуррентных нейронных сетей [13]. Эти методы анализируют последовательные положения и действия всех участников транспортного потока в течение определенного времени. Такой анализ позволяет выявлять агентов, чье поведение отличается от большинства. Сходные методы [14] применяются для обнаружения аномалий в других сложных динамических системах, таких как информационные системы [15].

Задача выявления девиантных агентов должна основываться на данных, полученных в результате наблюдений за состоянием транспортного потока. Такие наблюдения могут содержать данные о видеопотоках с камер наблюдения, отслеживающих реальные дороги. Однако обработка таких данных связана с дополнительными сложностями, такими как обработка видео, аннотирование данных, полнота выборки, семантический анализ изображений и т. д. Альтернативно данные для обучения могут быть сгенерированы в виртуальной среде. Виртуальная среда моделирует динамику движения транспортного потока на основе математических моделей движения ТС. Такие математические модели должны быть сбалансированными: не слишком сложными, чтобы избежать учета процессов, мало влияющих на результат, и не слишком упрощенными, чтобы корректно учитывать значимые аспекты взаимодействия и поведения агентов.

Цель настоящей работы — разработка модели симуляции транспортного потока, которая позволит оценить негативное влияние девиантных ТС на общий поток транспортной системы, а также алгоритма выявления

таких ТС. Рассмотрим три возможных правила поведения для ТС: два правила смены полосы движения и одно правило снижения скорости.

Имитационная модель. Модели клеточных автоматов (КА) широко используются для моделирования транспортных потоков, так как они эффективно описывают динамику движения [16, 17]. Такой моделью является усовершенствованная модель S-NFS [18], которая учитывает стохастические факторы и неравновесные состояния в транспортных потоках. Расширенная версия модели S-NFS, разработанная специально для БАТС [19], учитывает уникальные особенности их поведения в транспортных потоках. Эти модели позволяют более точно прогнозировать и анализировать поведение как обычных ТС, так и БАТС в различных условиях.

Разработанная модель транспортного потока основана на принципах КА и включает себя следующие категории ТС (или агентов): управляемые человеком, беспилотные автомобильные и ТС с девиантным поведением, управляемые человеком. Модель позволяет оперировать скоростями, представленными несколькими дискретными значениями $v = \{0, \dots, v_{\max}\}$.

Движение ТС, управляемого человеком (HDV), в полосе подчиняется правилам усовершенствованной модели S-NFS и применяется параллельно ко всем агентам в системе.

1. Ускорение: если $g_i > G$ или $v_i^{(0)} < v_{i+1}^{(0)}$, тогда

$$v_i^{(1)} = \min \{v_{\max}, v_i^{(0)} + 1\},$$

где g_i — расстояние (число незанятых клеток) между ТС; $v_i^{(0)}$ — скорость i -го ТС в начале временного шага; $v_{i+1}^{(0)}$ — скорость следующего ТС по направлению движения на текущей полосе.

2. Медленный старт (применяется с вероятностью q), тогда

$$v_i^{(2)} = \min \{v_i^{(1)}, x_{i+s_i}(t-1) - x_i(t-1) - s_i\},$$

где $s_i = S$ (с вероятностью r) и $s_i = 1$ (с вероятностью $1-r$).

3. Быстрый старт, тогда

$$v_i^{(3)} = \min \{v_i^{(2)}, x_{i+s_i}(t) - x_i(t) - s_i\}.$$

4. Случайное торможение (с вероятностью $1-p_i$), тогда

$$v_i^{(4)} = \max \{1, v_i^{(3)} - 1\},$$

где

$$P_i = \begin{cases} P_1, & \text{если } g_i > G; \\ P_2, & \text{если } v_i^{(0)} < v_{i+1}^{(0)}; \\ P_3, & \text{если } v_i^{(0)} = v_{i+1}^{(0)}; \\ P_4, & \text{если } v_i^{(0)} > v_{i+1}^{(0)}. \end{cases}$$

5. Избегание столкновения (коллизии):

$$v_i^{(5)} = \min \{ v_i, g_i(t) + v_i^{(4)} \}.$$

6. Движение вперед:

$$x_i(t+1) = x_i(t) + v_i^{(5)},$$

где $x_i(t)$ — положение i -го ТС в момент времени t . Расстояние между ТС определяется из выражения $g_i = x_{i+1}(t) - x_i(t) - 1$.

Начальная скорость текущего шага $v_i^{(0)}$ равняется скорости предыдущего шага $v_i^{(5)}$:

$$v_i^{(0)}(t) = v_i^{(5)}(t-1) = x_i(t) - x_i(t-1).$$

Величины $G, q, r, S, P_1, P_2, P_3$ и P_4 являются параметрами модели. При моделировании использованы значения: $G = 15, q = 0,99, r = 0,99, S = 2, P_1 = 0,999, P_2 = 0,99, P_3 = 0,98, P_4 = 0,01$.

Беспилотное автомобильное ТС (AV) движется по следующим, основным на модификации правилам [19].

1. Адаптивный круиз-контроль (если движущееся впереди ТС управляется человеком или является девиантным).

Если $v_i^{(0)} = 0$, то

$$v_i^{(1)} = \begin{cases} v_i^{(0)}, & \text{если } g_i = 0; \\ v_i^{(0)} + 1, & \text{если } g_i \geq 1. \end{cases}$$

Если $v_i^{(0)} \in \{1, 2, \dots, v_{\max} - 1\}$, то

$$v_i^{(1)} = \begin{cases} v_i^{(0)} - 1, & \text{если } g_i \leq \text{GAP}_1; \\ v_i^{(0)}, & \text{если } \text{GAP}_1 < g_i < \text{GAP}_2; \\ v_i^{(0)} + 1, & \text{если } g_i \geq \text{GAP}_2, \end{cases}$$

где GAP_1 и GAP_2 — величины, определяемые по табл. 1. Значения, приведенные в табл. 1, получены в результате адаптации реальных данных из технического отчета к текущей модели [19].

Таблица 1

Полученные значения GAP_1 и GAP_2

$v_i^{(0)}$	GAP_1	GAP_2
0	–	–
1	0	4
2	4	6
3	6	8
4	8	10
5	–	–

Если $v_i^{(0)} = v_{\max}$, то

$$v_i^{(1)} = \begin{cases} v_i^{(0)} - 1, & \text{если } g_i \leq GAP_{\max}^{ACC} = 10; \\ v_i^{(0)} + 1, & \text{если } g_i > GAP_{\max}^{ACC} = 10. \end{cases}$$

2. Избегание столкновения (коллизии):

$$v_i^{(2)} = \min \{v_i, g_i(t) + v_i^{(1)}\}.$$

3. Движение вперед:

$$x_i(t+1) = x_i(t) + v_i^{(2)}.$$

Если движущееся впереди ТС также является AV, то вместо правила 1 используется следующее правило:

если $v_i^{(0)} \leq v_{i-1}^{(1)}$, то

$$v_i^{(1)} = \min \{v_{\max}, v_i^{(0)} + 1\};$$

если $(v_i^{(0)} - v_{i-1}^{(1)}) \in \{1, 2, \dots, v_{\max}\}$, то $GAP \in \{gp_1, \dots, gp_{\max}\}$ и

$$v_i^{(1)} = \begin{cases} v_i^{(0)} - 1, & \text{если } g_i < GAP; \\ v_i^{(0)}, & \text{если } g_i \geq GAP, \end{cases}$$

где $gp_1 = 1$, $gp_2 = 3$, $gp_3 = 8$, $gp_4 = 12$ и $gp_5 = gp_{\max} = 17$. Данные значения определяются на основе простой физической оценки относительного тормозного пути двух последовательно идущих ТС [19].

Правило перестроения между полосами основано на модели Кукиды [20]. Решение о перестроении принимается на основании двух критериев (рис. 1):

- 1) стимулирующий критерий $g_i^{(n, f)} + v_{i+1}^{(n)} > v_i \geq g_i^{(p, f)} + v_{i+1}^{(p)}$;
- 2) критерий безопасности $v_i > v_{i-1}^{(n)} - g_i^{(n, b)}$.

В случае выполнения обоих критериев перестроение осуществляется с вероятностью $P = 0,5$. В отличие от [19] здесь БАТС имеют возможность перестраиваться и $P = 1$.

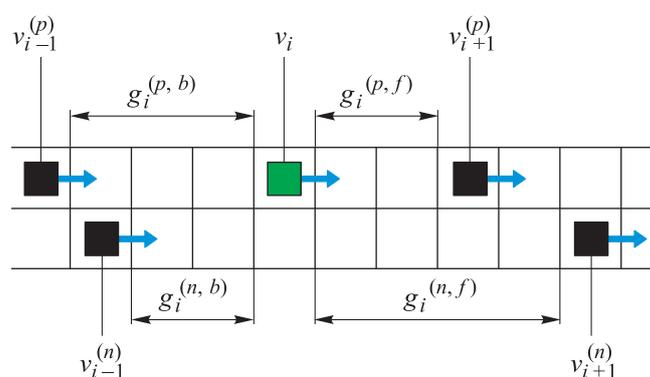


Рис. 1. Пояснения к решению о перестроении ТС, принятому на основании двух критериев

При интеграции модели Кукиды с правилами модели S-NFS необходимо использовать следующий алгоритм:

- применить стимулирующий критерий при перестроении;
- применить критерий безопасности при перестроении;
- перестроиться с вероятностью P ;
- применить правила движения по полосе.

Девантное ТС (DHDV) при движении подчиняется тем же правилам, что и обычные ТС, но с замещением одного из правил.

Правило 1. Замещение стимулирующего критерия при перестроении на критерий

$$\left(v_i < v_{i-1}^{(n)} \right) \wedge \left(v_i < g_i^{(n, f)} + v_{i+1}^{(n)} \right).$$

Правило 2. Замещение стимулирующего критерия при перестроении на критерий

$$\left(v_{i-1}^{(p)} < v_{i-1}^{(n)} \right) \wedge \left(v_i < g_i^{(n, f)} + v_{i+1}^{(n)} \right).$$

Правило 3. Замещение правила случайного торможения на следующее правило:

$$\text{если } (v_i^{(4)} = v_{i+1}^{(4)}) \wedge (v_i^{(4)} > v_{\min}) \wedge (g_i < G), \text{ то } v_i^{(4)} = v_i^{(4)} - 1.$$

Правила 1 и 2 подобраны так, чтобы девиант перестраивался перед ТС, движущимися быстрее него, тем самым вынуждая их также перестраиваться и замедляться.

Методика идентификации девиантных ТС. Рассматривается задача классификации ТС, движущегося в транспортном потоке, по результатам непрерывных наблюдений за самим ТС и некоторой окружающей области за определенный промежуток времени. Каждое ТС принадлежит одному из типов: AV, HDV, DHDV.

Задача классификации решается с помощью классического обучения с учителем. В качестве интеллектуального агента выступает рекуррентная LSTM (Long Short-Term Memory) нейронная сеть [11]. Агент обучается на размеченной выборке для обучения предсказывать тип ТС, за которым наблюдает в определенный период времени (эволюционные шаги КА).

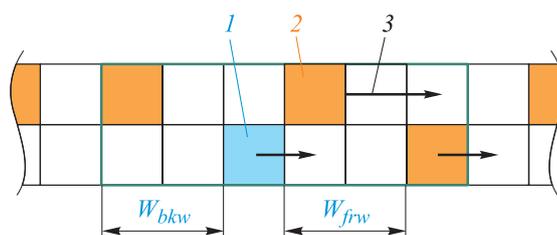
Транспортный поток моделируется для случая двухполосной дороги с периодическими граничными условиями, которая эквивалентна замкнутой кольцевой дороге. Проводится серия симуляций движения транспортного потока при различных параметрах. Выборка для обучения формируется из результатов серии моделирований.

Диапазоны варьирования параметров моделирования

Общее число ТС	[100, 200, 300, 400, 600, 800]
Относительная часть агентов	
HDV/DHDV, %	от 70 / 0 до 0 / 70 с шагом 10
Постоянные параметры	
для серии моделирования:	
доля агентов AV от общего числа ТС, %	30
максимальная скорость ТС v_{\max}	5
длина полосы	500 ячеек
число шагов стабилизации потока	500
число шагов захвата	
(для формирования выборки для обучения)	1000

Выборка для обучения сформирована на результатах моделирования 48 симуляций транспортного потока по 1000 шагов в каждом, со всеми сочетаниями варьируемых параметров.

Выборка для обучения представляет собой совокупность последовательностей наблюдений за каждым ТС, которое участвовало в моделировании. Каждое наблюдение представляет собой матрицу \mathbf{M}_{obs} , в которой зашифрованы данные о скорости отслеживаемого ТС, относительных положениях и скоростях остальных ТС в некоторой окрестности вокруг отслеживаемого ТС, и данные о совершаемых перестроениях. Матрица формируется из состояний КА в некоторой области вокруг ТС (рис. 2).



$$\mathbf{M}_{obs} = \begin{bmatrix} 1 & 0 & 0 & 3 & 0 & 0 \\ 0 & 0 & 2 & 0 & 0 & 2 \end{bmatrix}$$

Рис. 2. Матрица наблюдений, сформированная из состояний КА в некоторой области вокруг ТС:
 1 — отслеживаемое ТС; 2 — ТС в окружающей области;
 3 — скорость ТС

Матрица \mathbf{M}_{obs} размером $M \times N$, где $M = 2$ — число полос движения, а $N = W_{frw} + W_{bkw} + 1$. Параметры W_{frw} и W_{bkw} определяют размер области отслеживания перед и до ТС. В настоящем исследовании значения этих параметров брались одинаковыми и равными 13.

Каждому элементу матрицы \mathbf{M}_{obs} соответствует ячейка КА, расположенная в области вокруг отслеживаемого ТС. Каждый элемент M_{ij} матрицы формируется по следующему алгоритму:

- если соответствующая ячейка КА свободна, то $M_{ij} = 0$;
- если в соответствующей ячейке расположено ТС, то значение элемента M_{ij} рассчитывается из текущей скорости ТС $M_{ij} = v_{ij} + 1$ (чтобы неподвижные ТС отличались от пустых ячеек);
- если на предыдущем шаге моделирования ТС в соответствующей ячейке совершило перестроение, то элемент матрицы умножается на -1 .

Каждое наблюдение в обучающей выборке дополняется меткой y отслеживаемого ТС, согласно его типу: 0 для AV, 1 для HDV, 2 для DHDV.

Итоговая выборка имеет 5760 наблюдений (каждое по 1000 шагов) за ТС типа AV, 6712 наблюдений за ТС типа HAV и 6708 наблюдений за ТС типа HAVD, что в сумме дает более 19 млн наблюдений.

Структура нейронной сети представляет собой последовательность из слоя кодирования, рекуррентных слоев LSTM и полносвязных слоев (многослойный перцептрон) (рис. 3).

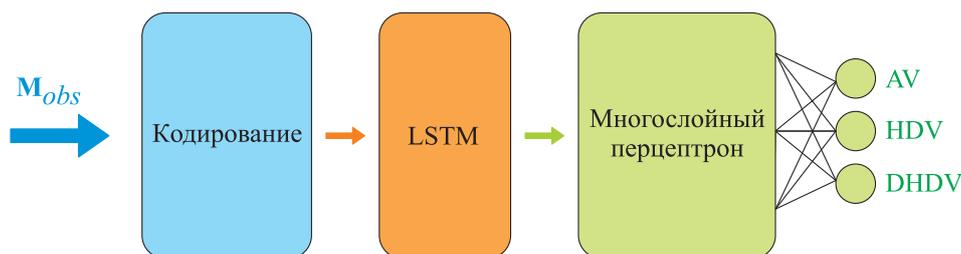


Рис. 3. Структура нейронной сети

В качестве функции потерь использовалась функция NLLLoss (Negative Log Likelihood Loss):

$$l(\theta) = -\sum_{i=1}^N (y_i \log \hat{y}_{\theta,i} + (1 - y_i) \log(1 - \hat{y}_{\theta,i})),$$

где θ — параметры нейронной сети; y_i — метка класса; $\hat{y}_{\theta,i}$ — значение, предсказанное нейронной сетью. В данном исследовании значения на выходном слое y_{last} нормировались с помощью функции Softmax:

$$\hat{y}_j = \text{Softmax}(y_{last, j}) = \frac{\exp(y_{last, j})}{\sum_n \exp(y_{last, n})}.$$

В качестве метрики отслеживания эффективности работы нейронной сети использовалась функция точности

$$\text{Accuracy} = \frac{1}{N} \sum_i 1(y_i = \hat{y}_i).$$

Процедура обучения состоит из последовательности эпох обучения. Каждая эпоха состоит из тренировочной и валидационной частей. Перед началом обучения обучающая выборка также подразделяется на две части — тренировочную и валидационную (в пропорции 90 и 10 % размера выборки). Параметр нейронной сети θ изменяется с помощью метода градиентного спуска на тренировочной части эпохи обучения с использованием тренировочной части выборки. На валидационной части эпохи обучения проводится оценка точности текущей версии

нейронной сети и проверка на переобучение на валидационной части выборки, которая не участвовала в обучении.

Остальные параметры обучения подбирали исходя из возможностей аппаратной части ЭВМ и обеспечения требуемой скорости обучения. В моменты, когда на валидационном шаге происходила стагнация функции потерь, шаг обучения менялся динамически. Обучение останавливалось после насыщения значений функции точности.

Как будет показано далее, даже простые реализации нейронной сети с небольшим числом слоев и нейронов успешно справляются с задачей классификации ТС в предложенной постановке. Основным и самым значимым фактором, определяющим точность классификации, является длина последовательности, т. е. то, как долго нейронная сеть следит за ТС. Так, на рис. 4 приведено сравнение двух различных структур нейронной сети при решении одинаковой задачи (длина последовательности наблюдений $L = 5$).

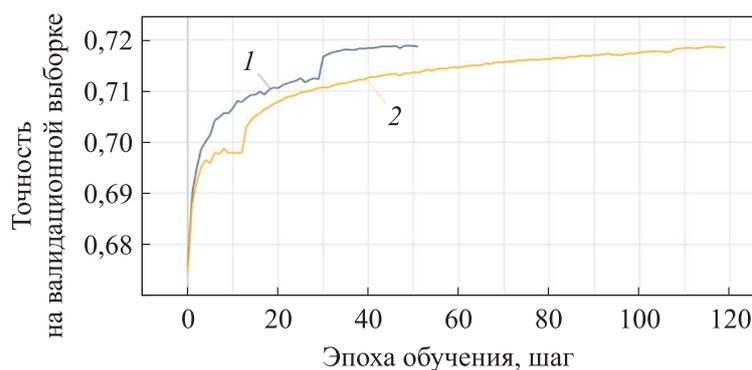


Рис. 4. Сравнение структур малой (1) и большой (2) нейронных сетей при решении одинаковых задачи

Структура малой нейронной сети: два рекуррентных слоя LSTM по 128 нейронов, многослойный перцептрон — два слоя по 256 нейронов с функцией активации ReLU.

Структура большой нейронной сети: три рекуррентных слоя LSTM по 512 нейронов, многослойный перцептрон — четыре слоя по 1024 нейрона с функцией активации ReLU.

В обеих реализациях работа слоя кодирования представляет собой простое поэлементное преобразование матрицы \mathbf{M}_{obs} в одномерный вектор, где каждый элемент матрицы копируется в одномерный вектор на соответствующее место.

Согласно результатам, обе нейронные сети достигли одной и той же точности классификации ТС $\sim 72\%$. Время обучения и число эпох отличаются. В дальнейших расчетах структуры нейронных сетей принимались одинаковыми, соответствующими малой нейронной сети.

Результаты и обсуждение. Для исследования влияния девиантных ТС на поток промоделировано движение ТС по двухполосной круговой дороге длиной 1000 клеток. Доля девиантных ТС варьировалась от 0 до 1 (т. е. до 100 %, когда все ТС девиантные). Каждая серия (отдельная симуляция) разделена на два периода: 1) подготовительный период T_s , для достижения стационарного состояния системы; 2) период наблюдения T_e , в котором оцениваются результаты симуляции. Число временных шагов для подготовительного периода составляет 4500, а для периода наблюдения 2500.

Плотность ρ и средняя скорость $\langle v \rangle$ ТС, а также плотность потока q определялись по формулам:

$$\rho = \frac{N}{M}; \quad \langle v \rangle = \frac{1}{T_e N} \sum_{t=T_s}^{T_s+T_e-1} \sum_{i=0}^{N-1} v_i(t); \quad q = \rho \langle v \rangle.$$

Влияние доли (R) девиантных агентов на транспортный поток, который состоит только из ТС, управляемых человеком, приведено на рис. 5, аналогичные зависимости, но для потока, который включает в себя 30 % БАТС (AV), — на рис. 6.

Из диаграмм на рис. 5, а, в, д следует, что в областях свободного (плотность ТС $< 0,1$) и плотного (плотность ТС $> 0,4$) транспортных потоков влияние присутствия и поведения девиантных ТС на общий поток несущественно. Это объясняется тем, что в свободном потоке каждое ТС движется так, как если бы других ТС не было, а в плотном потоке недостаточно пространства для маневров. Таким образом, единственный диапазон плотности ТС, в котором девиантные ТС могут влиять на поток, составляет 0,1–0,4.

Кривые частоты перестроений (см. рис. 5) указывают, чтобы избежать негативных эффектов, создаваемых девиантными ТС, все ТС в системе начинают чаще менять полосу движения, адаптируясь к возмущениям, вносимым девиантными ТС, и тем самым увеличивая общее число возмущений в системе, что приводит к уменьшению потока.

В рамках задачи идентификации ТС решались две задачи.

1. Показать принципиальную возможность идентификации типа ТС по последовательности наблюдений за ним. Тип наблюдений берется по структуре виртуальной среды, построенной на математической модели КА.

2. Изучить возможности идентификации ТС. Как быстро можно правильно определить тип ТС?

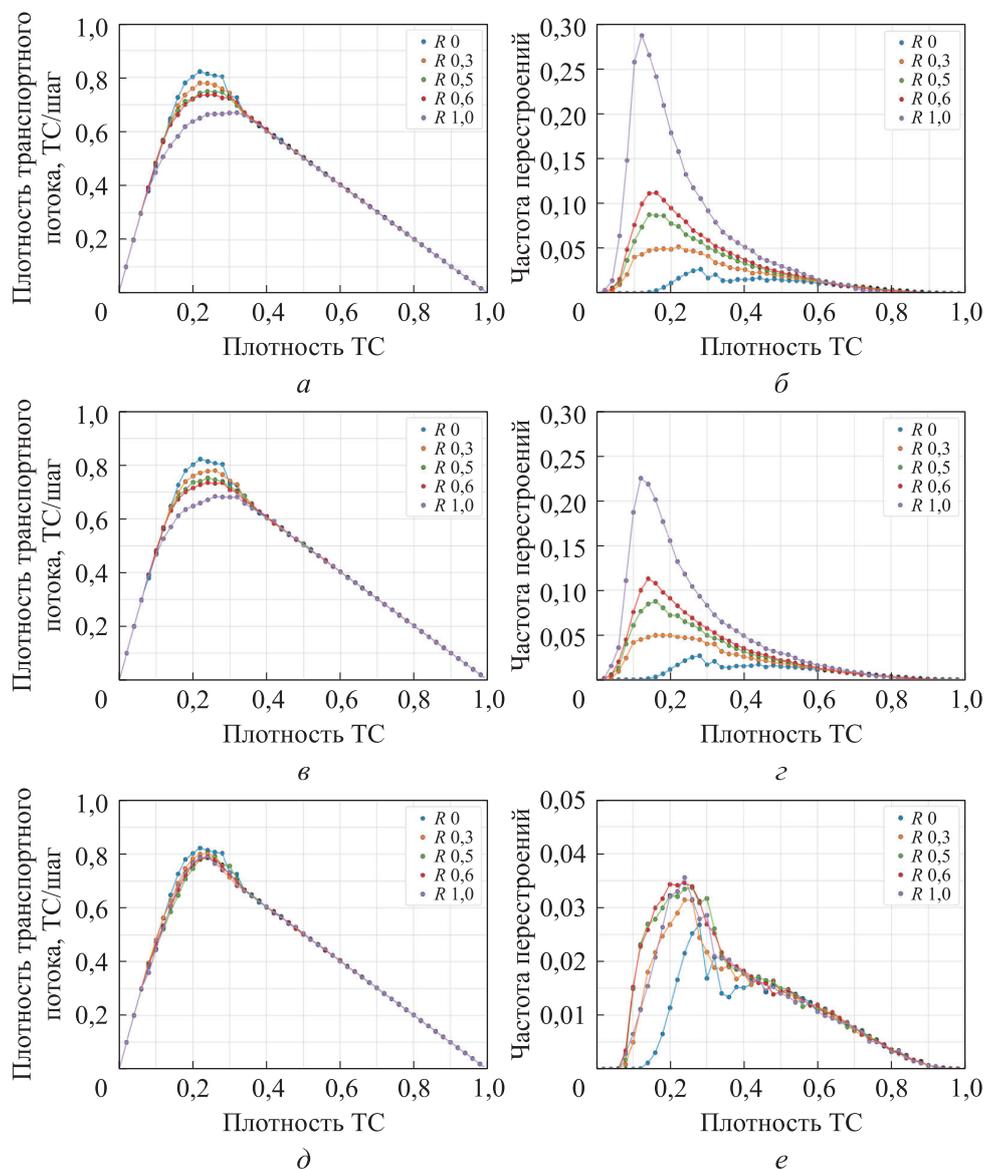


Рис. 5. Зависимости плотности (*a, в, д*) и частоты перестроений (*б, г, е*) транспортного потока, состоящего из ТС, управляемых человеком, от плотности ТС для первого (*a, б*), второго (*в, г*) и третьего (*д, е*) правил поведения девиантного агента; R — доля девиантных агентов в системе

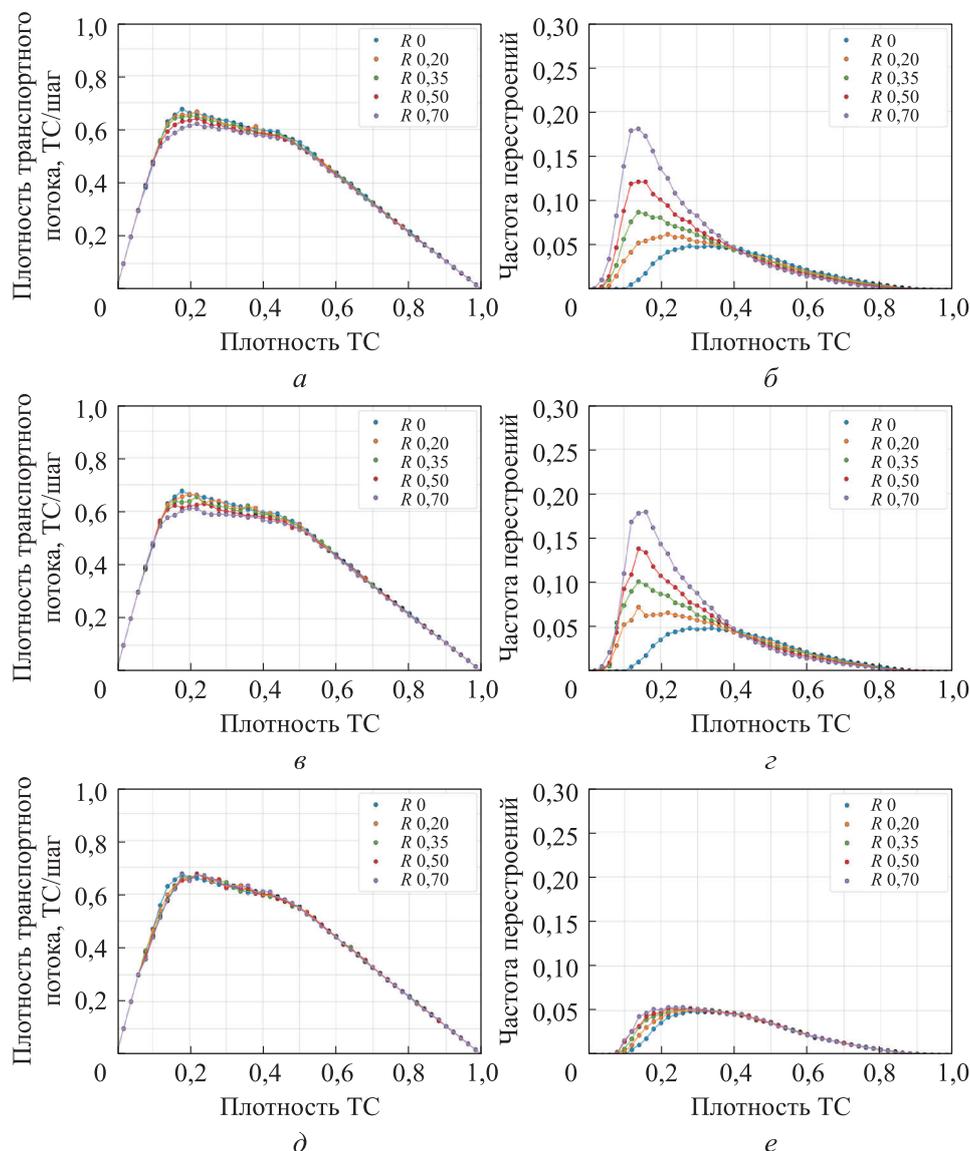


Рис. 6. Зависимости плотности (*a*, *в*, *д*) и частоты перестроений (*б*, *г*, *е*) транспортного потока, состоящего из 70 % ТС, управляемых человеком, и 30 % БАТС, от плотности ТС для первого (*a*, *б*), второго (*в*, *г*) и третьего (*д*, *е*) правил поведения девиантного агента;
 R — доля девиантных агентов в системе

Ответом на решение первой задачи может стать тот факт, что в процессе обучения нейронная сеть научилась правильно определять тип ТС с вероятностью более 99 %, что намного выше порога случайного угадывания в 33 % (поскольку число классов — три). Из этого можно сделать вывод, что даже простой математической модели транспортного потока достаточ-

но для моделирования таких сложных сценариев поведения ТС, как девиантное поведение или моделирование движения БАТС.

Что касается решения второй задачи, определено, что при увеличении длины последовательности (условно времени наблюдения за ТС) можно добиться почти 100%-ной правильной идентификации ТС в транспортном потоке.

Результаты обучения: на длине последовательности наблюдений 5 шагов достигнута точность 71,9 %, 7 шагов — 76,1 %, 10 шагов — 81,7 %, 13 шагов — 86,1 %, 18 шагов — 91,8 %, 23 шага — 95,6 %, 28 шагов — 97,7 %, 30 шагов — 98,4 %, 48 шагов — 99,9 %.

Прогресс обучения в части значений функции потерь во время тренировочных и валидационных фаз обучения и прогресс обучения в части увеличения показателей точности приведены на рис. 7. Перегибы на графиках обусловлены моментами изменения шага обучения.

Распределения числа шагов для корректной идентификации ТС (с какой длины наблюдаемой последовательности нейронная сеть правильно классифицирует наблюдаемое ТС) приведены на рис. 8. Данные получены на всей обучающей выборке с помощью нейронной сети, обученной на длине последовательности $L = 48$ шагов. Очевидно, что сети необходимо мало шагов, чтобы корректно идентифицировать девиантное ТС (DHVD). Однако для корректной классификации AV или HDV нейронной сети требуется большее число шагов.

Тот факт, что нейронная сеть научилась быстро идентифицировать девиантный ТС, имеет и обратную сторону. При ложных идентификациях (или когда наблюдение за ТС ведется недостаточно долго) нейронная сеть с большой долей вероятности неправильно определит ТС как девиантное. Абсолютное и относительное распределения неправильных ответов нейронной сети приведены на рис. 9. Если сеть на определенном шаге наблюдения показывает неправильный ответ, то она, скорее всего, определит наблюдаемое ТС как девиантное.

Число шагов, необходимых для корректной идентификации, можно представить как метрику сложности идентификации ТС: чем дольше сеть не может корректно определить тип ТС, тем сложнее случай. Распределение такой сложности в зависимости от локального (в области наблюдения M_{obs}) значения плотности транспортного потока (рис. 10):

$$q_{loc} = \frac{1}{MN} \sum_i^M \sum_j^N v_{ij}.$$

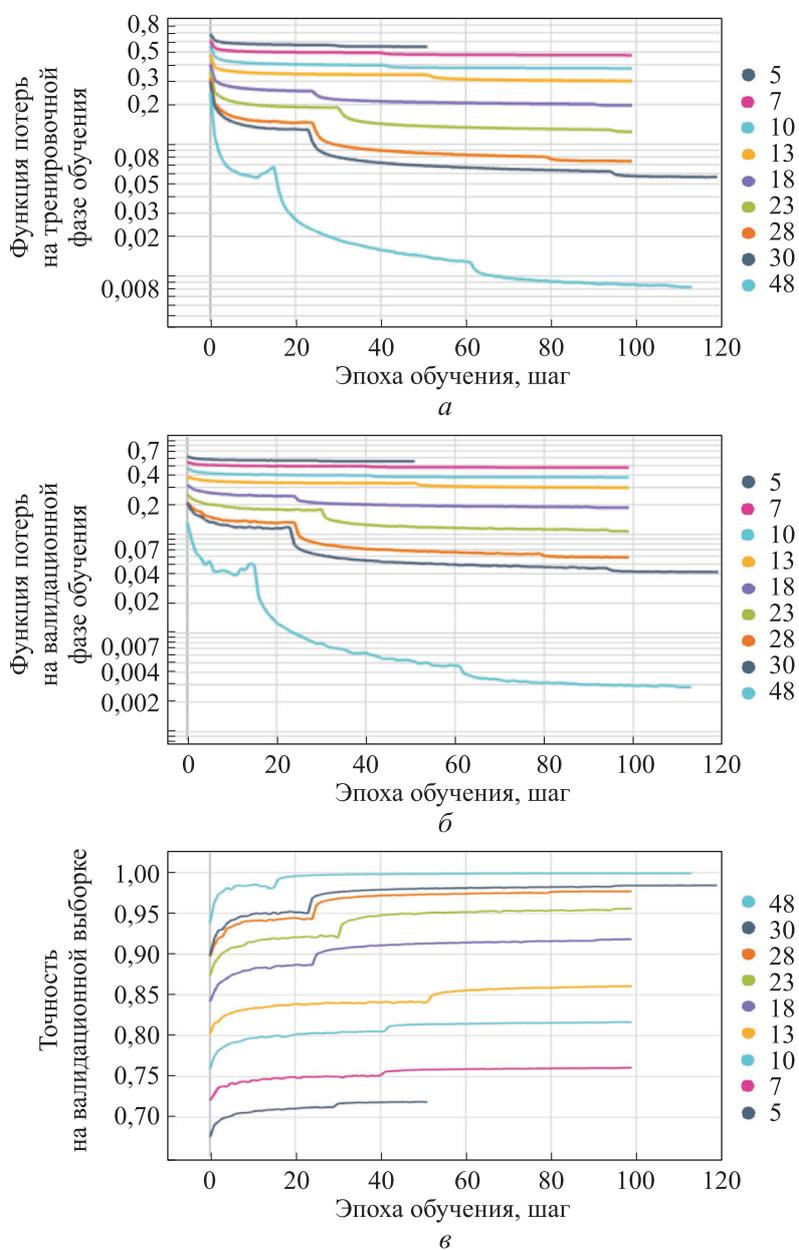


Рис. 7. Функции потерь во время тренировочной (*a*) и валидационной (*б*) фаз обучения, точность на валидационной выборке (*в*) для различной длины последовательностей (в шагах) для обучения

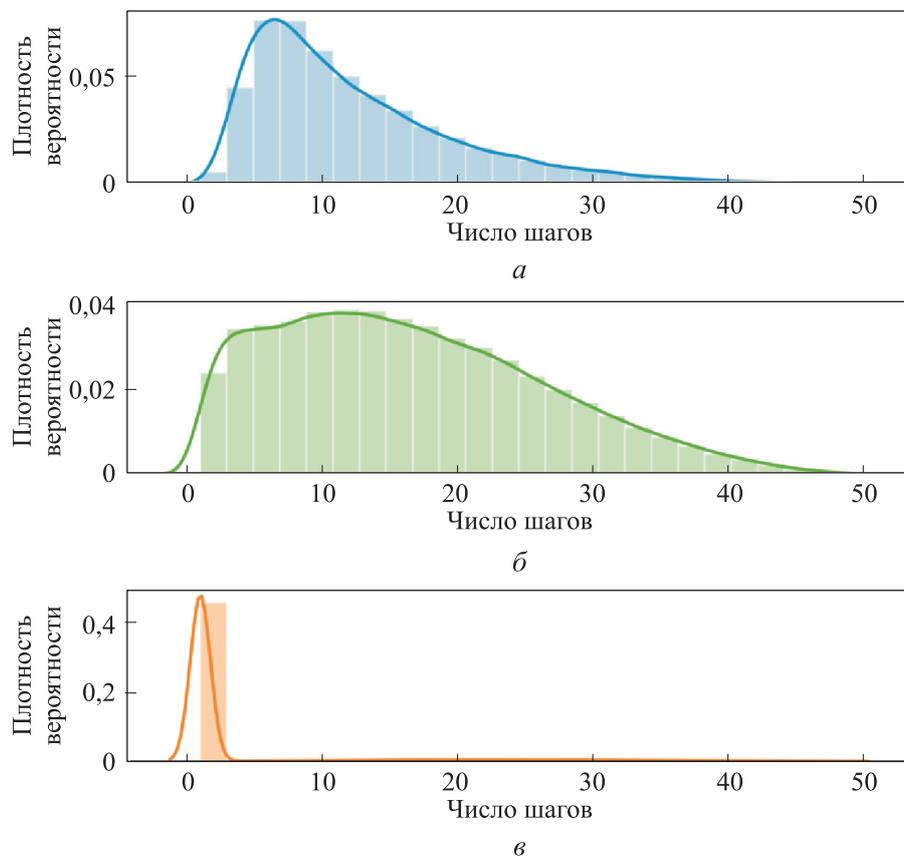


Рис. 8. Распределения числа шагов, необходимых для корректной идентификации ТС:

■ — AV, ■ — HDV, ■ — DHDV

При небольших значениях потока (когда скорость потока мала) нейросети сложнее идентифицировать ТС. Низкие значения потока могут быть также и в свободном потоке. В этом случае в области наблюдения за ТС может не быть других ТС или все они будут двигаться с максимальной скоростью, что затрудняет идентификацию ТС по их динамике.

Полученные результаты позволяют оценить примерное время наблюдения за ТС при движении в реальном транспортном потоке для его идентификации. Масштаб времени в математической модели КА соответствует 1 шаг = 1 с, а масштаб пространства — ширина клетки 7,5 м. Скорость ТС в мире КА, равная 5, соответствует реальной скорости 135 км/ч. В зависимости от средней скорости потока на разных участках дороги можно организовать подходящие системы наблюдения для отслеживания девиантных ТС.

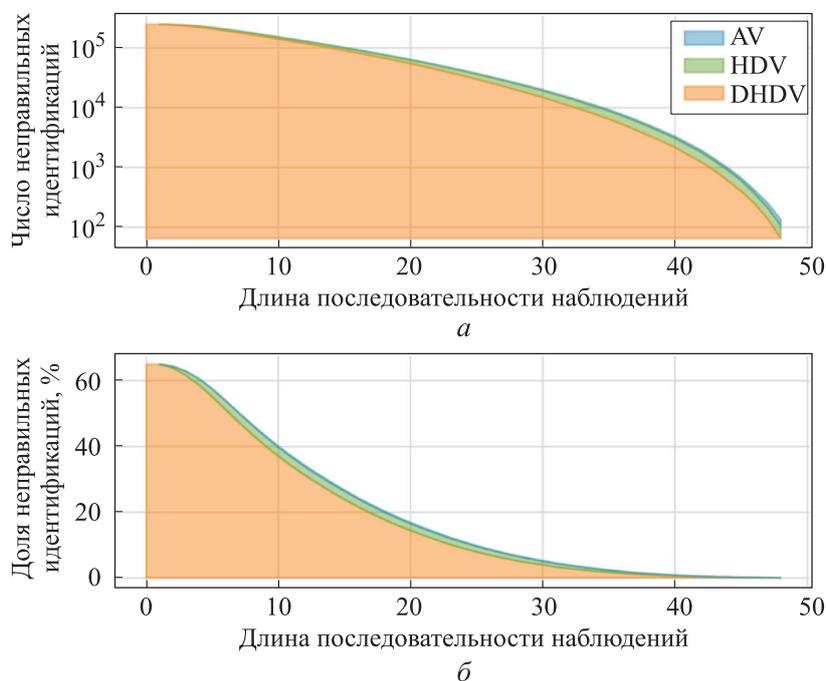


Рис. 9. Абсолютное (а) и относительное (б) распределения неправильных ответов нейронной сети

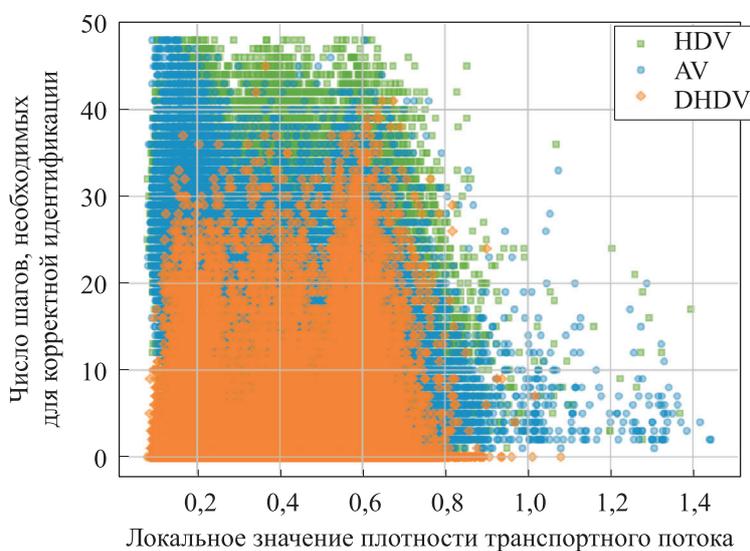


Рис. 10. Зависимость распределения числа шагов, необходимых для корректной идентификации, от локального значения плотности транспортного потока

Выводы. Показано, что в двухполосной круговой транспортной системе с возможностью перестроения между полосами присутствие девиантных ТС влияет на поток при средних значениях плотности ТС, т. е. в районе перехо-

да от свободного трафика к плотному. В указанной области присутствие девиантных ТС снижает максимальный поток системы. Из трех возможных правил поведения девиантных ТС наибольшее воздействие на поток системы оказывает правило смены полос, в то время как скрытое замедление оказывает гораздо меньшее влияние на поток системы.

Результаты исследования демонстрируют эффективность подхода на основе нейронных сетей, в частности с использованием архитектуры LSTM, для выявления аномалий в транспортном потоке. При использовании виртуальной среды, основанной на модифицированной модели S-NFS, в настоящей работе достигнуты две важные цели: точная классификация типов ТС — БАТС, автомобилей, управляемых человеком, и девиантных автомобилей, управляемых человеком, и необходимая продолжительность наблюдений для надежной классификации.

Определено, что сеть с архитектурой LSTM достигла впечатляющей точности классификации, превышающей 99 %, при длине последовательностей наблюдений 48 шагов, что значительно превышает случайный уровень угадывания, равный 33 %. Примечательно, что с увеличением длины последовательности точность значительно повышается: более короткие, длиной 5 шагов, достигали лишь 71,9 %, тогда как последовательности длиной 48 шагов практически достигли 99,9 %. Сеть продемонстрировала способность быстрее идентифицировать девиантные ТС с меньшим числом наблюдений по сравнению с беспилотными или управляемыми человеком автомобилями. Однако быстрое выявление сопровождалось заметным недостатком: сеть часто ошибочно классифицировала ТС как аномальные. Исследование не только выявило эту проблему, но и спрогнозировало ее возможные последствия в реальных условиях.

Эта технология подчеркивает практические преимущества использования нейронных сетей для мониторинга транспортного потока в реальном времени и выявления аномалий. Результаты демонстрируют значительный потенциал даже базовых конструкций нейронных сетей для решения сложных задач по выявлению аномалий и классификации ТС в рамках интеллектуальных транспортных систем. В будущем следует сосредоточить усилия на интеграции данных реальных наблюдений, уменьшении числа ложных срабатываний при выявлении девиантных ТС, а также изучении более продвинутых архитектур нейронных сетей для повышения производительности. В целом исследование закладывает прочную основу для внедрения машинного обучения в системы управления транспортом и выявления аномалий в режиме реального времени, что в итоге приведет к повышению безопасности и эффективности транспортных сетей.

ЛИТЕРАТУРА

- [1] Pan Y., Wu Y., Xu L., et al. The impacts of connected autonomous vehicles on mixed traffic flow: a comprehensive review. *Phys. A: Stat. Mech. Appl.*, 2024, vol. 635, art. 129454. DOI: <https://doi.org/10.1016/j.physa.2023.129454>
- [2] Guo X.-Y., Zhang G., Jia A.-F. Study on mixed traffic of autonomous vehicles and human-driven vehicles with different cyber interaction approaches. *Veh. Commun.*, 2023, vol. 39, art. 100550. DOI: <https://doi.org/10.1016/j.vehcom.2022.100550>
- [3] Abdeen M.A.R., Yasar A., Benaida M., et al. Evaluating the impacts of autonomous vehicles' market penetration on a complex urban freeway during autonomous vehicles' transition period. *Sustainability*, 2022, vol. 14, no. 16, art. 10094. DOI: <https://doi.org/10.3390/su141610094>
- [4] Muhammad T., Kashmiri F.A., Naeem H., et al. Simulation study of autonomous vehicles' effect on traffic flow characteristics including autonomous buses. *J. Adv. Transp.*, 2020, vol. 2020, no. 1, art. 4318652. DOI: <https://doi.org/10.1155/2020/4318652>
- [5] Baek S.K., Minnhagen P., Bernhardsson S., et al. Flow improvement caused by agents who ignore traffic rules. *arXiv preprint arXiv:0901.3513*. DOI: <https://doi.org/10.48550/arXiv.0901.3513>
- [6] Devyatkov V.V., Alfmtsev A.N. Selective covariance-based human localization, classification and tracking in video streams from multiple cameras. *BIOSTEC 2018– BIOINFORMATICS*, 2018, vol. 3, pp. 81–88. DOI: <http://dx.doi.org/10.5220/0006538100810088>
- [7] Chowdhury M.F., Biplob M.R.A., Uddin J. Real time traffic density measurement using computer vision and dynamic traffic control. *ICIEV and icIVPR*, 2018, pp. 353–356. DOI: <https://doi.org/10.1109/ICIEV.2018.8641039>
- [8] Buch N., Velastin S.A., Orwell J. A review of computer vision techniques for the analysis of urban traffic. *IEEE Trans. Intell. Transp. Syst.*, 2011, vol. 12, no. 3, pp. 920–939. DOI: <https://doi.org/10.1109/TITS.2011.2119372>
- [9] Popov A.Y., Ibragimov S.V., Malyshev S.A. Multiple objects association system for the smart city. *ElConRus*, 2021, pp. 2211–2216. DOI: <https://doi.org/10.1109/ElConRus51938.2021.9396415>
- [10] Baulin F.B., Buryi E.V. Feature extraction techniques for LIDAR range profile based object recognition. *Comput. Opt.*, 2021, vol. 45, no. 6, pp. 934–941. DOI: <https://doi.org/10.18287/2412-6179-CO-891>
- [11] Fitasov E.S., Legovtsova E.V., Pal'guev D.A. Experimental estimation of the projection method of the Doppler filtering of radar signals when detecting air objects with low radial velocities. *Radiophys. Quantum El.*, 2021, vol. 64, no. 4, pp. 300–308. DOI: <https://doi.org/10.1007/s11141-021-10132-5>
- [12] Saprykin Y., Ryzantsev V., Smirnov A. Application of neural networks to the analysis of time series data in the recognition of driver fatigue. *ITNT*, 2021. DOI: <https://doi.org/10.1109/ITNT52450.2021.9649427>

- [13] Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Comput.*, 1997, vol. 9, no. 8, pp. 1735–1780. DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>
- [14] Suyatinov S.I., Buldakova T.I., Vishnevskaya J.A. Identification of situations based on synergetic model. *SUMMA*, 2021, pp. 509–514. DOI: <https://doi.org/10.1109/SUMMA53307.2021.9632207>
- [15] Sakulin S., Alifimtsev A., Kvitchenko K., et al. Network anomalies detection approach based on weighted voting. *IJISP*, 2022, vol. 16, no. 1. DOI: <https://doi.org/10.4018/IJISP.2022010105>
- [16] Nagel K., Schreckenberg M. A cellular automaton model for freeway traffic. *J. Phys. I France*, 1992, vol. 2, no. 12, pp. 2221–2229. DOI: <https://doi.org/10.1051/jp1:1992277>
- [17] Kerner B.S., Klenov S.L. A microscopic model for phase transitions in traffic flow. *J. Phys. A: Math. Gen.*, 2002, vol. 35, no. 3, pp. L31–L43. DOI: <https://doi.org/10.1088/0305-4470/35/3/102>
- [18] Kokubo S., Tanimoto J., Hagishima A. A new cellular automata model including a decelerating damping effect to reproduce Kerner's three-phase theory. *Phys. A: Stat. Mech. Appl.*, 2011, vol. 390, no. 4, pp. 561–568. DOI: <https://doi.org/10.1016/j.physa.2010.10.027>
- [19] Tanimoto J., Futamata M., Tanaka M. Automated vehicle control systems need to solve social dilemmas to be disseminated. *Chaos Solitons Fractals*, 2020, vol. 138, art. 109861. DOI: <https://doi.org/10.1016/j.chaos.2020.109861>
- [20] Kukida S., Tanimoto J., Hagishima A. Analysis of the influence of lane changing on traffic-flow dynamics based on the cellular automaton model. *Int. J. Mod. Phys. C*, 2011, vol. 22, no. 3, pp. 271–281. DOI: <https://doi.org/10.1142/S012918311101621X>

Быков Никита Валерьевич — д-р техн. наук, заведующий кафедрой «Физика», начальник научно-исследовательского центра «Социофизика транспортных систем» РУТ (МИИТ) (Российская Федерация, 127994, Москва, ул. Образцова, д. 9, стр. 9); профессор кафедры «Ракетные и импульсные системы» МГТУ им. Н.Э. Баумана (Российская Федерация, 105005, Москва, 2-я Бауманская ул., д. 5, стр. 1).

Костров Максим Алексеевич — аспирант кафедры «Ракетные и импульсные системы» МГТУ им. Н.Э. Баумана (Российская Федерация, 105005, Москва, 2-я Бауманская ул., д. 5, стр. 1).

Товарнов Михаил Степанович — старший преподаватель кафедры «Ракетные и импульсные системы» начальник лаборатории инжинирингового центра им. М.П. Аржакова МГТУ им. Н.Э. Баумана (Российской Федерации, 105005, Москва, 2-я Бауманская ул., д. 5, стр. 1).

Просьба ссылаться на эту статью следующим образом:

Быков Н.В., Костров М.А., Товарнов М.С. Имитационное моделирование девиантного поведения в автомобильном транспортном потоке. *Вестник МГТУ им. Н.Э. Баумана. Сер. Приборостроение*, 2025, № 3 (152), с. 64–87.

EDN: RUPHAG

DEVIANT BEHAVIOR SIMULATION IN THE VEHICLES TRAFFIC FLOW

N.V. Bykov^{1,2}

M.A. Kostrov²

M.S. Tovarnov²

bykov@bmstu.ru

maks.kostrov@yandex.ru

tovarnov@bmstu.ru

¹ RUT, Moscow, Russian Federation

² BMSTU, Moscow, Russian Federation

Abstract

The paper proposes a simulation computer model of heterogeneous traffic flow based on the cellular automata approach. The model includes three types of the road user agents: human-controlled vehicles, unmanned vehicles, and the deviant vehicles. The traffic dynamics are based on the behavior rules formulated in the improved S-NFS model. Three rules of a deviant agent behavior are proposed and analyzed. Two of them are related to the lane changes and one to the intentional speed reduction. The paper shows that the deviant transport vehicles are primarily influencing the traffic flow at the medium vehicle densities. It considers the problem of detecting deviant behavior in the traffic flows using the neural networks. The study applies a learning sample created using the developed simulation model. Sample observation included data on the tracked vehicle velocity, relative positions and velocities of the adjacent vehicles, as well as information on the lane alterations. These data are organized in the form of matrices making it possible to be efficiently implement them in the neural network architecture. The results obtained demonstrate that neural networks, even with a relatively simple architecture, are classifying efficiently the vehicles in a flow, and are able to identify the deviant behavior, which emphasizes their potential in introducing in the intelligent transport systems

Keywords

Traffic flows, cellular automata, deviant agents, multi-agent systems, neural networks

Received 16.01.2025

Accepted 25.02.2025

© Author(s), 2025

The work was financially supported by the Russian Science Foundation (grant no. 24-21-00306)

REFERENCES

[1] Pan Y., Wu Y., Xu L., et al. The impacts of connected autonomous vehicles on mixed traffic flow: a comprehensive review. *Phys. A: Stat. Mech. Appl.*, 2024, vol. 635, art. 129454. DOI: <https://doi.org/10.1016/j.physa.2023.129454>

- [2] Guo X.-Y., Zhang G., Jia A.-F. Study on mixed traffic of autonomous vehicles and human-driven vehicles with different cyber interaction approaches. *Veh. Commun.*, 2023, vol. 39, art. 100550. DOI: <https://doi.org/10.1016/j.vehcom.2022.100550>
- [3] Abdeen M.A.R., Yasar A., Benaida M., et al. Evaluating the impacts of autonomous vehicles' market penetration on a complex urban freeway during autonomous vehicles' transition period. *Sustainability*, 2022, vol. 14, no. 16, art. 10094. DOI: <https://doi.org/10.3390/su141610094>
- [4] Muhammad T., Kashmiri F.A., Naeem H., et al. Simulation study of autonomous vehicles' effect on traffic flow characteristics including autonomous buses. *J. Adv. Transp.*, 2020, vol. 2020, no. 1, art. 4318652. DOI: <https://doi.org/10.1155/2020/4318652>
- [5] Baek S.K., Minnhagen P., Bernhardsson S., et al. Flow improvement caused by agents who ignore traffic rules. *arXiv preprint arXiv:0901.3513*. DOI: <https://doi.org/10.48550/arXiv.0901.3513>
- [6] Devyatkov V.V., Alfimtsev A.N. Selective covariance-based human localization, classification and tracking in video streams from multiple cameras. *BIOSTEC 2018–BIOINFORMATICS*, 2018, vol. 3, pp. 81–88. DOI: <http://dx.doi.org/10.5220/0006538100810088>
- [7] Chowdhury M.F., Biplob M.R.A., Uddin J. Real time traffic density measurement using computer vision and dynamic traffic control. *ICIEV and icIVPR*, 2018, pp. 353–356. DOI: <https://doi.org/10.1109/ICIEV.2018.8641039>
- [8] Buch N., Velastin S.A., Orwell J. A review of computer vision techniques for the analysis of urban traffic. *IEEE Trans. Intell. Transp. Syst.*, 2011, vol. 12, no. 3, pp. 920–939. DOI: <https://doi.org/10.1109/TITS.2011.2119372>
- [9] Popov A.Y., Ibragimov S.V., Malyshev S.A. Multiple objects association system for the smart city. *ElConRus*, 2021, pp. 2211–2216. DOI: <https://doi.org/10.1109/ElConRus51938.2021.9396415>
- [10] Baulin F.B., Buryi E.V. Feature extraction techniques for LIDAR range profile based object recognition. *Comput. Opt.*, 2021, vol. 45, no. 6, pp. 934–941. DOI: <https://doi.org/10.18287/2412-6179-CO-891>
- [11] Fitasov E.S., Legovtsova E.V., Pal'guev D.A. Experimental estimation of the projection method of the Doppler filtering of radar signals when detecting air objects with low radial velocities. *Radiophys. Quantum El.*, 2021, vol. 64, no. 4, pp. 300–308. DOI: <https://doi.org/10.1007/s11141-021-10132-5>
- [12] Saprykin Y., Ryazntsev V., Smirnov A. Application of neural networks to the analysis of time series data in the recognition of driver fatigue. *ITNT*, 2021. DOI: <https://doi.org/10.1109/ITNT52450.2021.9649427>
- [13] Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Comput.*, 1997, vol. 9, no. 8, pp. 1735–1780. DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>
- [14] Suyatinov S.I., Buldakova T.I., Vishnevskaya J.A. Identification of situations based on synergetic model. *SUMMA*, 2021, pp. 509–514. DOI: <https://doi.org/10.1109/SUMMA53307.2021.9632207>

- [15] Sakulin S., Alfimov A., Kvitchenko K., et al. Network anomalies detection approach based on weighted voting. *IJISP*, 2022, vol. 16, no. 1.
DOI: <https://doi.org/10.4018/IJISP.2022010105>
- [16] Nagel K., Schreckenberg M. A cellular automaton model for freeway traffic. *J. Phys. I France*, 1992, vol. 2, no. 12, pp. 2221–2229. DOI: <https://doi.org/10.1051/jp1:1992277>
- [17] Kerner B.S., Klenov S.L. A microscopic model for phase transitions in traffic flow. *J. Phys. A: Math. Gen.*, 2002, vol. 35, no. 3, pp. L31–L43.
DOI: <https://doi.org/10.1088/0305-4470/35/3/102>
- [18] Kokubo S., Tanimoto J., Hagishima A. A new cellular automata model including a decelerating damping effect to reproduce Kerner’s three-phase theory. *Phys. A: Stat. Mech. Appl.*, 2011, vol. 390, no. 4, pp. 561–568.
DOI: <https://doi.org/10.1016/j.physa.2010.10.027>
- [19] Tanimoto J., Futamata M., Tanaka M. Automated vehicle control systems need to solve social dilemmas to be disseminated. *Chaos Solitons Fractals*, 2020, vol. 138, art. 109861. DOI: <https://doi.org/10.1016/j.chaos.2020.109861>
- [20] Kukida S., Tanimoto J., Hagishima A. Analysis of the influence of lane changing on traffic-flow dynamics based on the cellular automaton model. *Int. J. Mod. Phys. C*, 2011, vol. 22, no. 3, pp. 271–281. DOI: <https://doi.org/10.1142/S012918311101621X>

Bykov N.V. — Dr. Sc. (Eng.), Head of the Department of Physics, Head of the Research Center “Sociophysics of Transport Systems”, RUT (Obraztsova ul. 9, str. 9, Moscow, 127994 Russian Federation); Professor, Department of Rocket and Impulse Systems, BMSTU (2-ya Baumanskaya ul. 5, str. 1, Moscow, 105005 Russian Federation).

Kostrov M.A. — Post-Graduate Student, Department of Rocket and Impulse Systems, BMSTU (2-ya Baumanskaya ul. 5, str. 1, Moscow, 105005 Russian Federation).

Tovarnov M.S. — Senior Lecturer, Department of Rocket and Impulse Systems, Head of Laboratory of the Engineering Center named after M.P. Arzhakov, BMSTU (2-ya Baumanskaya ul. 5, str. 1, Moscow, 105005 Russian Federation).

Please cite this article in English as:

Bykov N.V., Kostrov M.A., Tovarnov M.S. Deviant behavior simulation in the vehicles traffic flow. *Herald of the Bauman Moscow State Technical University, Series Instrument Engineering*, 2025, no. 3 (152), pp. 64–87 (in Russ.). EDN: RUPHAG