

УДК 519.876.5
<https://doi.org/10.31854/3034-2201-2026-4-1-C07>
EDN: CNWIIW

Адаптивное распределение вычислительных задач в интеллектуальных транспортных системах с применением мобильных RSU и машинного обучения

Тамбовцев Г. И.

Санкт-Петербургский государственный университет телекоммуникаций им. проф. М. А. Бонч-Бруевича,
Санкт-Петербург, 193232, Российская Федерация

Постановка задачи. Рост объема данных в сетях *Vehicle-to-Everything* и жесткие требования к задержкам в интеллектуальных транспортных системах делают использование исключительно облачных или стационарных периферийных вычислений недостаточным. Стационарные придорожные устройства (RSU) имеют фиксированную зону покрытия и ограничены в ресурсах при пиковых нагрузках. **Целью работы** является разработка подхода к адаптивному распределению вычислительных задач в динамической среде *Vehicle-to-Everything* с использованием мобильных узлов инфраструктуры (*mRSU*). Предлагается алгоритм многошаговой передачи и нейросетевая модель принятия решений, позволяющая выбирать оптимальный узел обработки на основе локально доступных бортовому устройству параметров. **Используемые методы.** Исследование базируется на методах имитационного моделирования (программа «*simV2X*»), теории массового обслуживания для оценки задержек и методах машинного обучения (многослойный перцептрон) для классификации режимов разгрузки. Элементами **новизны** являются включение мобильных узлов инфраструктуры в общую иерархию вычислений и разработка нейросетевой стратегии выбора узла, которая опирается только на локальные признаки бортового устройства, не требуя полной информации о состоянии глобальной сети. **Результат.** Применение *mRSU* позволило снизить среднюю задержку обработки почти в два раза и существенно уменьшить вероятность пропуска дедлайна задач. Обученная нейронная сеть продемонстрировала точность, сопоставимую с эталонным алгоритмом минимизации задержки: доля просроченных задач при использовании модели нейронной сети увеличилась всего на 0,5 % при снижении требований к объему передаваемой служебной информации. **Теоретическая / Практическая значимость.** Предложенный подход позволяет создавать масштабируемые и отказоустойчивые интеллектуальные транспортные системы, способные эффективно функционировать в условиях высокой плотности трафика и динамично изменяющейся топологии сети без необходимости постоянного обращения к облаку.

Ключевые слова: сеть связи, VANET, *Vehicle-to-Everything*, моделирование, интеллектуальная транспортная система, распределенные вычисления

Введение

Развитие интеллектуальных транспортных систем (ИТС) сопровождается ростом требований [1, 2] к скорости и надежности обмена данными между транспортными средствами, дорожной инфраструктурой и облачными сервисами. Для предотвращения ДТП и аварийных ситуаций в V2X сетях (аббр. от англ.

Библиографическая ссылка на статью:

Тамбовцев Г. И. Адаптивное распределение вычислительных задач в интеллектуальных транспортных системах с применением мобильных RSU и машинного обучения // Вестник СПбГУТ. 2026. Т. 4. № 1. С. 7. EDN: CNWIIW

Reference for citation:

Tambovtsev G. Adaptive Task Offloading in Intelligent Transportation Systems Using Mobile RSUs and Machine Learning // Herald of SPbSUT. 2026. Vol. 4. Iss. 1. P. 7. EDN: CNWIIW

Vehicle-to-Everything – взаимодействие транспортного средства с окружающей средой) используются [3] механизмы предиктивного управления движением, передача и анализ информации с датчиков автомобилей и придорожной инфраструктуры, что требует обработки больших объемов данных в условиях временных ограничений. Архитектуры, основанные на обработке данных в облаке, не способны обеспечить решение вычислительных задач до истечения срока их актуальности. Использование периферийных вычислений (граничных или туманных) позволяет снизить временные задержки [4], однако эффективность стационарных узлов периферийных вычислений – придорожных устройств (RSU, аббр. от англ. Roadside Unit) ограничена их фиксированным размещением и невозможностью оперативно перекрывать зоны с высокой нагрузкой [5]. В этой связи возрастающий интерес вызывает использование мобильных узлов периферийных вычислений (mRSU, аббр. от англ. mobile RSU) [5, 6]. Специальные транспортные средства, которые могут динамически перемещаться вдоль дорог, обеспечивать подключение в востребованных зонах mRSU, способны выполнять локальные вычисления и брать на себя часть нагрузки от бортовых устройств (OBU, аббр. от англ. On Board Unit), предназначенных для стационарных RSU или облака. При этом интеграция mRSU в существующие модели разгрузки требует новых алгоритмов принятия решений, учитывающих динамически изменяющиеся параметры радиоканала, направление движения, срок актуальности задач и возможность использования многошаговой передачи [7–9].

Высокодинамичные условия транспортной среды создают дополнительную сложность из-за частого изменения расстояний и быстрого ухудшения качества канала связи. В этих условиях необходимы адаптивные модели и алгоритмы распределения вычислительных задач, способные принимать решения в реальном времени и учитывать особенности мобильной периферийной инфраструктуры. Таким образом, разработка и исследование моделей адаптивных периферийных вычислений с поддержкой mRSU является актуальной задачей, имеющей большое значение для построения высокоэффективных, надежных и масштабируемых ИТС.

Описание задачи

Для описания адаптивного распределения вычислительных задач в интеллектуальных транспортных системах введем следующие обозначения (таблица 1).

Таблица 1. Принятые обозначения

Обозначение	Содержание
$V = \{v_i\}$	множество OBU
$R = \{r_j\}$	множество RSU
$M = \{m_k\}$	множество мобильных mRSU
C	облачный центр обработки
$T = \{t_n\}$	множество вычислительных задач
$d(t_n)$	актуальное время задачи t_n / время на выполнение
$w(t_n)$	объем вычислений задачи (в арифметических операциях)
$src(t_n)$	исходный узел, с которого начинается задача t_n
$s(x)$	вычислительная производительность узла x
$q(x)$	текущая очередь задач на узле x
$L(x, y)$	задержка передачи данных между узлами x, y
$\gamma(x, y)$	отношение сигнал / шум (SNR, аббр от англ. Singal-to-Noise Ratio) между узлами
$\eta(x, y)$	факт успешного приема-передачи пакета данных между узлами (1 – передано / получено, 0 – нет)
π	стратегия выбора места выполнения задачи
$\tau(t_n, x)$	итоговая задержка выполнения задачи t_n на узле x
$\delta(t_n)$	индикатор нарушения актуальности задачи: $\delta = 1$, если $\tau > d(t_n)$
H	множество маршрутов многошаговой передачи

Пусть в системе присутствуют узлы:

$$X = V \cup R \cup M \cup C$$

и множество вычислительных задач:

$$T = \{t_1, t_2, \dots, t_N\}.$$

Каждая задача t_n характеризуется как:

$$t_n = (w(t_n), d(t_n), src(t_n)).$$

Задержка выполнения задачи на узле x задается выражением:

$$\tau(t_n, x) = L(src(t_n), x) + \frac{w(t_n) + q(x)}{s(x)}.$$

Целью адаптивного распределения является выбор стратегии π , которая для каждой задачи t_n выбирает узел $x \in X$ (локальный – OBU; ближайший RSU или ближайший mRSU; облако). Критерием оптимальности выступает минимизация средней задержки $\tau(t_n, x)$, при соблюдении ограничения на актуальность данных: $\delta(t_n) = 0$. Дополнительно учитывается и многокритериальная функции балансировки нагрузки [10].

Методология адаптивного распределения задач

Для разработки алгоритмов распределения задач используется подход, базирующийся на совместном моделировании радиоканала, вычислительных ресурсов и алгоритмов выбора стратегии разгрузки. Процесс моделирования в программном комплексе «simV2X» [11] строится на итерационном пересчете состояния системы, где на каждом шаге обновляются позиции узлов, параметры SNR согласно спецификациям 3GPP TR 37.885¹ и состояние вычислительных очередей. Данная модель опирается на допущение о наличии «идеальных глобальных знаний». Предполагается, что системе в каждый момент времени известны точные значения очередей $q(x)$ на всех узлах, характеристики каналов и векторы движения всех участников. Эталонная модель всегда выбирает узел x , обеспечивающий математический минимум задержки $\tau(t_n, x)$, при условии, что выполнение задачи укладывается в заданный временной лимит $d(t_n)$. Для каждого запроса OBU строится маршрут выполнения задачи. В случае выполнения многошаговой передачи, если связь с RSU отсутствует или недоступна, OBU выбирает ближайший mRSU, совпадающий по направлению движения, при наличии устойчивого канала связи. Строится цепочка mRSU – mRSU / OBU – OBU.

Если узел перегружен, выполняется альтернативный выбор пути. Это означает, что каждый пакет может быть доставлен по следующей цепочке:

$$h_0 = OBU, h_1, h_2, \dots, h_{(K-1)}, h_K = X,$$

где конечный узел X – RSU с сохраненным ответом либо облако; промежуточные узлы h_K – mRSU или OBU и RSU, если X – облако.

¹ 3GPP TR 37.885. Study on Evaluation Methodology of New Vehicle-to-Everything (V2X) Use Cases for LTE and NR. 3GPP Technical Report, Release 15. URL: <https://portal.3gpp.org/ChangeRequests.aspx?q=1&specnumber=37.885> (Accessed 16.11.2025).

При этом маршрут оптимален, если:

– все радиоканалы на пути удовлетворяют условию успешного приема:

$$\gamma(h_i, h_i + 1) \geq \gamma_{\min}, \eta(h_i, h_i + 1) = 1;$$

– суммарная задержка минимальна:

$$L(src, X) = \sum_{i=0}^{K-1} (h_i, h_{(i+1)}) \rightarrow \min;$$

– маршрут укладывается во временные рамки задачи:

$$L(src, X) + \tau_{\text{exec}}(t, X) \leq d(t_n).$$

Каждое mRSU рассматривается как узел, который движется вместе с трафиком. mRSU всегда ближе к OBU, чем RSU. mRSU обладает ограниченной, но большей, чем бортовое устройство, вычислительной мощностью, а также выступает в роли мобильного ретранслятора и частично вычислительного узла. OBU подключается к mRSU, если выполняются следующие условия:

- OBU движется в сторону mRSU, или задача OBU не требует сложных вычислений;
- нагрузка на mRSU не превышает допустимую;
- SNR превышает минимальный уровень.

Таким образом, результат использования данного метода является теоретическим пределом эффективности системы. Практическая реализация такой модели в реальных условиях ИТС практически невозможна, поскольку она создает высокую сигнальную нагрузку: обмен данными о состоянии всех узлов в реальном времени приведет к деградации пропускной способности радиоканала. Вдобавок информация о состоянии удаленного узла (например, облака или соседнего mRSU) неизбежно устареет за время ее доставки.

В связи с этим предлагается использовать методы машинного обучения для уменьшения объема знаний эталонной модели. Нейронная сеть обучается имитировать ее решения, но опирается исключительно на локальные признаки, доступные OBU. Такой подход позволит достичь качества управления, близкого к эталонному, при полном отсутствии избыточного обмена служебными сообщениями в сети.

Описание эксперимента

Для проверки работоспособности методики адаптивного распределения вычислительных задач в ИТС была выполнена серия имитационных экспериментов в программном комплексе «simV2X». Основной сценарий имитационного моделирования использует прямолинейный участок дороги протяженностью 3 км. Данная конфигурация позволяет минимизировать влияние сложной геометрии перекрестков и сфокусироваться на анализе алгоритмов разгрузки и многошаговой передачи. В эксперименте используются три mRSU, следующие за транспортным потоком, включающего 250 транспортных средств с OBU. mRSU и транспортные средства движутся со скоростью от 15 до 25 м/с и равномерно распределены в случайных точках на каждом километре участка дороги, тогда как RSU размещены с интервалом в 1000 метров. Предполагается, что в стационарном положении, mRSU эквивалентен RSU.

Сетевое моделирование происходит с опорой на протокол 802.11bd². На каждом шаге моделирования осуществляется пересчет SNR, что позволяет учитывать изменения расстояний и условия прямой и не прямой видимости. Модель поддерживает построение цепочек передачи данных, выполняя многошаговую передачу. Это дает возможность использовать кластеризацию даже в отсутствие прямой видимости обрабатывающего узла.

² IEEE 802.11bd // IEEE. URL: <https://standards.ieee.org/ieee/802.11bd/7451/> (Accessed 19.11.2025).

Каждое OBU генерирует вычислительные задачи, размер которых определен от 0,5 до 2,5 Мбит. Для имитации нагрузки на центральный процессор OBU, RSU, mRSU или облачной инфраструктуры задача устанавливает случайный объем арифметических операций от 5 до 30, на 10^6 инструкций. Актуальность задачи устанавливает ограничения на выполнения и лежит в диапазоне от 0,5 до 2 с.

Процесс моделирования и сбора данных разделен на несколько этапов. Сначала производился непрерывный расчет состояния радиофизической среды. Для каждого OBU на каждом временном шаге определялось актуальное множество доступных соседей и выстраивались графы возможных маршрутов передачи. Все параметры радиоканалов и топологические метрики фиксировались в базе данных с временными метками.

Для каждой задачи алгоритм эталонной стратегии принимал решение о выборе узла, учитывая состояние очередей и возможность многошаговой доставки. После завершения цикла «запрос – ответ» вычислялась итоговая задержка и фиксировался статус соблюдения сроков выполнения задачи. Результаты работы эталонной модели были использованы для последующего машинного обучения.

Для подтверждения работоспособности предложенного подхода и оценки вклада mRSU в ходе экспериментов фиксируются два ключевых показателя, напрямую следующие из поставленной задачи:

- средняя задержка решения задачи, отражающая общую вычислительную и сетевую эффективность системы (снижение этого показателя свидетельствует, что алгоритм успешно находит кратчайшие маршруты и менее загруженные узлы);
- вероятность пропуска задачи.

Дополнительно проверяется гипотеза о том, что включение mRSU в иерархию вычислений позволяет нивелировать недостатки стационарной инфраструктуры. Сравнение проводится по двум сценариям:

- базовый сценарий: OBU самостоятельно решает свои задачи или распределяет их между RSU и облаком, что позволит выявить недостаточность покрытия и перегрузки RSU;
- сценарий с mRSU: в систему вводятся mRSU, реализующие эталонную стратегию в предположении значительного снижения задержек и нивелирования недостатков базового сценария.

Машинное обучение в V2X-среде

В задачах распределения вычислений в V2X-среде широко применяются методы машинного обучения, в том числе обучение с подкреплением и глубокое обучение с подкреплением [12, 13], поскольку решение о разгрузке должно приниматься в условиях высокой мобильности узлов, изменяющегося состояния радиоканала и ограниченности вычислительных ресурсов. Однако в настоящей работе выбор места обработки сводится к задаче классификации, что позволяет применять обучение с учителем. Модель обучается воспроизводить решение эталонной стратегии, но только по набору локально доступных признаков. Такой подход обеспечивает малую вычислительную сложность на этапе вывода и лучше подходит для исполнения непосредственно на OBU в реальном времени.

Целью построения модели является формирование компактного и быстро действующего модуля принятия решений, который работает только с локально доступной для OBU информацией, но при этом максимально приближает поведение к оптимальной стратегии выбора узла обработки. Для этого была сформирована большая обучающая выборка на основе имитационного моделирования ИТС. Референсной стратегией служил алгоритм минимизации задержки выполнения задачи с учетом RSU и mRSU. В каждом наборе данных были выбраны входные признаки и целевая метка, определяющая узел обработки задачи: OBU, ближайшие RSU / mRSU или облако.

Несмотря на то, что при моделировании учитывается широкий спектр параметров, полный список которых включает более 30 разных признаков, на практике OBU не может обладать большинством этих данных. Более того, передавать все эти параметры по сети для каждого OBU было бы неэффективно, поэтому для обучения нейросети был выбран минимальный информативный набор локально доступных признаков. Отбор признаков осуществлялся на основе двух критериев: экспертного выбора локально доступных параметров на OBU и оценки влияния отдельных признаков на точность классификации при их исключении из модели. Следует отметить, что отдельные признаки с невысокой индивидуальной важностью сохранились в итоговом наборе, поскольку их комбинация с другими параметрами повышали устойчивость модели. По результатам применения вышеописанных критериев в итоговый набор вошли: размер задачи (в битах); актуальность задачи (в секундах); оценочные временные задержки на

обработку задачи локально; SNR до ближайших узлов; расстояние до ближайших узлов; тактовая частота процессора на OBU; оценочные временные задержки при выборе разгрузки задачи на ближайший узел или облако. Из рассмотрения были исключены признаки, требующие глобального знания состояния сети, фактические задержки выполнения задач, параметры очередей и вычислительных ресурсов удаленных узлов, а также координаты инфраструктурных элементов.

Таким образом, обученная модель может быть выполнена непосредственно на OBU в реальном времени, и использованные для обучения признаки не требовали построения глобального графа сети или получения актуальных данных от внешней инфраструктуры. Ниже показана точность корректного предсказания узла распределения задач при обучении и валидации модели (рисунок 1) и матрица ошибок (рисунок 2).

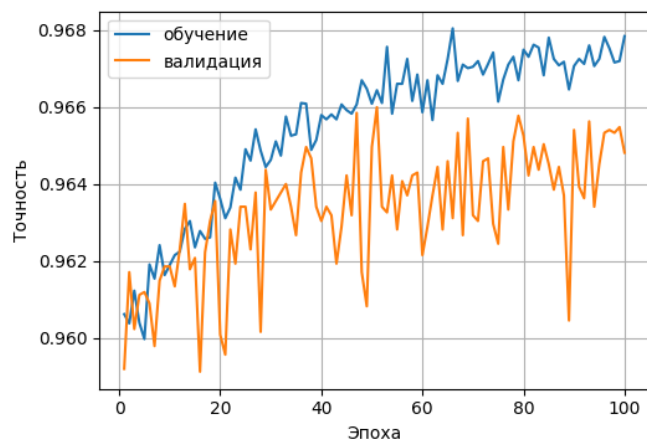


Рис. 1. График динамики обучения

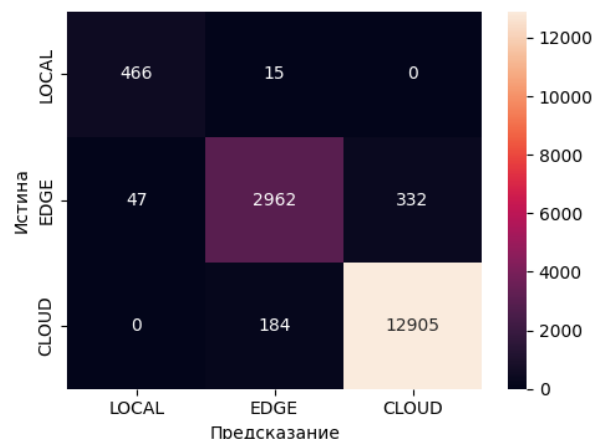


Рис. 2. Матрица ошибок

Полученная модель демонстрирует устойчивую высокую точность классификации и корректно разделяет режимы выполнения задач. Для оценки ее эффективности в условиях динамически изменяющейся топологии модель была интегрирована в программу «simV2X» для сравнения с другими стратегиями распределения задач.

Результаты

Анализ эффективности разработанной методики проводился путем сопоставления эталонной стратегии (MDD) с базовыми стратегиями (LOCAL, EDGE, CLOUD) и нейросетевой стратегией (NN). На первом этапе оценивалось влияние mRSU на общую производительность системы при использовании эталонного алгоритма (рисунок 3).




Рис. 3. Средняя задержка решения (а) и вероятность пропуска задачи (б) в рассматриваемых сценариях

Результаты имитационного моделирования наглядно демонстрируют преимущество интеграции мобильной периферии. Применение mRSU снижает среднюю задержку почти в два раза по сравнению с конфигурацией, использующей только RSU. Это достигается за счет более высокой пропускной способности канала, меньшей загруженности инфраструктурных узлов и перераспределения части нагрузки на мобильные вычислительные элементы. При этом введение mRSU приводит к снижению вероятности пропуска задач. Это объясняется тем, что mRSU сокращают среднюю дистанцию от транспортного средства до ближайшей точки с периферийными вычислениями и улучшают условия радиосвязи. В итоге повышается вероятность успешной доставки данных и выполнения задачи до истечения допустимого времени. Сравнение референсных стратегий распределения представлено на рисунке 4.

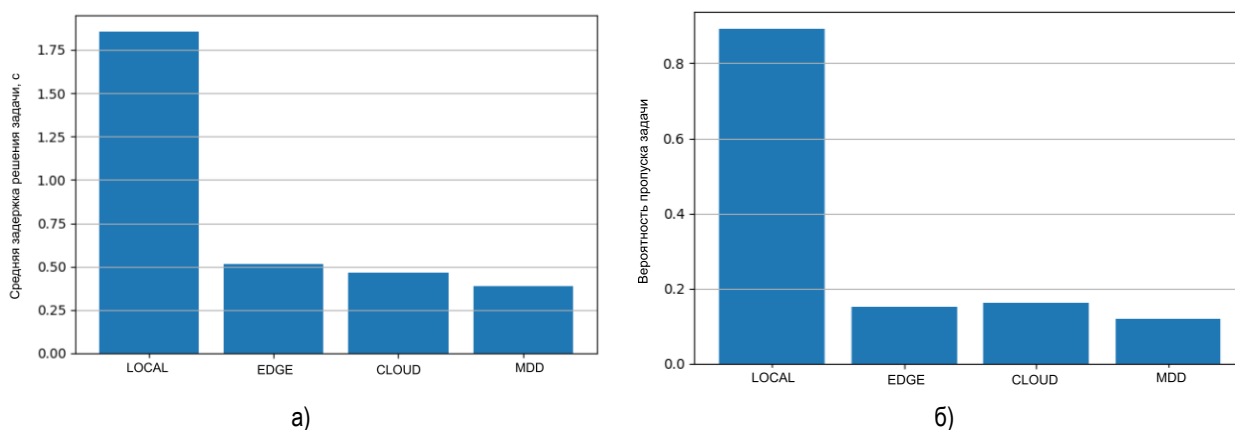


Рис. 4. Средняя задержка решения (а) и вероятность пропуска (б) задачи для рассматриваемых стратегий распределения задач только на OBU (LOCAL); на RSU и mRSU (EDGE); на облачную инфраструктуру (CLOUD); с применением эталонного алгоритма (MDD)

Из-за низких вычислительных возможностей автомобилей локальная обработка дает наибольшую задержку. Большинство задач превышает допустимую задержку, что приводит к массовой потере актуальности задач и их пропуску. Благодаря вычислениям на RSU и mRSU (EDGE) наблюдается значительное снижение задержки и пропуска задач, однако стоит учитывать, что RSU – стационарное устройство и в случае большого потока транспорта пропуск и потеря актуальности задачи могут увеличиться. Облако (CLOUD) быстрее, чем EDGE по вычислениям, однако уступает в количестве пропущенных задач из-за временных затрат на передачу данных. Эталонная стратегия распределения вычислительных задач (MDD) демонстрирует наилучшие показатели среди всех протестированных, поскольку в данном случае выбирается наиболее быстрый и эффективный путь к обработке, который не ограничивается только одной стратегией, а используется все три сразу.

После интеграции обученной модели были проведены дополнительные эксперименты со смешанной инфраструктурой, содержащей как RSU, так и mRSU. Итоговые значения средней задержки и доли просроченных задач приведены на рисунке 5.




Рис. 5. Средняя задержка выполнения (а) и доля просроченных задач (б) в сценариях с применением машинного обучения (NN) и эталонного алгоритма (MDD)

Несмотря на то, что классификатор опирается на ограниченный набор локальных признаков, графики зависимости средней задержки решения задач показывают высокую степень аппроксимации эталонного поведения. Модель успешно идентифицирует моменты, когда локальный ресурс близок к исчерпанию, и перенаправляет нагрузку на соседние mRSU, поддерживая вероятность пропуска задач на уровне, близком к оптимальному. Разница в средней задержке составляет всего порядка 6–7 %, а доля просроченных задач увеличивается лишь на ~0,5 %, что является ожидаемым следствием отсутствия у модели глобальной информации о состоянии сети. При этом нейросетевая стратегия (NN) обеспечивает своевременное выполнение более 98 % задач, что подтверждает ее способность корректно выбирать узел обработки в подавляющем большинстве ситуаций.

Заключение

В работе представлена модель адаптивного распределения вычислительных задач в интеллектуальных транспортных системах с использованием мобильных узлов. Выполненные имитационные эксперименты показывают, что включение mRSU в инфраструктуру значительно повышает эффективность системы: сокращаются дистанции передачи, улучшается качество радиосвязи, снижается загрузка стационарных RSU, а вычислительная нагрузка перераспределяется более равномерно. Это приводит к существенному уменьшению задержки выполнения задач и снижению вероятности нарушения их актуальности по сравнению со сценариями, использующими только RSU или облако.

На основе эталонной стратегии с минимальной задержкой была сформирована обучающая выборка и построена компактная нейросетевая модель принятия решений, работающая только с локально доступными на OBU признаками. Несмотря на отсутствие глобальной информации о сети, нейросетевая стратегия продемонстрировала качество работы, близкое к оптимальному алгоритму, обеспечив выполнение более 98 % задач в пределах допустимого времени. Интеграция модели в симулятор показала, что по средней задержке и доле просроченных задач ее поведение практически совпадает с эталонным.

Полученные результаты подтверждают перспективность использования мобильных периферийных узлов как элемента V2X-инфраструктуры и демонстрируют применимость методов машинного обучения для построения легких и быстрых стратегий распределения вычислений. Предложенная методика может стать основой для дальнейших исследований, направленных на развитие адаптивных стратегий управления ресурсами, улучшение моделей прогнозирования состояния радиоканала, интеграцию обучения с подкреплением и создание автономных систем распределенных V2X-вычислений.

В качестве направлений дальнейших исследований целесообразно расширить анализ предложенного подхода на сценарий с повышенной плотностью OBU, а также рассмотреть случаи с временной перегрузкой отдельных RSU/mRSU. Это позволит оценить устойчивость и масштабируемость предложенной методики в более непредсказуемых условиях.

Литература

1. Плотников П. В., Владыко А. Г. Анализ подходов к оптимизации V2X-систем: кластеризация, граничные и туманные вычисления // Труды учебных заведений связи. 2024. Т. 10. № 3. С. 7–22. DOI: 10.31854/1813-324X-2024-10-3-7-22. EDN: TRWNON
2. Meneghette R., De Grande R., Ueyama J., Rocha Filho G. P., Madeira E. Vehicular Edge Computing: Architecture, Resource Management, Security, and Challenges // ACM Computing Surveys (CSUR). 2021. Vol. 55. Iss. 1. DOI: 10.1145/3485129
3. Alnami H., Mohzary M. VehiCast: Real-Time Highway Traffic Incident Forecasting System Using Federated Learning and Vehicular Ad Hoc Network // Electronics. 2025. Vol. 14. Iss. 5. P. 900. DOI: 10.3390/electronics14050900. EDN: LUJYJD
4. Wang M., Yi H., Jiang F., Lin L., Gao M. Review on Offloading of Vehicle Edge Computing // Journal of Artificial Intelligence and Technology. 2022. Vol. 2. Iss. 4. PP. 132–143. DOI: 10.37965/jait.2022.0120. EDN: XFARLE
5. Guerna A., Bitam S., Calafate C. T. Roadside Unit Deployment in internet of Vehicles Systems: A Survey // Sensors. 2022. Vol. 22. Iss. 9. 3190. DOI: 10.3390/s22093190. EDN: DFKZIQ

6. Plotnikov P. V., Tambovtsev G. I., Vladyko A. G. Evaluating the Performance of Using Mobile Roadside Units for Task Offloading in V2X Systems // Proceedings of the 2024 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED, 13–15 November 2024, Moscow, Russian Federation). 2024. PP. 1–4. DOI: 10.1109/TIRVED63561.2024.10769815
7. Ahmed M., Raza S., Mirza M. A., Aziz A., Khan M. A., et al. A Survey on Vehicular Task Offloading: Classification, Issues, and Challenges // Journal of King Saud University-Computer and Information Sciences. 2022. Vol. 34. Iss. 7. PP. 4135–4162. DOI: 10.1016/j.jksuci.2022.05.016 EDN: PQVHAJ
8. Liu J. Ahmed M., Li J., Mirza M. A., Khan W. U., et al. RL/DRL Meets Vehicular Task Offloading Using Edge and Vehicular Cloudlet: A Survey // IEEE Internet of Things Journal. 2022. Vol. 9. Iss. 11. PP. 8315–8338. DOI: 10.1109/JIOT.2022.3155667 EDN: UEMNKN
9. Shuai R., Wang L., Guo Sh., Zhang H. Adaptive Task Offloading in Vehicular Edge Computing Networks Based on Deep Reinforcement Learning // 2021 IEEE/CIC International Conference on Communications in China (ICCC, 28–30 July 2021, Xiamen, China). 2021. PP. 260–265. DOI: 10.1109/ICCC52777.2021.9580313
10. Plotnikov P., Tambovtsev G., Vladyko A. V2X Simulation Framework for Intelligent Transportation Systems: Preprint. DOI: 10.20944/preprints202511.0575.v1 // ResearchGate. URL: https://www.researchgate.net/publication/397451294_V2X_Simulation_Framework_for_Intelligent_Transportation_Systems (дата обращения: 19.11.2025).
11. Плотников П. В., Тамбовцев Г. И., Владыко А. Г. Математическая модель многокритериальной балансировки параметров V2X-систем // Информатика и автоматизация. 2026. Т. 25. № 1. С. 16–48. DOI: 10.15622/ia.25.1.1. EDN: HTJNMD
12. Shi W., Chen L., Zhu X. Task Offloading Decision-Making Algorithm for Vehicular Edge Computing: A Deep Reinforcement-Learning-Based Approach // Sensors. 2023. Vol. 23. Iss. 17. P. 7595. DOI: 10.3390/s23177595. EDN: ZWFNNV
13. Yang S., Lee G., Huang L. Deep Learning-Based Dynamic Computation Task Offloading for Mobile Edge Computing Networks // Sensors. 2022. Vol. 22. Iss. 11. P. 4088. DOI: 10.3390/s22114088. EDN: LCVIRB

Материалы статьи были представлены на VI Всероссийской научно-технической и научно-методической конференции магистрантов, аспирантов и их руководителей «Перспективные телекоммуникационные технологии и развитие цифровых кластеров в России и мире (ПКМ 2025)».

**Статья поступила 19 декабря 2025 г.
Одобрена после рецензирования 27 апреля 2026 г.
Принята к публикации 28 апреля 2026 г.**

Информация об авторе

Тамбовцев Глеб Ильич – аспирант кафедры систем автоматизации и робототехники, Санкт-Петербургского государственного университета телекоммуникаций им. проф. М. А. Бонч-Бруевича. E-mail: tambovtsev.gi@sut.ru

Adaptive Task Offloading in Intelligent Transportation Systems Using Mobile RSUs and Machine Learning

G. Tambovtsev

The Bonch-Bruевич Saint Petersburg State University of Telecommunications,
St. Petersburg, 193232, Russian Federation

Problem statement. *The growth of data volumes in Vehicle-to-Everything (V2X) networks and stringent latency requirements in intelligent transportation systems make reliance solely on cloud computing or stationary edge computing insufficient. Stationary roadside units (RSUs) have a fixed coverage area and are resource-constrained under peak loads. The aim of this work is to develop an approach for adaptive task offloading in a dynamic V2X environment using mobile infrastructure nodes (mRSUs). A multi-hop transmission algorithm and a neural-network decision-making model are proposed, enabling the selection of an optimal processing node based on parameters locally available to the on-board unit (OBU).* **Methods.** *The study is based on simulation modeling (the “simV2X” software), queueing theory for latency estimation, and machine learning methods (a multilayer perceptron) for classifying offloading modes.* **Novelty.** *The novel contributions include incorporating mobile infrastructure nodes into the overall computing hierarchy and developing a neural-network node-selection policy that relies only on local OBU features, without requiring complete information about the global network state.* **Results.** *The use of mRSUs reduced the average processing latency by nearly a factor of two and significantly decreased the probability of missing task deadlines. The trained neural network demonstrated accuracy comparable to the reference delay-minimization algorithm: the share of overdue tasks increased by only 0.5% while reducing the required volume of transmitted control information.* **Theoretical / Practical significance.** *The proposed approach enables the development of scalable and fault-tolerant ITS capable of operating efficiently under high traffic density and rapidly changing network topology, without the need for continuous reliance on the cloud.*

Key words: *networks, VANET, Vehicle-to-Everything, simulation, intelligent transportation systems, distributed computing*

Information about Authors

Tambovtsev Gleb – Postgraduate Student at the Department of Automation Systems and Robotics (The Bonch-Bruевич Saint Petersburg State University of Telecommunications). E-mail: tambovcev.gi@sut.ru