

МИНИСТЕРСТВО ЦИФРОВОГО РАЗВИТИЯ,
СВЯЗИ И МАССОВЫХ КОММУНИКАЦИЙ РОССИЙСКОЙ ФЕДЕРАЦИИ
Федеральное государственное бюджетное образовательное учреждение
высшего образования
«Санкт-Петербургский государственный университет телекоммуникаций
им. проф. М.А. Бонч-Бруевича»

На правах рукописи

Аль-Свейти Малик А. М.

**Исследование и разработка моделей и методов построения
инфраструктуры сетей автономного транспорта с использованием
технологий Искусственного Интеллекта**

2.2.15. Системы, сети и устройства телекоммуникаций

Диссертация на соискание ученой степени
кандидата технических наук

Научный руководитель
кандидат технических наук,
Мутханна Аммар Салех Али

Санкт Петербург – 2023

ОГЛАВЛЕНИЕ

Введение.....	4
ГЛАВА 1. АНАЛИЗ АВТОНОМНЫХ ТРАНСПОРТНЫХ СРЕДСТВ В СЕТЯХ	
5G	10
1.1. Сети связи пятого поколения.....	10
1.2. Анализ развития автономных транспортных средств.....	19
1.3. Перспективы использования технологий MEC в сетях 5G.....	25
1.4. Перспективы использования туманных вычислений в сетях 5G.....	28
1.5. Перспективы использования туманных вычислений в автономных транспортных средств.....	36
1.6. Выводы по главе 1	38
ГЛАВА 2. Методы глубокого обучения в многоуровневых граничных сетях	
автотранспорта	40
2.1. Введение.....	40
2.2. Задачи, решаемые в главе.....	47
2.3. Рекуррентные нейронные сети для решения задач последовательного	49
2.4. Имитационная модель	64
2.5. Результаты моделирования	66
2.7. Выводы по главе 2	71
ГЛАВА 3. Метод прогнозирования скорости движения автотранспорта в зонах с	
интенсивным движением на основе движущего летающего тумана и методов	
Искусственного интеллекта	72
3.1 Введение.....	72
3.2. Постановка задачи	78
3.3 Предлагаемое решение	81
3.4 Результаты моделирования	83
3.5. Выводы по главе 3	89

ГЛАВА 4. Метод мониторинга трафика услуг беспилотных автомобилей в сетях связи пятого и последующих поколений для обнаружения и распознавания активности биологических объектов	91
4.1. Введение.....	91
4.2. Задачи, решаемые в главе.	94
4.3. Сетевая архитектура и протоколы Mesh.....	97
4.4. Вычислительная инфраструктура.	99
4.5. Алгоритм распознавания биологических объектов	101
4.6. Обучение искусственной нейронной сети	103
4.7. Алгоритм моделирования	105
4.8. Выводы по главе 4	1054
ЗАКЛЮЧЕНИЕ	109
СПИСОК ЛИТЕРАТУРЫ.....	111
ПРИЛОЖЕНИЕ	121

ВВЕДЕНИЕ

Актуальность темы исследования. Эффективное развитие сетей связи пятого и шестого поколения 5G/6G сложно представить без использования методов прогнозирования трафика. Для прогнозирования достаточно точное и своевременное знание о поведении трафика и обеспечении быстрого соединения, большей пропускной способности и быстрого времени отклика, называемое задержкой.

С ростом числа интеллектуальных устройств, а также популярностью услуг Интернета вещей (IoT), чувствительных к задержке и осознанию местоположения, появилась технология туманных вычислений, она предназначена для решения проблем, которые облачные вычисления не могут решить самостоятельно. Поскольку туман находится ближе к пользователю, он может улучшить некоторые очень важные характеристики QoS, такие как задержка и доступность. Туманные вычисления обеспечивают своевременное предоставление транспортных услуг в реальном времени локальным пользователям благодаря обработке данных в непосредственной близости, а не маршрутизации данных в удаленный центр обработки данных в облаке.

Технологические преимущества сетей 5G, в частности сетевых технологий SDN/NFV, а также облачных MEC и туманных вычислений приводит к необходимости использования методов прогнозирования трафика для обнаружения и распознавания движущегося биологического объекта, для автономного управляемого транспорта на основе интеллектуальных граничных вычислений.

Исследователи должны учитывать проблемы, возникающие из-за огромного количества устройств IoT и их взаимодействия, различных технологий и отдельных приложений. Поэтому для их преодоления—необходимо разработать и спроектировать структуры и модели, имитирующие реальную туманную систему.

Степень разработанности темы. В области сетей связи с ультра малыми задержками существует ряд работ отечественных и зарубежных ученых В.М. Вишневого, Б.С. Гольдштейна, В.Г. Карташевского, А.Е. Кучерявого, А.И. Парамонова, К.Е. Самуйлова, В.К. Сарьяна, С.Н. Степанова, В.О. Тихвинского, А.С. Бородин, Ю.В. Гайдамаки, Р.В. Киричка, Е.А. Кучерявого, М.А. Маколкиной, Д.А. Молчанова, А.С.А. Мутханна, А.А.А. Ateya.

Настоящая диссертация в отличие от известных методов построения инфраструктуры сетей автономного транспорта предлагает подходы на основе методов Искусственного Интеллекта и туманных вычислений, что свести к минимуму сетевые задержки и обеспечить низкое энергопотребление системы. Все это в целом и определяет цель, задачи, объект и предмет диссертационной работы. При этом решается следующая научная задача в области исследований по специальности 2.2.15 – Системы, сети и устройства телекоммуникаций: Исследование и разработка эффективных методов построения инфраструктуры сетей автономного транспорта на основе технологий Искусственного Интеллекта.

Объект и предмет диссертации. Объектом исследования является автономный управляемый транспорт и его взаимодействие с сетями связи, а предметом - разработка моделей и методов динамических туманных вычислений для них.

Цель и задачи диссертации. Целью диссертационной работы является повышение эффективности функционирования автономного управляемого транспорта путем разработки моделей и методов Искусственного интеллекта и туманных вычислений.

Для достижения поставленной цели в диссертации последовательно решаются следующие задачи:

- Анализ развития сетей связи и последующих поколений
- Анализ принципов построения и предоставляемых пользователям услуг в сетях будущего поколения

- Анализ развития автономных транспортных средств
- Разработка модели и методов обнаружения и распознавания биологических объектов в придорожной зоне с использованием технологии МЕС для автономных транспортных средств
 - Разработана имитационная модель для проверки работоспособности алгоритма распознавания, используя рекуррентную нейронную сеть для определения движения людей и животных по шоссе.
 - Разработана модель глубокого обучения с использованием алгоритма долговременной краткосрочной памяти (LSTM) и алгоритма двунаправленной долговременной краткосрочной памяти (BI-LSTM), для прогнозирования трафика в автономных транспортных средствах в многоуровневой облачной архитектуре.
 - Разработана модель для прогнозирования скорости движения автотранспорта в зонах с интенсивным движением на основе движущего летающего тумана и стековой двунаправленной модели долговременной краткосрочной памяти (SBILSTM).

Научная новизна.

1. В отличие от известных методов машинного обучения для прогнозирования трафика в многоуровневой облачной архитектуре был предложен метод прогнозирования трафика в автономных транспортных средствах с использованием нейронных сетей на основе BI-LSTM и LSTM, что повышает эффективность принятия решений.

2. В отличие от известных методов глубокого обучения для прогнозирования скорости движения автотранспорта в зонах с интенсивным движением был разработан метод прогнозирования скорости движения автотранспорта в зонах с интенсивным движением на основе движущего летающего тумана и стековой двунаправленной модели долговременной краткосрочной памяти (SBILSTM), позволяющий повысить точность прогнозирования скорости движения.

3. В отличие от известных методов обнаружения и распознавания биологических объектов в придорожной зоне для автономных транспортных средств разработанный метод использует облачную структуру МЕС на основе нейронной сети, что позволяет повысить достоверность распознавания типов биологических объектов.

Теоретическая и практическая значимость диссертации.

Теоретическая значимость диссертационной работы состоит, прежде всего, в разработке методов динамических туманных вычислений с использованием технологии мобильных граничных вычислений МЕС и сетью общедоступных датчиков с коммуникационными модулями LoRa Mesh для автономного управляемого транспорта что сводит к минимуму сетевые задержки и обеспечивает низкое энергопотребление системы. Кроме того, весьма важным представляется метод машинного обучения для прогнозирования трафика для автономного управляемого транспорта

Практическая значимость диссертационной работы состоит в том, что полученные новые научные результаты (предлагаемый метод) могут быть использованы для обнаружения и распознавания активности биологических объектов на обочине дороги, что позволяет уменьшить количество аварий, вызванных животными или людьми на дороге. Также, состоит в создании методики прогнозирования трафика в многоуровневой облачной структуре в средах сетей автотранспорта и движущегося тумана.

Полученные в диссертационной работе результаты использованы в Федеральном государственном бюджетном образовательном учреждении высшего образования «Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича» (СПбГУТ) при чтении лекций, проведении практических занятий и лабораторных работ.

Методология и методы исследования. При работе использованы методы машинного и глубокого обучения, математической статистики, теории вероятностей и имитационного моделирования.

Основные положения, выносимые на защиту:

1. Метод глубокого обучения с использованием алгоритма долговременной краткосрочной памяти (LSTM) и алгоритма двунаправленной долговременной краткосрочной памяти (BI-LSTM), позволяющий уменьшить корень среднеквадратичной ошибки на 60% при использовании 8 частей выборки.

2. Метод прогнозирования скорости движения автотранспорта в зонах с интенсивным движением на основе движущего летающего тумана и стековой двунаправленной модели долговременной краткосрочной памяти (SBILSTM), позволяющий уменьшить корень среднеквадратичной ошибки на 18%.

3. Метод мониторинга трафика услуг автономных транспортных средств в сетях связи пятого и последующих поколений, позволяющий обнаружить и распознавать активности биологических объектов на обочине дороги на основе технологии интеллектуальных граничных вычислений и ячеистой беспроводной технологии LoRa.

Степень достоверности и апробация результатов.

Достоверность основных результатов диссертации подтверждается корректным применением математического аппарата, результатами имитационного моделирования, обсуждением результатов диссертационной работы на международных конференциях и семинарах, публикацией основных результатов диссертации в ведущих рецензируемых журналах.

Апробация результатов исследования. Основные результаты диссертационной работы докладывались и обсуждались на следующих международных и российских конференциях и семинарах: The 20th International Conference on Next Generation Wired/Wireless Advanced Networks and Systems + The 13th conference on Internet of Things and Smart Spaces. International Conference on

Advanced Computing & Next-Generation Communication ICACNGC 2022, Российское научно-техническое общество радиотехники, электроники и связи им. А.С. Попова "Инфо-Электросвязь", 75-я научно-техническая конференция Санкт-Петербургского НТО РЭС им. А.С. Попова, посвященная Дню радио., 24th International Conference on Distributed Computer and Communication Networks: Control, Computation, Communications, "Актуальные проблемы инфотелекоммуникаций в науке и образовании". 2019, "Актуальные проблемы инфотелекоммуникаций в науке и образовании". 2022.

Публикации по теме диссертации. Всего по теме диссертации опубликовано 10 работ, 1 из которых опубликована единолично. В числе опубликованных работ – 2 статьи в рецензируемых научных журналах, входящих в перечень изданий, рекомендуемых ВАК Министерства высшего образования и науки Российской Федерации (из них 2 в изданиях, соответствующих искомой специальности), 2 статьи в рецензируемых изданиях, входящих в международные базы данных SCOPUS и WoS, 6 статей в журналах и сборниках конференций, включенных в РИНЦ.

Соответствие паспорту специальности. Содержание диссертации соответствует пп. 3, 11, 12 и 14 паспорта специальности 2.2.15. Системы, сети и устройства телекоммуникаций.

Личный вклад автора. Основные результаты диссертации получены автором самостоятельно.

ГЛАВА 1. АНАЛИЗ АВТОНОМНЫХ ТРАНСПОРТНЫХ СРЕДСТВ В СЕТЯХ 5G

1.1 Сети связи пятого поколения

Беспроводная технология 5G призвана обеспечить более высокую скорость передачи данных - до нескольких гигабит в секунду, сверх низкую задержку, большую надежность, огромную емкость сети, повышенную доступность и более стабильный пользовательский опыт для большего числа пользователей. Высокая производительность и повышенная эффективность позволяют создавать новые возможности для пользователей и объединять новые отрасли [70].

5G - это пятое поколение мобильных сетей, которое является важным развитием для современных сетей 4G LTE [59]. 5G разработан для удовлетворения экспоненциального роста данных и возможностей подключения в современном обществе, а так же Интернета вещей с миллиардами подключенных устройств. Первоначально 5G будет работать рядом с существующими сетями 4G, а затем превратится в полностью независимые сети в более поздних версиях с расширением зоны покрытия. Помимо обеспечения более быстрого соединения и большей пропускной способности, очень важной характеристикой 5G является быстрое время отклика, называемое задержкой.

Преимущества технологии 5G:

- высокая скорость - 5G намного быстрее, чем сети предыдущего поколения, с потенциальной скоростью до 20 гигабит в секунду, что в 100 раз быстрее, чем в сетях 4G и 4G LTE [71]. Улучшения, предлагаемые 5G, означают, что фильмы будут загружаться за секунды, а не за минуты;

- низкая задержка - Задержка - это время, которое проходит между действием и ответом. Например, задержка между нажатием на ссылку на веб-странице и отображением этой веб-страницы в браузере. Сети 5G будут иметь гораздо меньшую задержку, чем 4G LTE. Один из экспериментов показал, что она может составлять всего 5 миллисекунд. Такая низкая задержка сможет поддерживать новые приложения, такие как IoT и искусственный интеллект, обеспечивая связь в режиме реального времени;

- увеличение мощности - 5G обеспечит в 1000 раз большую пропускную способность по сравнению с 4G в более широком частотном спектре. Он сможет обрабатывать одновременно приложения с высоким спросом и соединять тысячи устройств с доступом в Интернет, от телефонов до датчиков IoT;

- высокая пропускная способность - Большая пропускная способность означает большую универсальность и возможность делать больше за меньшее время. Это поддерживает как более быстрое соединение, так и большее количество устройств, а также означает, что в рамках конкретной сети больше людей могут подключиться к Интернету;

- содействие инновациям - Если 4G был ориентирован в первую очередь на мобильные телефоны, то 5G, обладая низкой задержкой и высокой пропускной способностью, идеально подходит для подключения целого ряда различных устройств или вещей, например, дронов и датчиков в продукте или устройстве. В таких отраслях, как здравоохранение, розничная торговля, производство и развлечения, будет наблюдаться огромный технологический прогресс.

Основные характеристики связи 5G, актуальные для сектора производственной промышленности и не только, сводятся к трем услугам. Во-первых, улучшенная мобильная широкополосная связь (eMBB) с увеличенной скоростью передачи данных выше 1 Гбит/с, достигающей 20 Гбит/с в нисходящем канале и 10 Гбит/с в восходящем канале. Во-вторых, массовая связь машинного

типа (mMTC), нацеленная на большое количество устройств на обширных территориях. Гупта и др. оценивают ее в 1 000 000 соединений на км². приводят число 100 узлов на м², то есть 100 000 000 на км². Такая масштабируемость в плане конечных узлов является основным аспектом mMTC. Энергоэффективная работа (до десяти лет автономной работы) для устройств IoT позволяет поддерживать большие сети с минимальным обслуживанием. В-третьих, сверхнадежная связь с низкой задержкой (uRLLC) [53], нацеленная на симметричные задержки при повышении и понижении скорости загрузки на 0,5 мс в каждую сторону, что в сумме дает ключевой показатель задержки в 1 мс. Надежность достигает более 99,999 %. URLLC станет полностью стандартизированным в 3GPP Release 16. Примечательно, что за 1 мс сигналы, идущие со скоростью света, могут преодолеть расстояние в 100 км в обе стороны, что требует использования облачных вычислений для управления в замкнутом цикле [1].

- Расширенная мобильная широкополосная связь (eMBB) - Расширенная мобильная широкополосная связь означает улучшение качества мобильной широкополосной связи, которое, как ожидается, обеспечит 5G по сравнению с предыдущими стандартами и технологиями мобильной связи, увеличив скорость передачи данных более чем в десять раз. Новые приложения будут включать в себя стационарный беспроводной доступ в Интернет для домов, приложения для наружного вещания без необходимости использования тележек для вещания, а также более широкие возможности подключения для людей, находящихся в пути [53].

- Массивная связь машинного типа (mMTC), также известная как массивная машинная связь (MMS) или массивная связь между машинами - это тип связи между машинами по проводным или беспроводным сетям, при котором генерация данных, обмен информацией и управление происходят с минимальным вмешательством человека или вообще без него. Это подклассификация связи машинного типа (MTC). mMTC имеет дело, в частности, с беспроводной связью и

сетью среди огромного количества (миллиардов) машин и считается ключевым шагом от IoT к Интернету всего. Рынок массовых коммуникаций машинного типа, по оценкам, будет расти с темпом роста 7,5% в течение прогнозируемого периода 2021-2026 гг. Связь машинного типа (MTC) является фундаментальной технологией для реализации концепции полностью подключенного мира в пятом поколении (5G) IoT. Массовое распространение устройств MTC представляет собой серьезную проблему для сотовых сетей с точки зрения эксплуатации и управления, включая массовый доступ и перегрузку сети [65]. Связь между машинами (M2M) является важным структурным элементом IoT и обозначается как связь машинного типа (MTC) проектом партнерства третьего поколения (3GPP), позволяя объектам общаться друг с другом через любую сеть связи (проводную или беспроводную). MTC соединяются друг с другом, образуя сеть MTC, чтобы облегчить интеллектуальное потребление товаров, таких как управление водными ресурсами, интеллектуальный учет, мониторинг окружающей среды, структур и активов, датчики на теле, удаленная диагностика, интеллектуальное сельское хозяйство и системы наблюдения.

- **Сверхнадежные коммуникации (URLLC):** Это критически важные задачи, включая управление устройствами в реальном времени, промышленными роботами, системами связи и безопасности транспортных средств, автономным вождением и более безопасными транспортными сетями. Коммуникации с низкой задержкой также открывают новый мир, в котором возможно удаленное медицинское обслуживание, процедуры и лечение. Сверхнадежная связь с низкой задержкой (URLLC), представленная в релизе 15 3GPP в соответствии с требованиями MCЭ-R M.2083, является одной из ключевых основ нового радио 5G (NR). Как базовая функция, необходимая для поддержки плотных сенсорных сетей конечных точек IoT, она является основным фактором для ряда уникальных сценариев использования в таких областях, как производство, передача энергии, транспорт и здравоохранение. При необходимости поддержки сквозных задержек

до 5 мс бюджет задержки для отдельных интерфейсов может составлять всего 1 мс. Это означает, что оптимизация должна производиться на каждом этапе процесса передачи данных по восходящему и нисходящему каналу. Хотя это не входит в сферу действия спецификаций 3GPP, необходимость сокращения времени отклика при обработке данных также приводит к появлению стратегий высокораспределенных граничных вычислений [77].

5G уже на горизонте и, как ожидается, окажет огромное влияние на общество. 5G позволит развернуть новые "умные" города и отрасли, которые в настоящее время невозможны при использовании нынешних технологий [60]. Он также обеспечит новые формы связи и мобильности, которые никогда не были возможны ранее. Влияние 5G на общество будет огромным, но у этой технологии есть и некоторые потенциальные недостатки. Потенциальные возможности применения 5G безграничны и включают такие вещи, как улучшение широкополосной связи, дополненная и виртуальная реальность, автономные транспортные средства и телемедицина [56]. Ожидается, что сеть 5G окажет значительное влияние на нашу жизнь в ближайшие годы, и она уже начала изменять то, как люди работают и живут. Например, в ближайшие годы ожидается взрывной рост Интернета вещей: Подключенные к сети устройства будут использоваться для отслеживания цепочек поставок, автоматизации производственных процессов и повышения производительности в офисах и на заводах. Хотя до полного внедрения 5G еще есть некоторое время, он уже проложил путь для новых захватывающих технологий, таких как дополненная реальность и виртуальная реальность.

5G позволит использовать технологии IoT для повышения эффективности бизнес-операций и принятия лучших решений. Кроме того, низкая задержка, обеспечиваемая 5G, позволит компаниям принимать решения в режиме реального времени и быстрее внедрять изменения, чтобы реагировать на изменения в бизнес-среде. Наконец, 5G будет поддерживать различные офисные приложения, включая видеоконференции и виртуальные совещания, инструменты для совместной работы

и улучшенные функции безопасности. Предприятиям необходимо начать думать о том, как они могут извлечь выгоду из использования этих технологий в своей повседневной деятельности, чтобы оставаться конкурентоспособными и подготовиться к появлению сети 5G. 5G может изменить многие аспекты нашей жизни, но наибольшее влияние, как ожидается, будет оказано на рабочее место.

Хотя развертывание систем мобильной связи следующего поколения все еще впереди на временном интервале в десять или более лет, многие текущие программы 6G и связанные с ними инвестиции открывают заманчивые перспективы для значительного ускорения исследований 6G [52]. Промышленные и общественные организации уже начали инвестировать в исследования и инновации (R&I), чтобы соответствовать требованиям, которые 6G, вероятно, будет предъявлять, когда начнет функционировать около 2030 года [55].

К ним относятся сценарии использования, обещанные в сетях 5G, но еще не реализованные, и более продвинутые сценарии использования, которые появляются в контексте систем 6G [58]. Примерами таких новых сценариев являются терагерцовая связь, повсеместное покрытие (земля, воздух, космос, море), голопортация, тактильная/осязательная связь, медицинская/здоровая вертикаль, государственная/национальная безопасность, визуализация и зондирование, услуги общественной безопасности, киберфизические системы/производство и транспорт. Примеры соответствующих сценариев использования 6G и вытекающих из них технологических требований показаны на таблице 1.1 [57].

Таблица 1.1 – Примеры соответствующих сценариев использования 6G и вытекающих из них технологических требований

Пример использования	Технологическое требование	Показатель производительности (5G → 6G)
Голографические, тактильные/осязательные коммуникации, цифровые двойники	Очень высокая пропускная способность	Подключение: 10 Gbps → 500 Gbps – 1 Tbps Нисходящая связь: 20 Gbps → 1 Tbps Спектр: 400 MHz – 71 GHz → Up to 10 THz
Повсеместные услуги, масштабные сети IoT, транспорт, сельское хозяйство и животноводство	Очень широкая зона покрытия	10 Мбит/с / м ² → 1-10 Гбит/с / м ³ везде, например, небо, море, космос и т.д.
AR/VR/MR, цифровой двойник, тактильные/осязательные коммуникации, медицина/здравоохранение, телехирургия, Правительство/Национальная безопасность, первое реагирование/экстренные службы, транспорт	Повышенная надежность	1-10 ⁻⁵ (99.999%) → 1-10 ⁻⁹ (99.9999999%) доступность
Массовый масштаб сетей IoT, умное сельское хозяйство и животноводство	Конечные точки с высокой плотностью	1 млн. соединений / км ² → 10 млн. соединений / км ²
AR/VR/MR, голографические коммуникации, цифровой двойник,	Синхронизация нескольких потоков на несколько устройств	Задержка воздушного интерфейса: 1 мс → 10 нс - 0,1 мс

Пример использования	Технологическое требование	Показатель производительности (5G → 6G)
тактильные/осязательные коммуникации, телемедицина, телехирургия		Задержка от конца до конца: 5 - 10 мс → < 100 мкс Джиттер: не указан → < ±0,1 мкс
AR/VR/MR, тактильные/осязательные коммуникации, транспортная вертикаль	Точное отслеживание положения	10 см в 2D 1 см в 3D, с 6 степенями → движения: (x, y, z) плюс тангаж, рысканье и вращение
Массовый масштаб сетей IoT, умное сельское хозяйство и животноводство	Чрезвычайно низкое энергопотребление и устройства с ограниченными ресурсами	Энергия/бит: Не указано → 1 пДж/бит, чрезвычайно низкое энергопотребление: срок службы батареи датчика 20 лет, включая устройства, которые никогда не нужно заряжать (например, поглощающие энергию из окружающей среды)

Таблица 1.2 – Архитектурные инновационные аспекты 6G

Стимулирующая технология	Потенциал	Проблемы	Варианты использования
Инновационные сетевые архитектуры			
Множественное подключение и архитектура без ячеек	Бесшовная мобильность и интеграция различных видов связей	Планирование, необходимость в новом дизайне сети	Повсеместная связь, беспилотная мобильность, голографическое телеприсутствие,

Стимулирующая технология	Потенциал	Проблемы	Варианты использования
			электронное здравоохранение
3D сетевая архитектура	Повсеместное 3D-покрытие, бесперебойный сервис	Моделирование, оптимизация топологии и энергоэффективность	Повсеместная связь, электронное здравоохранение, беспилотная мобильность
Деагрегирование и виртуализация	Снижение затрат для операторов при массовом развертывании	Высокая производительность для обработки РНУ и МАС	Повсеместная связь, голографическое телеприсутствие, индустрия 4.0, беспилотная мобильность
Расширенный доступ - обратная интеграция	Гибкие варианты развертывания, ретрансляция с наружного на внутренний	Масштабируемость, планирование и помехи	Повсеместная связь, электронное здравоохранение
Операции по сбору энергии и маломощные	Энергоэффективные сетевые операции, отказоустойчивость	Необходимость интеграции характеристик источников энергии в протоколы	Повсеместная связь, электронное здравоохранение
Разведанные в сети.			
Обучение для оценки ценности информации	Интеллектуальный и автономный выбор информации для передачи	Сложность, неконтролируемое обучение	Повсеместная связь, электронное здравоохранение, голографическое телеприсутствие, индустрия 4.0, беспилотная мобильность

Стимулирующая технология	Потенциал	Проблемы	Варианты использования
Обмен знаниями	Ускорьте обучение в новых сценариях	Необходимость разработки новых механизмов совместного использования	Повсеместная связь, беспилотная мобильность
Сетевая архитектура, ориентированная на пользователя	Распределенный интеллект по конечным точкам сети	Обработка в режиме реального времени и с низким энергопотреблением	Повсеместная связь, электронное здравоохранение, индустрия 4.0

1.2 Анализ развития автономных транспортных средств

Автономное транспортное средство - это автомобиль, который способен чувствовать окружающую среду и работать без вмешательства человека. Пассажир не обязан контролировать автомобиль в любой момент, да и вообще в нем нет необходимости. Автомобиль может работать полностью автономно как будто кто-то действительно управляет им.

Автономное транспортное средство оснащено различными датчиками для определения окружающего пространства, такими как радар, лидар, сонар, система глобального позиционирования, компьютерное зрение, измерение расстояния и инерциальные измерительные приборы. Передовые системы управления

интерпретируют сенсорную информацию, чтобы определить подходящий курс для навигации, а также соответствующие препятствия и знаки.

Эксперименты с системами автоматизированного вождения (СAB) проводятся по крайней мере с 1920-х годов; [10] испытания начались в 1950-х годах. Первый полуавтоматический автомобиль был разработан в 1977 году японской машиностроительной лабораторией Цукуба. Для его управления требовались специально размеченные улицы, которые интерпретировались двумя камерами на автомобиле и аналоговым компьютером. Автомобиль развивал скорость до 30 км/ч (19 миль в час) при поддержке надземного рельса [2].

Автономное транспортное средство означает транспортное средство, способное преодолевать дороги в районе и понимать устройства управления дорожным движением без активной работы водителя в любой из систем управления транспортного средства. Термин "самоуправляемое транспортное средство" исключает транспортное средство, оснащенное системами активной безопасности или помощи водителю, включая системы для обеспечения электронной помощи при движении вслепую, предотвращения столкновений, экстренного торможения, помощи при парковке, адаптивного круиз-контроля, помощи при движении по полосе, предупреждения о выходе из полосы движения, о пробках и помощи в очереди, если только система сама по себе или в сочетании с другими системами не позволяет транспортному средству, в котором установлена данная технология, двигаться без активного управления или контроля со стороны человеческого фактора.

Автомобили без водителя нуждаются в разновидностях машинного зрения для распознавания визуальных объектов. Автономные транспортные средства разрабатываются с использованием глубоких нейронных сетей - типа архитектуры глубокого обучения со многими вычислительными этапами и уровнями, в которых нейроны моделируются из среды, в которой активируется сеть. Нейронная сеть опирается на большой объем данных, полученных из реальных сценариев

вождения, что позволяет нейронной сети "учиться" тому, как реализовать наилучший курс действий [3].

В мае 2018 года исследователи из Массачусетского технологического института объявили о создании роботизированного автомобиля, способного ориентироваться на незапланированных дорогах [4]. Исследователи из Лаборатории компьютерных наук и искусственного интеллекта (CSAIL) разработали новую систему под названием MapLite, которая позволяет самодвижущимся автомобилям ездить по дорогам, по которым они никогда раньше не ездили, без использования 3D-карт. Система объединяет GPS-навигацию автомобиля с "разреженной топографической картой", такой как OpenStreetMap (то есть, имеющей только 2D-черты дорог), и рядом датчиков, отслеживающих дорожные условия [5].

Машинное обучение применяется для более высоких уровней помощи водителю, таких как восприятие и понимание окружающего мира. В основном это связано с использованием систем на базе камер для обнаружения и классификации объектов, но есть также разработки в области LiDAR и радаров.

Одной из самых больших проблем автономного вождения является неправильная классификация объектов. Данные, собранные различными датчиками автомобиля, собираются и затем интерпретируются системой автомобиля. Но при разнице всего в несколько пикселей на изображении, полученном системой камер, автомобиль может ошибочно принять знак "Стоп" за что-то более безобидное, например, за знак ограничения скорости. Если система также примет пешехода за фонарный столб, то она не сможет предвидеть, что он может сдвинуться с места.

Благодаря улучшенному и более обобщенному обучению моделей машинного обучения, системы могут улучшить восприятие и идентифицировать объекты с большей точностью. Обучение системы путем предоставления ей более разнообразных входных данных по ключевым параметрам, на основе которых она принимает свои решения, помогает лучше проверить данные и убедиться, что то,

на чем она обучается, является репрезентативным для истинного распределения в реальной жизни. Таким образом, не возникает сильной зависимости от одного параметра или набора ключевых характеристик, которые в противном случае могли бы заставить систему сделать определенный вывод.

Нейронные сети могут распознавать шаблоны, поэтому их можно использовать в автомобилях для контроля за водителем. Например, распознавание лиц может быть использовано для идентификации водителя и проверки наличия у него определенных прав, например, разрешения на запуск автомобиля, что может помочь предотвратить несанкционированное использование и угон.

В краткосрочной перспективе автомобили будут нуждаться в определенном контроле и внимании со стороны человека, назначенного "водителем". Именно здесь распознавание мимики станет ключом к повышению безопасности. Системы могут быть использованы для изучения и обнаружения признаков усталости или недостаточного внимания и предупреждения пассажиров, возможно, даже для замедления или остановки автомобиля.

Программное обеспечение для фреймворков глубокого обучения, такое как Caffe и TensorFlow от Google, использует алгоритмы для обучения и включения нейронных сетей. Они могут использоваться при обработке изображений для изучения объектов и их классификации, чтобы автомобиль мог легко реагировать на окружающую его среду. Это может быть определение полосы движения, когда система определяет углы поворота, необходимые для того, чтобы избежать объектов или оставаться в пределах полосы движения на шоссе, и, следовательно, точно предсказывает путь впереди.

Нейронные сети также могут использоваться для классификации объектов. С помощью ML их можно обучить определенным формам различных объектов. Например, они способны различать автомобили, пешеходов, велосипедистов, фонарные столбы и животных.

Изображение также может быть использовано для оценки близости объекта, а также его скорости и направления движения. Для маневрирования вокруг препятствий автономный автомобиль может использовать ML для расчета свободного пространства, например, вокруг автомобиля, а затем безопасно объехать его или сменить полосу движения для обгона.

Добавление компьютерных систем и сетевых возможностей в транспортные средства делает кибербезопасность автомобилей еще более актуальной. Машинное обучение может быть использовано и здесь для повышения безопасности. В частности, его можно использовать для обнаружения атак и аномалий, а затем их преодоления.

Одна из угроз для отдельного автомобиля заключается в том, что злоумышленник может получить доступ к его системе или использовать его данные. Модели машинного обучения должны обнаруживать подобные атаки и аномалии, чтобы обезопасить автомобиль, его пассажиров и дороги.

Крупнейшие технологические компании и основные производители автомобилей соревнуются в разработке своих предложений автономных транспортных средств. Каждая из них хочет быть первой на рынке, чтобы доминировать в этой области. В настоящее время наблюдается большая активность в развитии подключенной инфраструктуры, появлении технологии 5G, движении к созданию нового законодательства для регулирования отрасли и даже стремлении к мобильности как услуге (MaaS).

Также происходят изменения в том, как используется машинное обучение. Вот те будущие тенденции, которые, по нашему мнению, будут определять рынок автономных транспортных средств.

Обучение является основным аспектом машинного обучения. Чтобы приблизиться к человеческим возможностям и избежать риска аномалий, требуется многократное обучение системы в разнообразных и не очень ситуациях, возникающих на городских дорогах, шоссе и автострадах.

По мере того, как производители автомобилей накапливают все больше дорожных километров, и все больше объектов требуют обнаружения и классификации, создаваемые наборы данных растут.

Рост этих наборов данных создает проблему: наличие достаточной вычислительной производительности, на которой можно развернуть обученные сети. В связи с этим одной из инноваций является создание высоко оптимизированных методов ускорения. В области обработки информации достигнут большой прогресс, например, в развертывании обученных сетей непосредственно на интегральных микросхемах. Эти новые микросхемы позволяют развертывать сложные сети по низкой цене и с низким энергопотреблением. Подобные кремниевые решения, оптимизированные по стоимости и занимающие мало места, смогут продвинуть рынок вперед и преодолеть проблемы вычислительной производительности.

Маловероятно, что мы можем ожидать появления полномасштабных серийных моделей автономных автомобилей раньше 2025 года. Кроме того, еще предстоит выяснить, сколько времени пройдет, прежде чем количество автомобилей без водителя превысит количество автомобилей с ручным управлением.

Тем не менее, легковые и грузовые автомобили без водителя уже не за горами. Благодаря машинному обучению, эти автомобили обеспечат большую мобильность миллионам людей с ослабленным зрением и инвалидов; позволят осуществлять доставку в отдаленные районы, быстрее и экономичнее доставлять товары людям и соединять сообщества; и, что самое главное, повысят безопасность дорожного движения, снизив количество дорожно-транспортных происшествий, травм и смертей.

Наконец, ключевым фактором является сотрудничество. Различные компании имеют опыт в своих областях, связанных с машинным обучением. Некоторые специализируются на восприятии с помощью камер или обработке

данных LiDAR; другие вкладывают средства в объединение входных данных датчиков; третьи обладают опытом в поиске пути и планировании траектории и переводе этих решений в приятные действия по управлению, ускорению и замедлению. Эти компании должны будут сотрудничать, чтобы помочь автопроизводителям запустить свои автономные транспортные средства в производство.

Как автомобильные алгоритмы искусственного интеллекта используются для автономных транспортных средств:

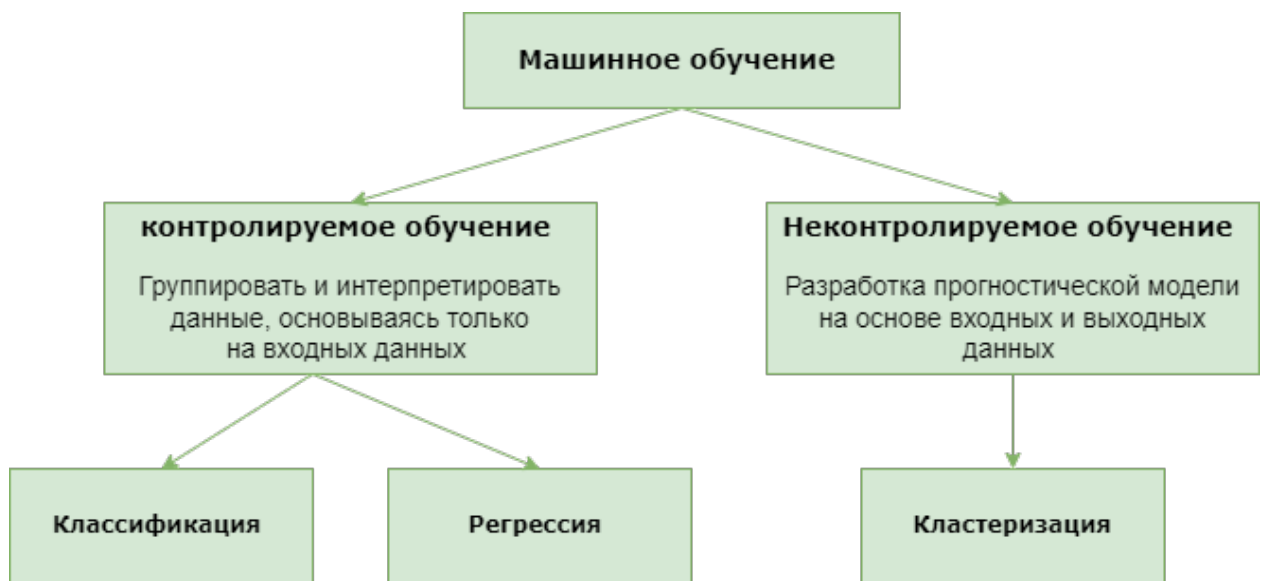


Рисунок 1.1 – Алгоритм искусственного интеллекта для автономных транспортных средств

1.3 Перспективы использования технологий MEC в сетях 5G

В сущности, Техническое объяснение цели MEC можно изложить как решение, которое позволяет пользователям использовать облачные

вычислительные ресурсы на границе сети (между сетями радиодоступа и опорной сетью) [72]. Пограничные вычисления являются одной из ключевых основ для удовлетворения потребностей в связи с низкой задержкой (1 миллисекунда) и возможностью поддержки новых сегментов бизнеса, где телекоммуникационные сети ранее не существовали, в этом и заключается цель MEC - управлять задачами намного быстрее и эффективнее, благодаря большей близости между элементами сети [75].

Платформа MEC обычно развертывается на выделенном сервере поверх облачной инфраструктуры, где также могут быть развернуты приложения, работающие как виртуальные машины или контейнеры. Если рассматривать MEC более подробно, то общие сущности можно сгруппировать на сущности системного уровня, уровня хоста и сетевого уровня:

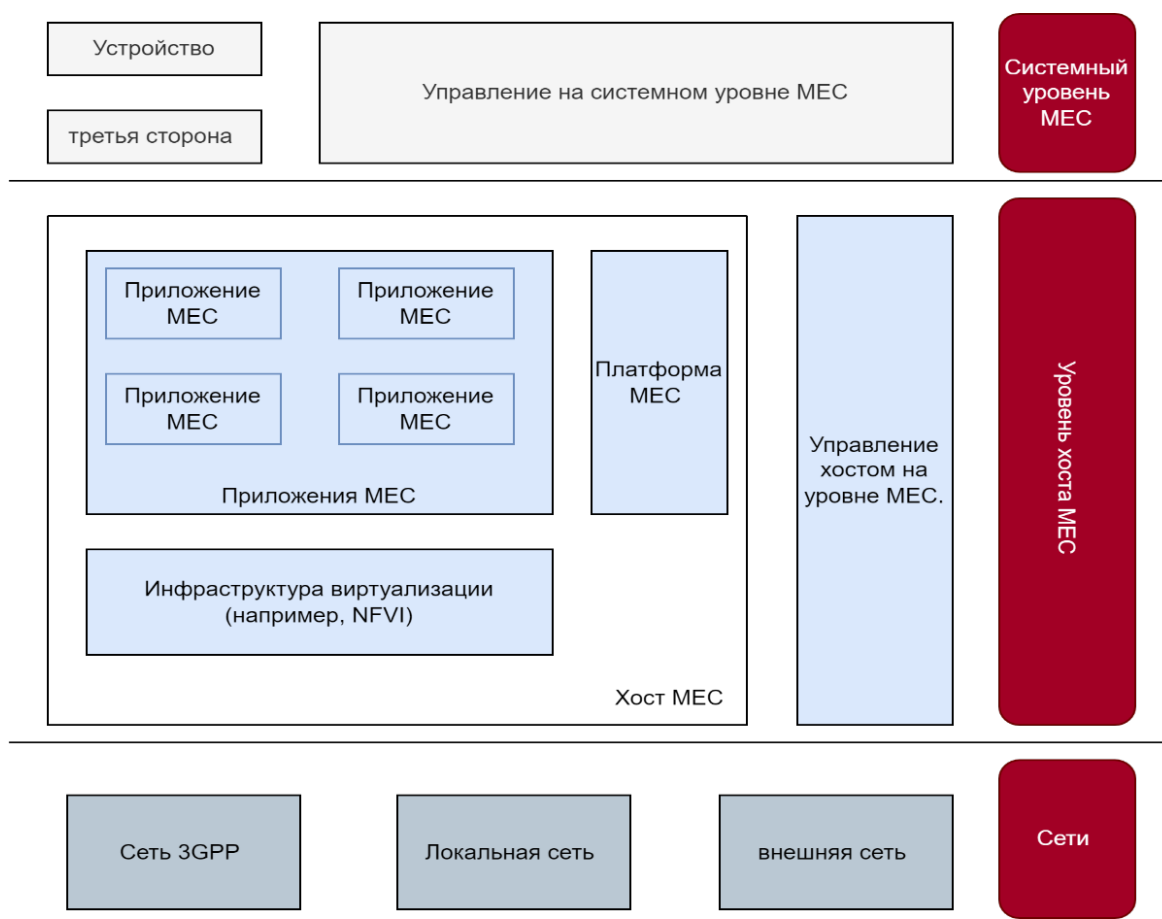


Рисунок 1.2 – Уровни MEC системы

Хост МЕС состоит из следующих частей:

- Хост МЕС - это объект, содержащий платформу МЕС и инфраструктуру виртуализации, которая предоставляет вычислительные ресурсы, ресурсы хранения и сетевые ресурсы для запуска приложений МЕС.

- Платформа МЕС - это набор основных функциональных возможностей, необходимых для запуска приложений МЕС на определенной инфраструктуре виртуализации и позволяющих им предоставлять и потреблять услуги МЕС (платформа МЕС может также предоставлять услуги).

- Приложения МЕС инстанцируются на инфраструктуре виртуализации узла МЕС на основе конфигурации или запросов, подтвержденных руководством МЕС.

Преимущества 5G МЕС:

- предлагает клиентам новые сетевые услуги. Следовательно, это позволяет поставщикам услуг увеличить доход за счет использования множества вариантов использования;

- приложения работают в локальной среде, что повышает производительность и удобство работы пользователей благодаря меньшим задержкам;

- не изменяя существующую архитектуру сети 5G, поставщики услуг могут внедрять новые услуги для конечных потребителей;

- благодаря приложениям ОТТ ("Over the Top") услуги доступны клиентам в зависимости от их местонахождения;

- обеспечивает безопасность услуг IoT;

- предлагает распределенную инфраструктуру и повышает надежность приложений и сетевых сервисов;

- снижает потребность в облачном хранении данных и последовательно экономит транспортные расходы;

- позволяет экономить пропускную способность сети и снижает ее перегрузку.

1.4 Перспективы использования туманных вычислений в сетях 5G

Интернет развивался с момента его зарождения и сейчас выходит за рамки традиционных настольных компьютеров. Распространение Интернета вещей привело к трансформации способов взаимодействия мира в Интернете. Теперь IoT готов соединить устройства, людей, среду, виртуальные объекты и машины таким образом, какого мир еще не знал. Развертывание IoT, таких как "умные города", "умные дома" и тому подобное - вещи, которые были скорее фантастикой, - теперь становятся реальностью и, по прогнозам, затронут как можно больше аспектов человеческой жизни.

Типичные системы IoT состоят из огромного количества устройств, начиная от датчиков, встроенных в дороги, и заканчивая мобильными устройствами, такими как автомобили и поезда. При таком большом количестве вещей, задействованных в развертывании IoT, количество устройств, подключенных к Интернету, растет семимильными шагами. В настоящее время количество конечных устройств (как правило, смартфонов и ноутбуков) оценивается примерно в 3-4 миллиарда, и ожидается, что через несколько лет оно вырастет до триллиона. Такое количество устройств будет генерировать гигантские объемы данных, в результате чего возникает явление, получившее название "цунами данных". Приложения и сетевая инфраструктура должны будут соответствующим образом адаптироваться к такому огромному увеличению объема данных, которые им придется обрабатывать, учитывая ограничение доступной пропускной способности.

Развитие техники всегда было направлено на создание систем, которые могут функционировать при минимальном вмешательстве человека. Интернет вещей является идеальной платформой для разработки таких приложений, в частности потому, что подключение каждого устройства к Интернету дает каждому устройству возможность самостоятельно принимать решения, тем самым снижая

необходимость вмешательства человека. Исследования таких автономных систем показали, что они в значительной степени зависят от низкого времени отклика приложения. Системы IoT, такие как интеллектуальные сети, совместное обнаружение объектов и т.д., требуют задержки порядка субмиллисекунд - требования, которые Интернет должен обеспечить, чтобы приложение работало нужным образом. Такое изменение характера устройств, подключенных к Интернету, и сопутствующее увеличение объема генерируемых данных требует эволюции и сетевой инфраструктуры. Нынешняя облачная модель исполнения окажется неэффективной, если вообще осуществимой, для футуристических приложений, которые предлагает развитие IoT.

Туманное вычисление (Fog computing) - это термин, введенный профессором Сальваторе Дж. Столфо, который недавно был подхвачен компанией Cisco. Fog Computing - это парадигма, которая расширяет облачные вычисления и сервисы до границ сети, позволяя приложениям работать в непосредственной близости от пользователей, быть очень географически распределенными и поддерживать мобильность пользователей. Благодаря таким характеристикам, Fog сокращает задержки запросов на услуги и улучшает QoS, что приводит к превосходному пользовательскому опыту. Вычисления Fog являются необходимостью для новых приложений Интернета всего (IoE) (таких как промышленная автоматизация, транспорт и т.д.), которые требуют реального времени/предсказуемой задержки. Благодаря широкому и плотному географическому распределению, парадигма тумана хорошо подходит для анализа больших данных в реальном времени. Точки сбора данных в туманных вычислениях плотно распределены, что добавляет четвертую ось - геораспределение - к часто упоминаемым измерениям больших данных (объем, разнообразие, скорость и достоверность).

Туман предоставляет те же услуги, что и облако (вычисления, хранение и сети), и использует те же механизмы (виртуализация, многопользовательский

доступ и т.д.). Эти общие атрибуты облака и тумана позволяют разработчикам создавать приложения, использующие взаимодействие между туманом и облаком.

Важно отметить, что туман не является заменой существующей парадигмы облачных вычислений, наоборот, туман является расширением облака. Приложения, созданные для тумана, должны быть способны использовать как гибкость и мощность облака, так и возможности тумана в реальном времени.

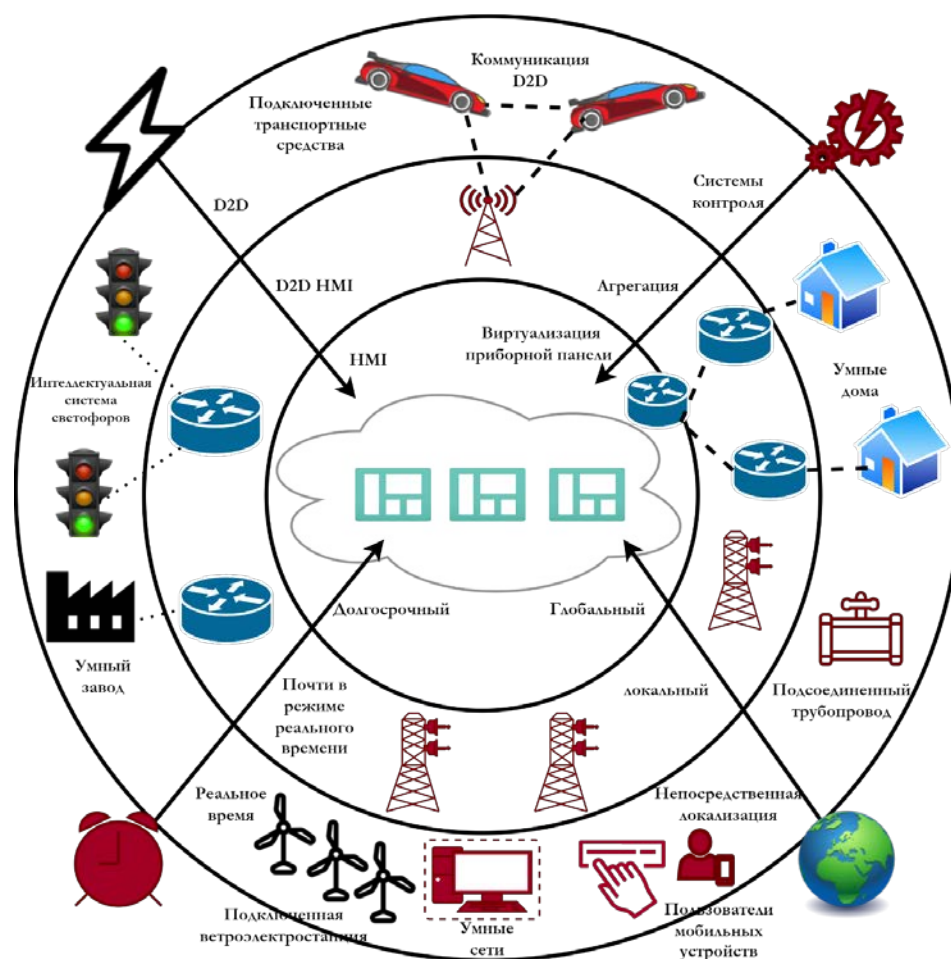


Рисунок 1.3 – Приложения, поддерживаемые туманными вычислениями

Приложения с жесткими требованиями к задержкам, например, мобильные игры, видеоконференции и т.д. Запуск этих приложений в облаке может ухудшить качество работы пользователей из-за ненадежности QoS, предлагаемого облаком.

Геораспределенные приложения, в которых точки сбора данных распределены по обширной территории, например, мониторинг трубопроводов или сети датчиков для мониторинга окружающей среды.

Быстрые мобильные приложения с участием высококомобильных пользователей (интеллектуальный подключенный автомобиль, подключенный железнодорожный транспорт).

Крупномасштабные распределенные системы управления, состоящие из огромного количества датчиков и исполнительных механизмов, работающих согласованно для повышения удобства пользователей. Например, интеллектуальные сети, подключенные железные дороги, интеллектуальные системы светофоров.

Туманные вычисления и сети 5G - две концепции, имеющие разное происхождение, но вскоре они сойдутся, поскольку обещания, которые дает видение сетей 5G, делают необходимым перенос обработки данных на периферию [81].

Связь в сетях 5G будет основана на высокочастотных сигналах - в диапазоне миллиметровых волн - которые смогут выделять большую пропускную способность для более быстрой передачи видео и мультимедийного контента высокого качества. Сети 5G обещают обеспечить миллисекундные и субмиллисекундные задержки при скорости передачи данных более 1 гигабита в секунду. Эта задержка настолько мала, что исключает возможность того, что радиointерфейс является узким местом. Мобильные сети нового поколения проектируются таким образом, чтобы они могли обслуживать коммуникации, не ограничиваясь людьми (где можно замаскировать задержку) - они создаются для поддержки надежной и быстрой межмашинной связи, для эффективного использования которой необходима низкая задержка.

Для того чтобы 5G была успешной, она должна поддерживать туманные вычисления, иначе радиointерфейсы с низкой задержкой будут бесполезны. В

типичной сети 5G мобильные пользователи подключаются к базовой станции, которая в свою очередь подключена к опорной сети через проводные каналы. Запросы к облачному приложению будут проходить через базовую станцию и опорную сеть, чтобы в итоге попасть на облачные серверы. При таком развертывании, несмотря на то, что радиointерфейсы с низкой задержкой обеспечивают субмиллисекундную связь между мобильным устройством и базовой станцией, отправка запроса с базовой станции в облако приведет к увеличению задержки на порядки.

Необходимо, чтобы сети 5G были не просто инфраструктурой связи. Услуги вычислений и хранения данных, если они будут предоставляться сетью в непосредственной близости от устройств, позволяют приложениям воспользоваться преимуществами радиосвязи с низкой задержкой и обеспечить очень быстрое время отклика. Это принесет большую пользу как потребителям (благодаря своевременным ответам), так и провайдеру (благодаря снижению нагрузки на магистральную сеть). Такой перенос обработки из облака на периферию формирует определение туманных вычислений, и не будет ошибкой сказать, что сети 5G не смогут выполнить свои обещания без туманных вычислений. Туманные вычисления - это не особенность, как считает большинство, а необходимое требование для успешной работы сетей 5G.

Ключевым элементом сетей 5G, обеспечивающим возможность туманных вычислений, являются малые соты (пико и фемтосоты), также известные как микросоты. Малые соты могут облегчить нагрузку на базовые станции на крыше макросоты, позволяя конечным точкам подключаться к ним. Устройство может подключаться как к макросоте, так и к микросоте. Таким образом, архитектура сетей 5G становится иерархической: на вершине находится опорная сеть (облако), затем базовые станции макросот, базовые станции микросот и, наконец, конечные устройства. Таким образом, с точки зрения туманных вычислений, базовые станции макро- и микросот образуют туманные узлы, т.е. сетевые узлы, обеспечивающие

вычисления и хранение данных. Пакеты, отправляемые устройствами вверх по каналу связи, анализируются на базовых станциях микро- или макросот, прежде чем попасть в основную сеть.

Еще одним важным достижением в области связи, которое несет с собой 5G, является эффективная связь между устройствами. Отправляемые данные будут передаваться от устройства-отправителя непосредственно к устройству-получателю, а базовая станция будет обрабатывать только управляющую информацию. Это позволяет осуществлять обмен данными между устройствами, не нагружая базовую станцию, тем самым выигрывая у туманных систем в масштабируемости при работе с многочисленными устройствами, взаимодействующими друг с другом. Это будет особенно полезно для приложений, которые включают в себя множество подключенных точек и непрерывную связь между ними, например, умные дома.

Архитектура физической сети туманной сети 5G будет расширять архитектуру современных гетерогенных облачных сетей радиодоступа. В традиционной архитектуре HCRAN все задачи обработки приложений выполняются в облаке внутри опорной сети, что требует передачи данных в опорную сеть от миллиардов конечных устройств. Такое огромное количество коммуникаций может снизить пропускную способность фронтальной сети и перегрузить опорную сеть, что пагубно скажется на качестве обслуживания конечных пользователей.

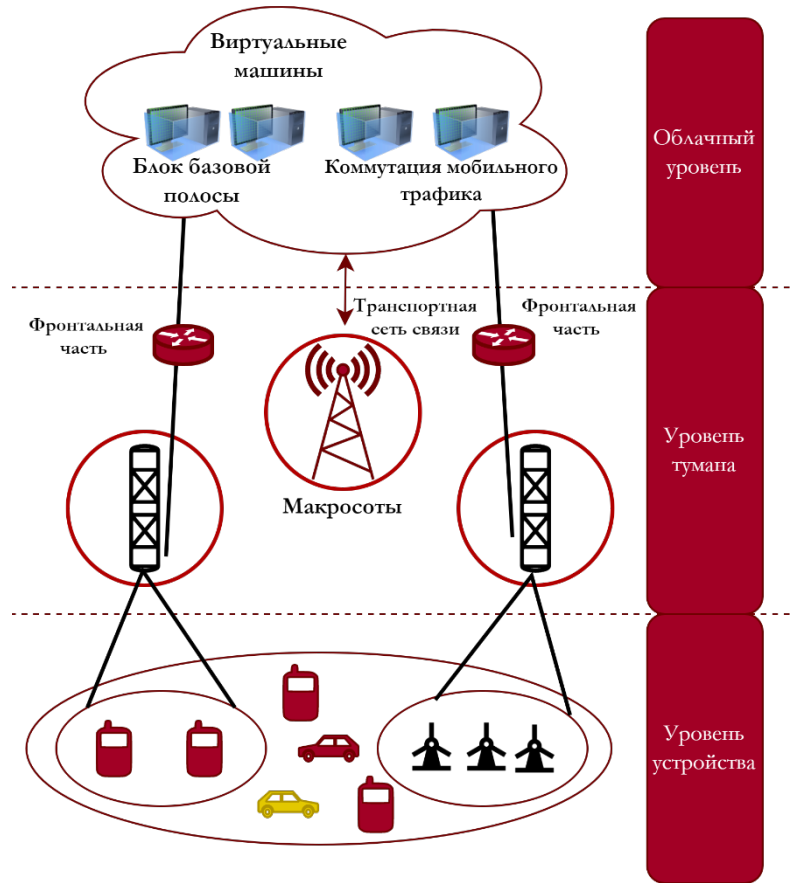


Рисунок 1.4 – Архитектура сети 5G с туманными вычислениями – трехслойная архитектура

Интуитивно понятное решение этой проблемы заключается в том, чтобы спустить вычислительные возможности и возможности хранения из облака к границе, чтобы необходимость отправки всех данных, генерируемых конечными устройствами, в облако отпала, а это избавит фронтальную и опорную сети от огромного всплеска трафика. Архитектура туманной сети состоит из 3 логических уровней, которые показаны на рисунке 1.4.

- **Уровень устройств** - Уровень устройств включает в себя все конечные устройства, подключенные к туманной сети. К устройствам относятся устройства IoT, такие как датчики, шлюзы и т. д., а также мобильные устройства, такие как смартфоны, планшеты и т. д. Эти устройства могут обмениваться данными напрямую с сетью или осуществлять одноранговую связь между собой. Являясь

источником всех данных, поступающих в сеть, и основными исполнителями задач, эти устройства представляют собой самый нижний уровень туманных устройств. Уровень устройства обеспечивает вычисления либо посредством встроенного кодирования (для устройств низкого класса, таких как датчики), либо как программное обеспечение, работающее в операционной системе устройства.

- Туманный уровень - Туманный уровень состоит из промежуточных сетевых устройств, расположенных между конечными устройствами на уровне устройств и облачным уровнем. Первой точкой разгрузки в этом слое являются удаленная радиоголовка (RRH) и малые соты, которые соединены оптоволоконным фронтальным каналом с основной сетью. Обработка входящих данных здесь значительно снизит нагрузку на фронтальную часть (Fronthaul). Макросоты также образуют точку разгрузки обработки данных, которые отправляют обработанные данные в опорную сеть через транзитные каналы. И Fronthaul, и Backhaul реализуются с помощью каналов Ethernet, а промежуточные устройства, такие как маршрутизаторы и коммутаторы на пути от радиоголовок к ядру, также являются потенциальными местами, где задачи вычислений и хранения данных могут быть разгружены.

- Облачный уровень - этот уровень образует вершину иерархической архитектуры, а облачные виртуальные машины являются точками разгрузки вычислений. Теоретически бесконечная масштабируемость и высококлассная инфраструктура облака позволяют обрабатывать данные, требующие интенсивных вычислений и большого объема памяти, что невозможно сделать на граничных устройствах. В дополнение к обработке на уровне приложений, облачный уровень содержит блоки базовой полосы, которые обрабатывают данные, поступающие от RRH и малых сот через фронтальные каналы, и направляют обработанные данные на серверы приложений.

1.5 Перспективы использования туманных вычислений в автономных транспортных средствах

Туманные вычисления – это архитектура распределенных вычислений, которая представляет собой промежуточный уровень устройств между облаком и конечными устройствами. По сути, это расширяет вычислительные ресурсы и ресурсы хранения, обычно предоставляемые облаком, ближе к границе сети. Туманные вычисления значительно перекликаются с родственными технологиями, такими как мобильные периферийные вычисления (MEC) и мобильные облачные вычисления (MCC), и эти термины иногда используются как взаимозаменяемые [76].

Также может быть включено машинное обучение, которое помогает понять, какие данные необходимо отправить в облако. Это позволяет решить проблему задержки при отправке данных в облако, что очень важно для самоуправляемых автомобилей.

Автомобильные туманные вычисления разработаны с учетом двух ключевых категорий: движущиеся и припаркованные автомобили. В каждом разделе понимание коммуникационных и вычислительных компонентов работы самодвижущихся автомобилей является очень важным. В целом, коммуникация сосредоточена на создании эффективных методов передачи информации другим близлежащим автомобилям. Именно здесь и происходит вычисление. Цель - собрать и проанализировать окружающие данные (например, количество машин, скорость, наличие пешеходов и т.д.) и ответить методом, который лучше всего подходит для текущей обстановки.

Предварительная обработка данных - Самым большим преимуществом туманных вычислений является возможность обрабатывать данные с локальных интеллектуальных устройств, в данном случае с нашего автомобиля. Однако для

того, чтобы наш самоуправляемый автомобиль знал о своем окружении, а также общался с другими самоуправляемыми автомобилями, требуется большая вычислительная мощность и обратная связь в реальном времени.

Существуют две наиболее распространенные формы связи:

- технология связи между транспортными средствами (V2V) - это интеллектуальная технология, которая позволяет обмениваться данными от одного транспортного средства к другому [61]. Связь для технологии V2V основана на выделенной связи малого радиуса действия (DSRC) [80]. Это не совсем новая технология, она существует уже несколько десятилетий, но системы V2V окажут наибольшее влияние на безопасность транспортных средств, когда они станут широко доступны, например, для предотвращения дорожно-транспортных происшествий. Связь V2V позволяет автомобилям получать информацию о скорости и положении других автомобилей, находящихся рядом, используя протокол беспроводной связи, аналогичный Wi-Fi [62]. Эти данные затем используются для предупреждения водителей о потенциальных опасностях, помогая уменьшить количество аварий и заторов на дорогах. V2V может обнаруживать опасные дорожные условия, проблемы рельефа и погодные угрозы в радиусе 300 метров. Система V2V способна сделать вождение более предсказуемым и безопасным для всех участников дорожного движения.

- Связь между транспортным средством и сетью (V2N) - Поскольку транспортные средства все меньше зависят от ручного управления, возможна реализация более безопасных, эффективных и устойчивых поездок, и все это благодаря технологиям V2N. Передача информации между транспортными средствами и системой управления направлена на передачу информации между транспортными средствами и сетью. Этот процесс возможен благодаря сетевой инфраструктуре с высокой пропускной способностью, низкой задержкой и высокой надежностью. Автомобили могут получать широкоэмитерные предупреждения о

заторах на дорогах или авариях, прокладывая путь к автономному вождению - будущему мобильности.

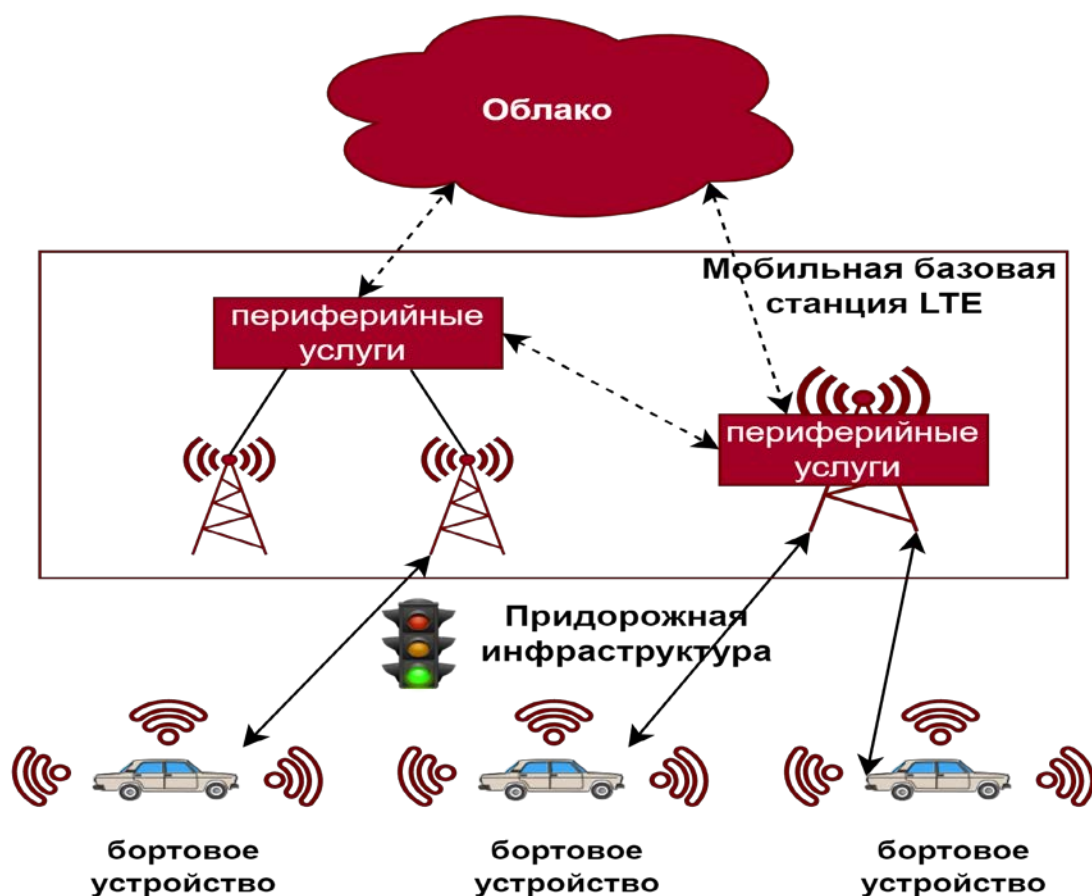


Рисунок 1.5 – Связь с инфраструктурой V2V через LTE

V2V определяется количеством присутствующих компонентов (т.е. количеством автомобилей), а также средней скоростью этих автомобилей.

1.6 Выводы по главе 1

- Анализ развития сетей связи пятого поколения показывает что, сеть может обеспечить очень высокую скорость передачи данных, сверх низкую задержку,

большую надежность, огромную емкость сети и высокую пропускную способность, что приводит к быстрому соединению, и также большому количеству устройств и большому числу людей способных подключиться к интернету.

- Проанализированы: возможности использования методов туманных вычисления в сетях 5G для решения задач автономного управляемого транспорта; методы машинного обучения при определении данных необходимых для отправки в облако, для уменьшения задержки при отправки данных в облако; определен круг задач в которых можно эффективно применить машинное и глубокое обучение прогнозирования трафика в сетях связи пятого и последующих поколений. К этим задачам относятся прогнозирование потерь пакетов, задержки и пропускной способности в сетях связи пятого поколения для Интернета Вещей и Тактильного Интернета.

- Для коммуникации автономных управляемых транспортов между собой, нужно применить эффективные методы передачи информации, для этого очень важно собрать и проанализировать окружающие данные. В связи с этим, требуется большая вычислительная мощность и обратная связь в реальном времени., Необходимо исследовать возможность и эффективность использования автомобильных туманных вычислений.

ГЛАВА 2 МЕТОДЫ ГЛУБОКОГО ОБУЧЕНИЯ В МНОГОУРОВНЕВЫХ ГРАНИЧНЫХ СЕТЯХ АВТОТРАНСПОРТА

2.1 Введение

Автономные транспортные средства являются одним из наиболее важных новых вариантов использования перспективных технологий для сетей пятого поколения (5G) и следующего поколения в многочисленных приложениях. В настоящее время использование БА экспоненциально растет во всем мире, благодаря быстрому росту осведомленности и использованию методов искусственного интеллекта (AI) в различных областях. Прогнозирование потоков данных необходимо для БА, чтобы улучшить передачу данных и уменьшить задержки за счет более эффективного использования соответствующих возможностей, мониторинга, управления и контроля дорожной системы. В данной главе диссертационной работы предлагается подход глубокого обучения с двунаправленной моделью долговременной краткосрочной памяти (BI-LSTM) для прогнозирования интенсивности движения транспортных средств с многоуровневыми сервисами облачных вычислений. С точки зрения точности прогнозирования проводится сравнение между BI-LSTM и однонаправленной LSTM в зависимости от количества используемых пакетов. Точность прогнозирования рассчитывается с помощью среднеквадратичной ошибки (RMSE), средней абсолютной процентной ошибки (MAPE), коэффициента детерминации (R^2) и времени обработки.

Многоуровневая сетевая структура отличается от любой другой структуры, поскольку она охватывает, контролирует, управляет локальными облачными

структурами и предлагает лучшие возможности, чем поставщики облачных услуг. Многоуровневая архитектура обеспечивает стабильную и повторяемую архитектуру на нескольких платформах: она является основной в производстве, а также ядром нынешнего и грядущего публичного облака. С ростом использования IoT в различных сферах жизни, включая обмен данными в реальном времени между пользователями и машинами, тактильный интернет позволил системе IoT мгновенно и быстро взаимодействовать в промышленном и коммерческом секторах.

Тактильный интернет — это интернет, обеспечивающий удаленный доступ к точным и виртуальным операциям в режиме реального времени, сочетающий в себе несколько преимуществ: практически полное отсутствие задержек, надежность и очень высокую защиту. Реализация тактильного интернета включает в себя приложения из различных областей: робототехника, электроника, виртуальная реальность, дополненная реальность, искусственный интеллект и т.д. [6,7].

Ожидается, что технологии беспроводной связи следующего поколения, включая сети 5G и выше, станут важным фактором успеха автономных транспортных средств в ближайшие годы. Они позволят внедрить новые услуги и сценарии применения в будущем интеллектуальном транспорте, благодаря возможности быстрого и надежного обмена данными между различными субъектами. Развитие коммуникационных технологий для интеллектуальных транспортных систем в сочетании с передовой обработкой данных и искусственным интеллектом (AI) означает, что такие важные функции как обеспечение крупномасштабных сетей, выбор технологий для гетерогенного беспроводного доступа, а также интеллектуальные и безопасные интегрированные услуги, пользуются большим спросом [8].

Полностью функциональная и эффективная сеть 5G немыслима в отсутствие AI. Сочетание ML и AI на границе сети может быть достигнуто путем распределения сетей 5G, который обеспечивает синхронное подключение

нескольких устройств IoT и генерирует большое количество данных, которые могут быть обработаны с помощью ML и AI, позволяющих таким сетям быть предиктивными и проактивными, что необходимо для эффективности сети пятого поколения. Добавив ML к технологии 5G, интеллектуальные каналы могут принимать собственные решения. Мобильные устройства могут создавать гибкие, динамические коллекции в соответствии со считанными данными, что повышает эффективность, латентность и надежность сетевых приложений.

Как только ML и AI будут объединены с 5G периферийные вычисления для множественного доступа (MEC), мобильные операторы смогут обеспечить их [9,10]:

- Значительную степень компьютеризации за счет распределенной структуры ML и AI на границе сети;
- Управление трафиком в сетях доступа на основе приложений;
- Динамическая нарезка сети охватывает различные сценарии с различными условиями качества обслуживания (QoS) [11].

Автономные транспортные средства с поддержкой многоуровневых облачных вычислений растут во всем мире по экспоненте, поскольку репутация методов искусственного интеллекта и их использование в многочисленных приложениях резко возросли. Прогнозирование транспортных потоков необходимо для того, чтобы автономные транспортные средства определяли маршрут движения и принимали адаптивные решения относительно окружающих их объектов. Связь между транспортными средствами (V2V) позволяет автомобилям общаться друг с другом, передавая сообщения, содержащие данные о скорости автомобиля или предупреждения об изменении местоположения. Когда система транспортных средств обменивается данными посредством связи V2R (vehicle-to-roadside), придорожное устройство берет на себя управление движением транспортных средств и отправляет широковещательное сообщение всем автомобилям, находящимся поблизости [12].

Специфические проблемы, связанные с маршрутизацией в VANETs - топология сети, демографическая ситуация, различная плотность трафика в другое время и быстрые изменения прибывающих и убывающих транспортных средств в сетях автотранспорта [66]. В сетях сетей автотранспорта широковещательные пакеты передаются в зависимости от географической области, определенной пакетом. Транспортные средства посылают короткие пакеты со своими идентификаторами и текущим географическим положением [69].

Таким образом, может быть разработана кооперативная система предотвращения столкновений, которая поможет избежать столкновений путем предоставления предупреждений. Безопасность сетей автотранспорта критически важна, поскольку их существование связано с неотложными ситуациями. Важно, чтобы злоумышленник не смог изменить жизненно важную информацию [13].

На рисунке 2.1, показано многоуровневая облачная система, которая состоит из нескольких уровней. Первый уровень - это физическое оборудование, которое включает в себя бортовые устройства (OBU), которые могут быть подключены к распределенным RSU. RSU — это интеллектуальный мультисервисный узел доступа, используемый вместо небольших сетевых узлов при расширении традиционных сетей и создании новых сетей с большим количеством удаленных объектов [73]. Второй уровень содержит гетерогенные, облачные, граничные серверы, разбросанные вдоль границы RAN [74]. Система состоит из двух серверов MEC: мини-облака и микрооблачного граничного сервера. Каждый RSU связан с мобильными базовыми станциями и граничным сервером микрооблака. Граничный сервер микрооблака работает с ограниченными вычислительными и энергетическими возможностями. Каждый набор серверов микрооблака связан с пограничным сервером мини-облака с мощными вычислительными и энергетическими ресурсами.

Уровень 3 - это SDN, распределенная по основной сети. Этот уровень состоит из двух основных подуровней: уровня управления и данных. На подуровне данных

находятся распределенные виртуальные коммутаторы OpenFlow, которые обслуживают подходящую версию протокола OpenFlow. Второй подуровень (уровень плоскости управления) включает распределенные SDN для управления и контроля всей сети [54]. Интерфейс прикладных программ (API) управляет SDN и основными сетевыми интерфейсами к уровню 1 и серверу приложений. Предлагаемая система имеет два прямых интерфейса на уровне-1. Первичным интерфейсом является транспортное средство, а последующим интерфейсом - каркасная сеть транспортного средства. Это может быть достигнуто через соответствующую сеть IEEE 802.11, различные стандарты связи для беспроводной локальной сети (WLAN) связи на различных частотах, более известной как Wi-Fi [64]; уровень-2 распределенные граничные серверы связаны через быструю беспроводную сеть (Wi-fi). Каждый RSU связан с сервером MEC для обеспечения вычислительной мощности на границе сети доступа [68]. Это снижает трафик на ведущую сеть, уменьшая её перегрузку или потерю пакетов.

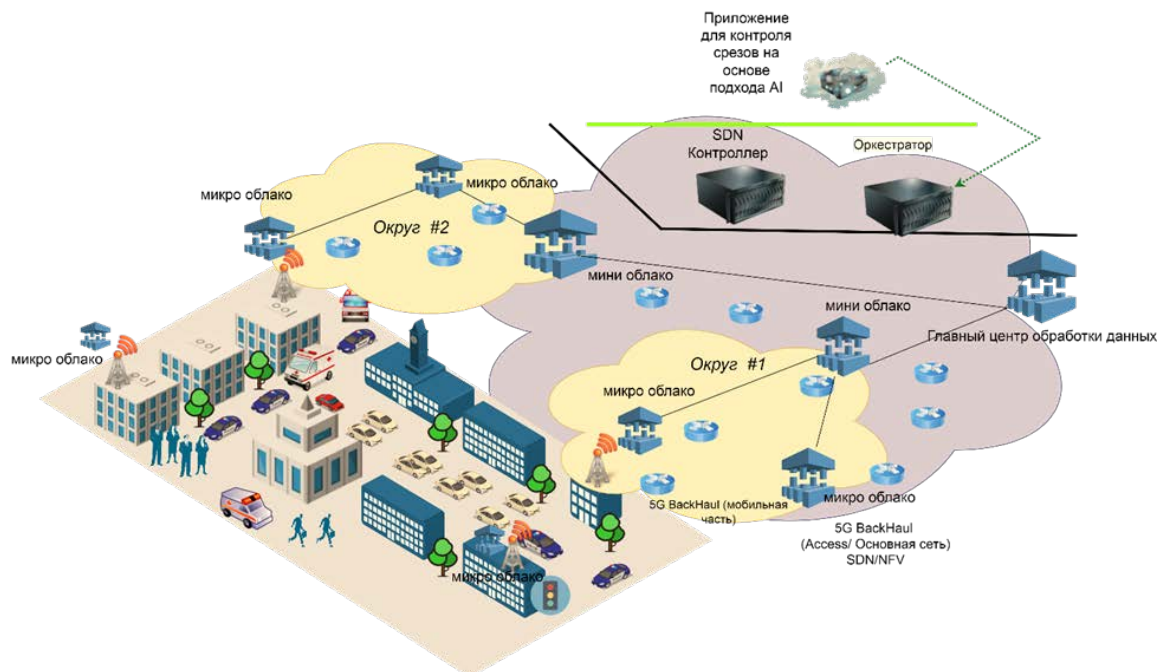


Рисунок 2.1 – Многоуровневая облачная система

Концепции глубокого обучения недавно привлекли внимание многих исследователей благодаря своей способности решать проблемы распознавания, понимания естественного языка, сокращения размерности, идентификации объектов, моделирования движения, прогнозирования трафика и т.д. Глубокое обучение использует концепции многослойных нейронных сетей для вывода глубинных свойств данных от самого низкого до самого высокого уровня. Они находят в данных большое количество структур, которые позволяют их представить и сделать логические выводы. Разработка автономного транспорта, который может сделать транспортные сети гораздо более экономичными и снизить риск для жизни людей. Эта концепция также имеет дополнительное преимущество - экономию времени. В последние десятилетия большое внимание уделяется безопасному автоматизированному вождению. Информация должна вовремя поступать от систем помощи водителю (DAS), автономных транспортных средств и систем распознавания дорожных знаков (TSR) [8, 14].

Прогнозирование сетевого трафика является важным инструментом для беспроводных сетей 5G и других сетей, позволяющим управлять перегрузкой и ресурсами сети, а также обеспечивать безопасность, надежность и связь выбранных сетей. Использование статистических временных рядов или подходов машинного обучения позволяет прогнозировать будущие потоки сетевого трафика на основе предыдущих данных. Эффективное прогнозирование может улучшить качество обслуживания (QoS) и снизить эксплуатационные расходы для поставщиков сетевых услуг. Существующая литература показывает, что модели глубоких обучений более эффективно изучают модели сетевого трафика и более точно предсказывают будущий трафик, чем традиционные модели [9,10,15].

В работе [14] рассматривается прогнозирование сетевого трафика с использованием глубоких нейронных сетей (DNN, аббр. от англ. Deep Neural Network). Исследуется то, как DNN могут заранее предсказать приблизительную скорость сетевого взаимодействия. В работе [15] было выполнено прогнозирование

задержки IoT с помощью много параметрического метода DNN. В [16, 17] изучалось долгосрочное и краткосрочное прогнозирование трафика беспроводной сети с помощью LSTM с поддержкой глубокого обучения. В [18] авторами представлены решения на основе глубокого обучения для сетей 5G и интернета транспортных средств (IoV, аббр. от англ. Internet of Vehicles). В статье [19] рассматриваются последние исследования беспроводных сетей следующего поколения и роль методов машинного обучения (ML, аббр. от англ. Machine Learning) в этих будущих беспроводных системах. Прогнозирование трафика по временным рядам с использованием глубокого обучения и LSTM-сети для граничных вычислений с поддержкой IoT выполнено в работе [20]. В работе [21] представлены исследования проблемы прогнозирования трафика IoT с помощью Машинного обучения, глубокого обучения, статистических методов прогнозирования на основе временных рядов, таких как LSTM, ARIMA, VARMA и нейронных сетей прямого распространения (FFNNs, аббр. от англ. Feed Forward Neural Networks). В статье [22] был представлен обширный обзор современных ML подходов к прогнозированию сотового трафика в сетях 5G. В работе [22] проведены исследования прогнозирования маршрута транспортного средства на основе ML с использованием V2V-взаимодействия и бортовых датчиков. Представлен метод прогнозирования маршрута с использованием алгоритма случайного леса и архитектуры кодер-декодер LSTM. Проанализированные релевантные работы позволили сделать некоторые предварительные выводы относительно способа решения задачи прогнозирования трафика в беспроводной коммуникационной среде автономных транспортных средств с многоуровневой облачной архитектурой поддержки вычислений с использованием методов искусственного интеллекта. Представляется, что гипотетически перспективным является подход глубокого обучения на основе моделей рекуррентных нейронных сетей типа LSTM и их возможных модификаций, адаптированных под предметную область.

2.2 Задачи, решаемые в главе

В этой главе диссертационной работы был исследован метод прогнозирования трафика в автономных транспортных средствах с многоуровневыми облачными вычислениями с использованием подхода глубокого обучения на основе BI-LSTM (аббр. от англ. Bidirectional Long-Short-Term Memory – двунаправленная модель с долговременной краткосрочной памяти) и LSTM (однаправленная модель).

Для прогнозирования сетевого трафика использовалось множество методов машинного обучения, таких как Random Forest [23], ARIMA [21, 24], VARMA [21], LSTM [7, 16, 17, 20], NARX [8, 13, 25, 26] и др.

Мы построили модель глубокого обучения на основе блоков LSTM и BI-LSTM для прогнозирования спроса, создали систему БА с помощью симулятора AnyLogic для создания обучающего набора данных машинного обучения. После сбора, исследования и обработки набора данных мы использовали их в качестве входных данных для модели глубокого обучения и для метода прогнозирования. Затем набор данных применяется к сети в двух подмножествах: в столбцах информации (I) и вывода (O), а затем мы разбиваем его на подмножества для обучения и тестирования. Нормирование входных данных должно находиться в интервале $[-1, 1]$, что соответствует фактическим максимальным или минимальным значениям.

Сначала мы обучаем сеть, тестируем ее и, наконец, внедряем. В данном исследовании мы не использовали проверочный набор для сети и не оптимизировали статические гиперпараметры сети, такие как размер слоя LSTM.

Результаты исследований можно резюмировать следующим образом:

- Предложены двунаправленная LSTM (BI-LSTM) и однонаправленная LSTM с моделью глубокого обучения для прогнозирования трафика в автономном транспортном средстве на основе мультиоблачных услуг.

- Модель глубокого обучения была обучена в различных конфигурациях, основанных на количестве используемых пакетов, с использованием BI-LSTM и однонаправленной LSTM в двух случаях - в среде сетей автотранспорта и в среде движущегося тумана. Цель состояла в том, чтобы найти оптимальную часть выборки, обеспечивающий наивысшую точность.

- С точки зрения точности прогнозирования было проведено сравнение между BI-LSTM и LSTM при различных конфигурациях сети на основе используемых частей выборки и между этими различными конфигурациями сети.

- Точность прогнозирования определялась с помощью RMSE, MAPE, (R^2) и времени обработки, учитывая MSE как функцию потерь и скорость обучения 0,1.

- Наконец, результаты моделирования показывают следующее:

- ❖ во всех случаях точность прогнозирования с помощью BI-LSTM выше, чем у LSTM;

- ❖ точность прогнозирования в случае использования 8 частей выборки превосходит конкурентов и имеет наилучшие показатели как для BI-LSTM, так и для LSTM сетей;

- ❖ точность прогнозирования при использовании 64 частей выборки является низкой по сравнению с другими;

- ❖ R^2 примерно одинаков в обоих случаях и близок к 1, что означает, что сеть хорошо подогнана;

- ❖ для среды сетей автотранспорта при использовании 64 частей выборки, время обработки самое быстрое, а при использовании 8 частей выборки, время обработки самое длительное по сравнению с другими;

- ❖ при использовании 8 частей выборки, модель BI-LSTM имеет самое быстрое время обработки в среде тумана, а при использовании 16 частей выборки,

модель LSTM имеет самое быстрое время обработки. Тем не менее, при использовании 64 частей выборки, модели имеют самое длительное время обработки.

2.3 Рекуррентные нейронные сети для решения задач последовательного

Прогнозирование поведения трафика с помощью глубокого обучения имеет большое значение, поскольку оно способно обучаться на больших объемах данных и определять модели лучше, чем другие подходы. Прогнозирование потенциального трафика позволяет улучшить QoS до возникновения сбоев. Обучение с помощью глубоких нейронных сетей (DNN) может быть использовано в качестве метода прогнозной аналитики, поскольку оно использует историческую информацию для улучшения процесса принятия решений, что приводит к повышению точности. Кроме того, прогнозирование возможности появления большого количества потоков данных в необычное время, которые, скорее всего, можно классифицировать как атаки на основе потоков данных, позволяет повысить безопасность сети. Более того, прогнозирование таких больших потоков данных может также устранить риск, который может нарушить работу системы IoT. Прогнозирование сетевого трафика позволяет пользователям быстро принимать меры по отслеживанию перегруженности трафика и улучшению работы сети. Кроме того, прогнозирование трафика на длительные периоды позволяет использовать детальные модели трафика для оценки будущих потребностей в пропускной способности, что обеспечивает более точное планирование и принятие более эффективных решений. Прогнозирование на короткие периоды (от миллисекунд (мс) до минут) подходит для динамических ресурсов. Быстрое

прогнозирование трафика является мощным методом для достижения большей эффективности. Их методы необходимы для повышения точности прогнозирования сетевого трафика, чтобы предотвратить ухудшение способности системы к обеспечению качества обслуживания и преодолеть трудности 5G.

Наблюдаемая технология должна прогнозировать, чтобы предотвратить слабые совместные решения; поэтому необходимы различные прогнозы трафика. Многочисленные стратегии ML были разработаны для повышения точности прогнозов трафика. Среди лучших подходов - DNN, который основан на системе ANN. Этот метод был проконтролирован и протестирован для прогнозирования будущих данных о трафике. Глубокое обучение - это особый вид многослойной нейронной сети (MLNN). Глубокое обучение зависит от MLNN и соответствующих алгоритмов, которые обрабатывают большие наборы данных. Другие способы лучше, чем обычные NN, обрабатывают данные из предыдущих случаев. RNN относится к числу наиболее распространенных и широко используемых сетевых циклов в предыдущей информации. Каждая сеть в цикле получает входные данные и информацию от предыдущей сети, выполняет определенный процесс, генерирует выход и передает данные будущей сети.

Обычная рекуррентная нейронная сеть (RNN), аббр. от англ. Recurrent Neural Network) - это сеть, которая использует петлю обратной связи для создания памяти и крайне плохо справляется с условиями, когда что-либо должно быть "сохранено" надолго. Задержки в обучении становятся еще более серьезными, когда нет связи между последней необходимой порцией данных и критической целью. Влияние скрытого состояния или входа t-шага на последующие состояния сети реакции быстро уменьшается. Предлагаемые сегодня решения с глубоким обучением в основном связаны с гибкостью и сложностью непрерывной сети "строительных блоков". Было показано, что вместо одного числа, на которое влияют все последующие условия, можно создать особого рода ячейку, в которой тем или иным способом имитировать "длинную память", операции записи и чтения в этой "ячейке

памяти" и т.д. Такая клетка будет иметь не одну группу весов, подобно обычному нейрону, а различные, в таком случае обучение будет очень трудным, но практически утечки обычно происходят. Для одних случаев требуется только новая информация, а для других - более ранние данные. Обычные нейронные сети отстают в обучении, потому что задержка между ранее необходимой информацией и требуемым ключом увеличивается экспоненциально.

А. Сеть долговременной краткосрочной памяти (LSTM)

Одной из самых популярных и часто используемых модельных структур в искусственном интеллекте является LSTM. Сеть LSTM – это тип рекуррентной нейронной сети (RNN, аббр. от англ. Recurrent Neural Network), наиболее подходящих для долгосрочного хранения данных и обычно используемых в области глубокого обучения. Поскольку большие объемы данных могут повлиять на производительность модели, она является естественным выбором для построения, обучения и развертывания сети. Преимущество LSTM в том, что она помогает обеспечить меньшее влияние на независимые связи. Кроме того, сеть должна быть обучена определять, какой фрагмент информации подходит для сети, и иметь точное представление о том, что нужно хранить. В случае глубокого обучения, LSTM применяется многократно.

LSTM стал наиболее эффективным решением почти всех проблем прогнозирования последовательностей благодаря последним достижениям в области науки о данных. Ячейка LSTM получает или отбрасывает данные в зависимости от их веса. Впоследствии эти данные возмещаются в зависимости от их веса. Операция обучения RNN адаптирует веса соединений, которые управляют скрытым состоянием и входом. Но эти сети обучаются по мере поступления сигналов, выходного сигнала или удаления информации через последовательные шаги распространения ошибки. Блок LSTM, в отличие от стандартного рекуррентного блока, сохраняет ячейку памяти.

Стандартная структура ячеек LSTM показана на рисунке 2. Ячейка в LSTM имеет три основных узла, называемых гейтами (gate), управляющих ее состоянием: входной (input gate), забывания (forget gate) и выходной (output gate), а фактическая ячейка обратной связи – это скрытое состояние.




Рисунок 2.2 – Структура сети LSTM

Гейты LSTM представляют собой сигмоидальную передаточную функцию (1), т.е. их выход эквивалентен 0 или 1.

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (2.1)$$

Следует оценить гейт забывания, как процентный вклад входа; входной гейт выбирает текущую информацию для хранения в ячейке памяти. Текущий вектор значений-кандидатов может быть использован для состояния слоя активации гиперболического тангенса (\tanh -слой – один из типов слоев, используемых в нейронных сетях, который включает свои собственные весовые матрицы). Входной гейт подключается к \tanh -слою для получения изменения состояния. Выход функции активации \tanh соответствует значению между -1 и 1 для определения его значимости.

Оценка использует функцию $\tanh(x)$ следующим образом:

$$\tanh \tanh (x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.2)$$

Другие связи увеличивают связность модели (о них мы поговорим ниже). Предположим, что мы задаем, что x_t и h_t - это векторы входного и скрытого состояния по времени t . В этом случае W_i и W_h представляют собой весовые матрицы, которые применяются к входному пути и обратной связи, соответственно, а b - вектор смещения.

Учитывая следующий вход x_t для скрытого состояния f с предыдущего шага h_{t-1} и текущее состояние ячейки C_{t-1} , мы вычисляем математические формы для входных ворот i_t , ворот забывания f_t и выходных ворот o_t в LSTM:

$$i_t = \sigma(w_i x_t + g_i h_{t-1} + b_i) \quad (2.3)$$

$$f_t = \sigma(w_f x_t + g_f h_{t-1} + b_f) \quad (2.4)$$

$$o_t = \sigma(w_o x_t + g_o h_{t-1} + b_o) \quad (2.5)$$

где i_t, f_t, o_t определяются как функция весовых матриц $w_i, g_i, w_f, g_f, w_o, g_o$ и векторов смещения b_i, b_f, b_o .

Компактные формы для уравнений состояния клетки-кандидата, состояния клетки и вектора скрытого состояния (выходного вектора) следующие:

$$C'_t = \tanh(w_c x_t + g_c h_{t-1} + b_c) \quad (2.6)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot C'_t \quad (2.7)$$

$$h_t = o_t \odot \tanh(C'_t) \quad (2.8)$$

Состояние клетки-кандидата \tilde{C}_t определяются как функция весовых матриц w_c и g_c . Оператор \odot обозначает произведение Хадамарда (произведение по элементам).

В. Двухнаправленная LSTM (BI-LSTM)

Двухнаправленные LSTM основаны на блоке LSTM, где два LSTM подаются на входной сигнал. Одна подается на входной ряд (путь прямого распространения). На втором этапе обратная форма входного ряда подается на модель LSTM (путь обратного распространения). Сеть LSTM анализирует только влияние прошлой серии на текущую и игнорирует более позднюю информацию, поэтому оптимальная производительность не достигается. В отличие от этого BI LSTM связывает выход блока LSTM двухнаправленно. Она улавливает двухнаправленные зависимости сигналов, что повышает общую производительность модели. BI-LSTM – это последовательная вычислительная модель, состоящая из двух LSTM. Каждая нейронная сеть имеет ряд информации в обратном пути (от приходящей к предыдущей) и прямом пути (от последней к приходящей). В двухнаправленной сети входные данные поступают в двух направлениях, что отличает BI-LSTM от обычной LSTM. В обычной LSTM входной поток может идти в одном направлении: либо назад, либо вперед. В двухнаправленной LSTM можно заставить входные данные поступать в обоих направлениях, чтобы получить информацию из будущего и прошлого.

Bi-LSTM эффективно увеличивают количество информации, доступной сети, улучшая содержание, доступное алгоритму. Прямое и обратное направления BI-LSTM одновременно передаются на выходной модуль. Таким образом, могут быть получены прошлые и предстоящие данные, как показано на рисунке 2.3. В каждый момент времени t вход подается на прямой и обратный пути сети LSTM.

Выход BI-LSTM может быть представлен следующим образом:

$$\vec{h}_t = H(W_1 x_t + W_2 \vec{h}_{t-1} + \vec{b}) \quad (2.9)$$

$$h^{\leftarrow}_t = H(W_3 x_t + W_5 h^{\leftarrow}_{t-1} + b^{\leftarrow}) \quad (2.10)$$

$$y_t = W_4 \vec{h}_t + W_6 h^{\leftarrow}_t + b_y \quad (2.11)$$

где \vec{h}_t , h^{\leftarrow}_t , и y_t - векторы для прямого, обратного и выходного слоев. W - весовые коэффициенты. b^{\rightarrow} , b^{\leftarrow} и b_y - соответствующие векторы смещения.

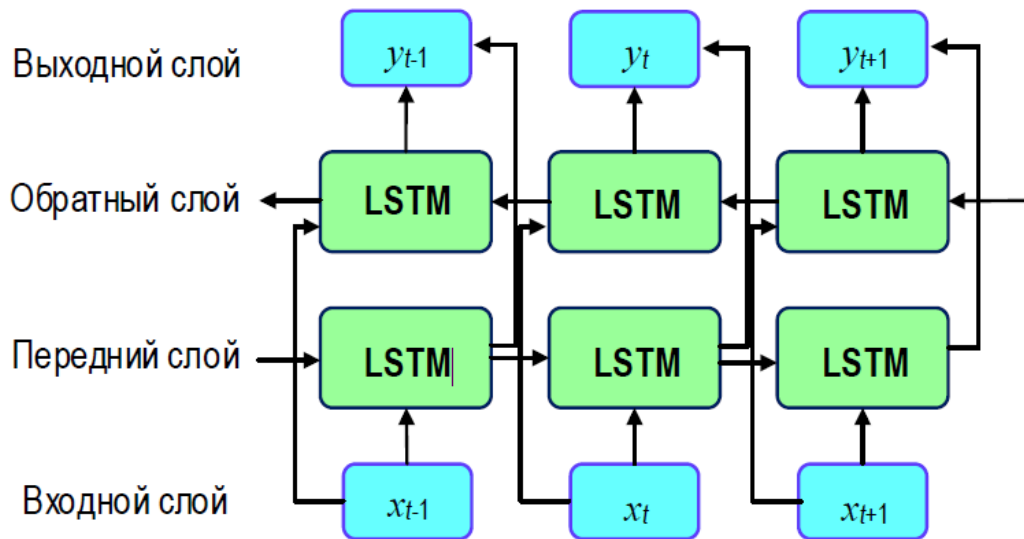


Рисунок 2.3 – Структура нейронной сети Bi-LSTM

На рисунке 2.3 можно видеть поток информации в обратном и прямом слоях. BI-LSTM обычно используется там, где требуется последовательность задач. Этот тип сети может использоваться в классификации текстов, распознавании речи и прогностических моделях.

А. Среда сетей автотранспорта

Транспортные средства потенциально могут взаимодействовать с другими участниками этих сетей и придорожной инфраструктурой (RSU) для доступа к информационным услугам, начиная от безопасности и заканчивая поддержкой

водителей, подключением к Интернету для получения конкретной информации и мультимедийных средств (VoIP, обмен мгновенными сообщениями и т.д.) [67].

МЕС включают в себя перемещение вычислений, связанных с трафиком и услугами, из централизованного облака на границу сети и ближе к клиентам. Граница сети анализирует, обрабатывает и хранит данные вместо того, чтобы отправлять их в облако для обработки. Наиболее значительным преимуществом пограничных вычислений является значительное сокращение задержек при аналитической обработке [79]. Вычисления выполняются на конечных устройствах, поэтому информации не нужно преодолевать километры сетей, чтобы попасть в центр обработки данных.

Преимущества пограничных вычислений с множественным доступом очевидны во многих местах и приложениях. Наиболее очевидным является то, что она позволяет сетевым операторам и поставщикам услуг сократить задержки при предоставлении услуг для улучшения общего обслуживания клиентов, а также внедрять новые услуги с высокой пропускной способностью без упомянутых выше задержек.

Если предположить, что облачная служба обмена сообщениями может быть спроектирована как система очередей, то средняя задержка, вызванная доставкой сообщения в облако, укладывается в следующее уравнение:

$$w \propto \frac{\rho}{1-\rho} \cdot \frac{1}{\mu} \quad (2.12)$$

где μ - производительность сервера (Скорость передачи, относящаяся к количеству сообщений/единицу времени). ρ - это плотность трафика; мы также можем выразить это как отношение между скоростью входящих сообщений и производительностью $\rho = a/\mu$, а - это скорость входящих сообщений в единицу времени. Мы рассматриваем его как функцию интенсивности дорожного движения.

Если предположить, что область связи узла представляет собой контур радиуса R , то входящий трафик можно рассчитать как

$$a = 2R\eta v \quad (2.13)$$

где R - дальность связи (m), η - плотность транспортных средств, оснащенных сетевыми узлами ($1/m^2$), v - скорость транспортных средств (m/s).

Если система не имеет потерь, то это соответствует загрузке сервера. Если мы зададим значение задержки w , как показано в (2.12), использование зависит от значения производительности μ . Исходя из упомянутой выше взаимосвязи, мы можем быть уверены, что для достижения высокого уровня удобства использования нам необходимо увеличить производительность. Мы должны выбрать высокий трафик и высокие значения производительности, чтобы получить значительные преимущества. Эти условия соответствуют условиям звездно-структурированной сети.

Внедрение МЕС не является очень ресурсоэффективным решением. Использование МЕС обеспечивает относительно небольшое покрытие территории с относительно небольшим количеством пользователей, что означает относительно небольшой трафик и затраты на оборудование и персонал. Использование высокопроизводительного оборудования не является жизнеспособным решением, поскольку использование низкопроизводительного сервера негативно сказывается на качестве обслуживания. Эта проблема возникает из-за относительно небольшого трафика (количество пользователей) и нестабильного трафика.

Поэтому, когда мы используем решения МЕС для улучшения качества услуг, мы должны предложить решение для улучшения качества используемого оборудования. Ключевым моментом является предложение многоуровневой архитектуры для оптимизации использования оборудования для решений МЕС, как показано на рисунке 2.4.

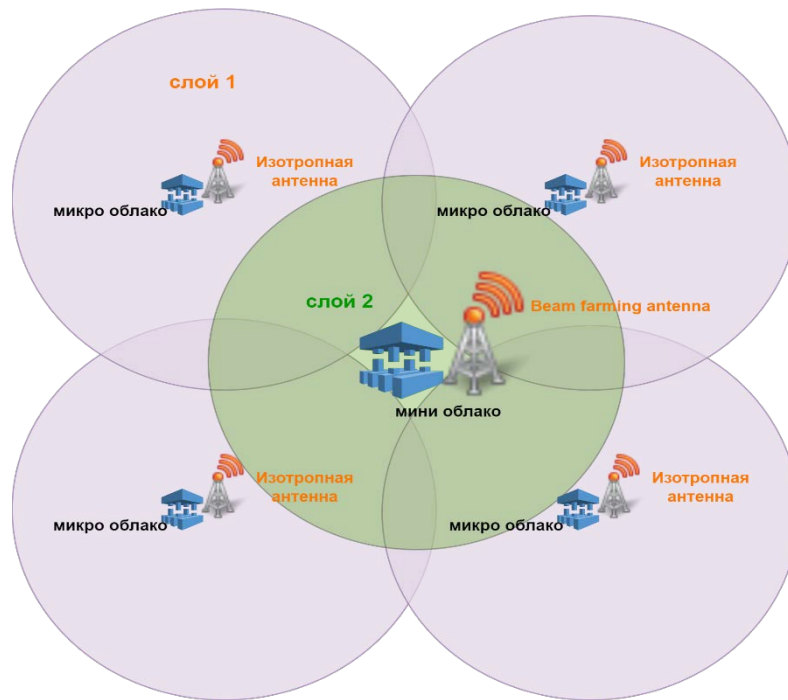


Рисунок 2.4 – Двухслойная структура МЕС

В этой структуре есть два слоя; первый слой состоит из системы МЕС, содержащей микроячейки или малые ячейки. Имеется изотропная базовая станция, где каждая ячейка оснащена необходимыми вычислительными ресурсами (облако). Соты будут обслуживать пользователей вокруг и рядом с антеннами. Второй слой МЕС сота имеет антенну с формированием луча. Эта сота может помочь любому абоненту в сотах первого уровня благодаря технологии формирования луча. Формирование луча улучшает использование пропускной способности беспроводной сети и дальность действия, а также повышает качество потокового видео, голоса и других приложений, чувствительных к пропускной способности, задержкам и джиттеру. Когда ресурсы первого уровня заняты, ячейка во втором слое обслуживает запросы абонентов. Если ресурсы первого слоя заняты, ячейка второго слоя обслуживает запросы абонентов.

Пусть трафик представляет собой пуассоновский поток, а экспоненциальное распределение описывает время обслуживания. Модель очереди в целом совместима с методом М/М/1/к с ограниченным буфером. Тогда вероятность того,

что входящая информация не попадет в систему (вероятность потери) определяется выражением:

$$p = \frac{1-\rho}{1-\rho^{n+2}} \rho^{n+1} \quad (2.14)$$

В этом уравнении $\rho = \frac{a}{\mu}$, где a - интенсивность входящих сообщений, а μ - интенсивность входящего трафика. В этом случае производительность сервера равна \bar{t} .

Следующее уравнение позволяет рассчитать средний размер очереди при $i=1$:

$$\bar{L} = \frac{\rho(1-(n+1)\rho^n + k\rho^{n+1})}{(1-\rho)(1-\rho^{n+1})} \quad (2.15)$$

Среднее время отклика первого слоя представлено следующим образом:

$$T = (\bar{L} + 1)\bar{t} \quad (2.16)$$

Сравнивая систему с ограниченным размером очереди с конструкцией с неограниченным размером очереди, мы вычисляем задержку системы М/М/1:

$$\bar{T}_m = \frac{\bar{t}}{1-\rho} \quad (2.17)$$

Для метода М/М/1, нагрузка на сервер достаточна для обеспечения трафика; для метода М/М/1/к, нагрузка на сервер может быть вычислена следующим образом:

$$u_i = 1 - P_0 \quad (2.18)$$

$$P_0 = \left\{ \frac{1}{n+1} \quad \rho_i = 1 \frac{1-\rho_i}{1-\rho_i^{n+1}} \quad \rho_i \neq 1 \right. \quad (2.19)$$

где P_0 - вероятность того, что сервер не работает в это время.

Предлагается модель реализации для МЕС с учетом вышеприведенного предположения о модели очереди. Чтобы увеличить использование метода МЕС (микро - или миниоблака), следует выбрать режим повышенного использования облака; однако это приведет к ухудшению QoS. Предлагается использовать несколько уровней, включая облака, предназначенные для обслуживания избыточного трафика, поступающего с соседних уровней. Такой метод работает по следующей схеме: коммуникации с регионом сетей автотранспорта, поступают в облако первого уровня, описываемое системой очередей М/М/1/к (первый уровень). Предполагается, что производительность облака μ_1 определяется временем обслуживания t_1 . И выбираем значение t на основе времени доставки T_0 и требований к нагрузке сервера.

В. Туманная среда

Fog предназначен в первую очередь для приложений и сервисов, которые плохо работают в архитектуре облачных вычислений или не могут в ней работать. В области IoT растущее развитие не может быть полностью поддержано только облачными решениями. При оценке IoT приходится сталкиваться с очисткой и предварительной обработкой данных перед отправкой их в Облако. Fog плодотворно взаимодействует с Облаком, особенно в администрировании данных и аналитике, порождая новый класс приложений. Архитектура вычислений Fog - это своего рода "прослойка" на границе между Облаком и устройствами IoT с датчиками и мобильными устройствами пользователей.

Потенциальная структура такой системы может быть представлена на рис.2. Система состоит из нескольких слоев. Эти слои могут иметь различные или

идентичные приложения. Например, базовая станция с изотропной антенной и микрооблаком полагается на транспортное средство для обслуживания входящих туманных запросов, которые должны быть выполнены как можно быстрее. Аналогично, следующий облачный слой помогает запросам, которые не были выполнены первым облаком и ожидают обслуживания. Облако 3-го уровня, реализованное на третьей базовой станции с направленной антенной, удовлетворяет требования по перегрузке трафика обоих нижних облаков.

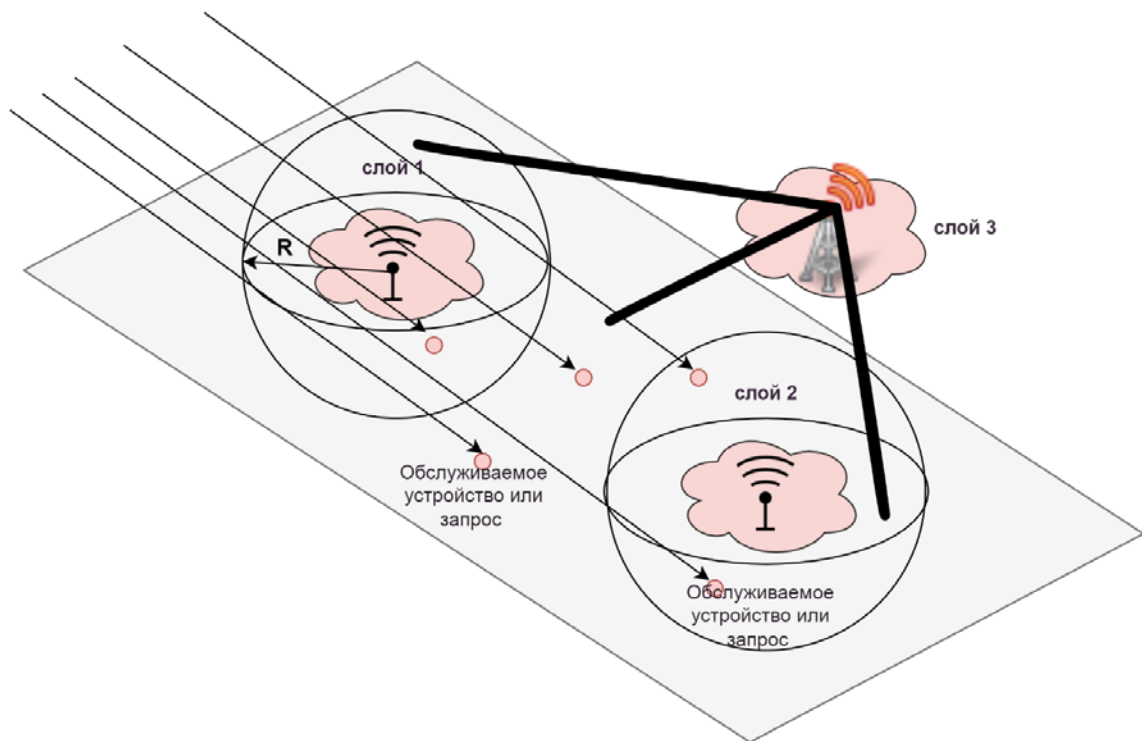


Рисунок 2.5 – Структура движущегося тумана

При моделировании результирующего трафика мы должны предложить модель тумана. Мы предполагаем, что туман - это поток устройств, движущихся в одном направлении (рис. 2.5). В общем случае каждое устройство может двигаться по своему пути, но этот случай нереален. Кроме того, мы предполагаем, что зона покрытия базовой станции - это сфера радиуса R . Мы предлагаем одно конкретное направление для всех устройств, находящихся в исследуемой области.

Эта перспектива включает в себя любое количество слоев. Слои могут быть реализованы в виде стационарных базовых станций на дороге или мобильных базовых станций на транспортном средстве или дроне.

Несколько систем, которые соединяют основное облако в течение времени Δt , это

$$n_1(\tau) = \frac{S}{2} v \tau \eta = 2\pi R^2 v \tau \eta, \quad (2.20)$$

где S - площадь сферы, v - скорость тумана (m/s), τ - интервал (секунды), η - количество устройств на единицу объема (плотность тумана), R - радиус сферы (метры).

$$n_i(\tau) = p_{i-1} n_{i-1}(\tau), \quad (2.21)$$

Где p_{i-1} - вероятность потери уровня i^l . Любая система может находиться в i^{th} облаке в случайный момент времени γ со средним значением

$$\bar{\gamma} = \frac{4R}{3v}. \quad (2.22)$$

Функция распределения вероятностей для γ описывается как в [2.23].

$$f(\gamma) = \frac{1}{2} \left(\frac{v}{R}\right)^2 \gamma, \quad 0 \leq \gamma \leq \frac{2R}{v} \quad (2.23)$$

$$F(\gamma) = \frac{1}{4} \left(\frac{v\gamma}{R}\right)^2 \quad 0 \leq \gamma \leq \frac{2R}{v} \quad (2.24)$$

Вероятность того, что система не работает на базовой станции равна вероятности того, что время удержания в зоне не будет больше, чем задержка T_m

$$p(\gamma \leq T_m) = F(T_m) = \frac{1}{4} \left(\frac{vT_m}{R} \right)^2, \quad 0 \leq T_m \leq \frac{2R}{v} \quad (2.25)$$

Красиво звучит представление этого метода как системы очередей, в которой заинтересованные запросы с несколькими приоритетами покидают очередь, прежде чем будут обслужены, если время задержки превышает время нахождения в зоне действия базовой станции. Однако, точного уравнения для этого метода не существует. Следовательно, мы можем предложить использовать метод очереди M/M/1/prio, при котором средняя задержка должна быть меньше T_m

Мы можем вычислить T_m из (20), используя формулу

$$T_m = \frac{2R}{v} \sqrt{p_0}, \quad (2.26)$$

когда p_0 - вероятность того, что время в области обслуживания меньше T_m , мы предполагаем, что p_0 - вероятность проигрыша на этом уровне.

Мы применяем метод M/M/1/prio для демонстрации задержки на каждом слое:

$$\bar{W}_i = \frac{\sum_{j=1}^M \rho_j \bar{t}_j}{(1-R_{i-1})(1-R_i)}, \quad i = 1, \dots, M \quad (2.27)$$

$$R_i = \sum_{j=1}^i \rho_j, \quad R_{i-1} = \sum_{j=1}^{i-1} \rho_j \quad (2.28)$$

где M - номер приоритета; ρ_j - интенсивность j -го приоритетного трафика, \bar{t}_j - среднее время обслуживания j -го приоритетного запроса.

При определении плана с помощью многоуровневого МЕС, основанного на этом методе, мы должны выбрать параметры пути; таким образом, они могут удовлетворять следующему условию

$$\bar{W}_i + \bar{t}_i < T_m \quad (2.29)$$

Дисбаланс заключается в том, что средняя задержка меньше времени в зоне действия базовой станции с вероятностью $1-p_0$. Если p_0 невелика, то (2.29) означает, что, как правило, запросы i -го приоритета обслуживаются в зоне действия базовой станции.

Используя (2.26), (2.27) и (2.29), мы можем сделать оценку требуемой производительности \bar{t}_j Для каждого приоритета и количества облаков (слоев).

2.4 Имитационная модель

Структура моделируемой сети представляет собой некую реализацию метода очередей.

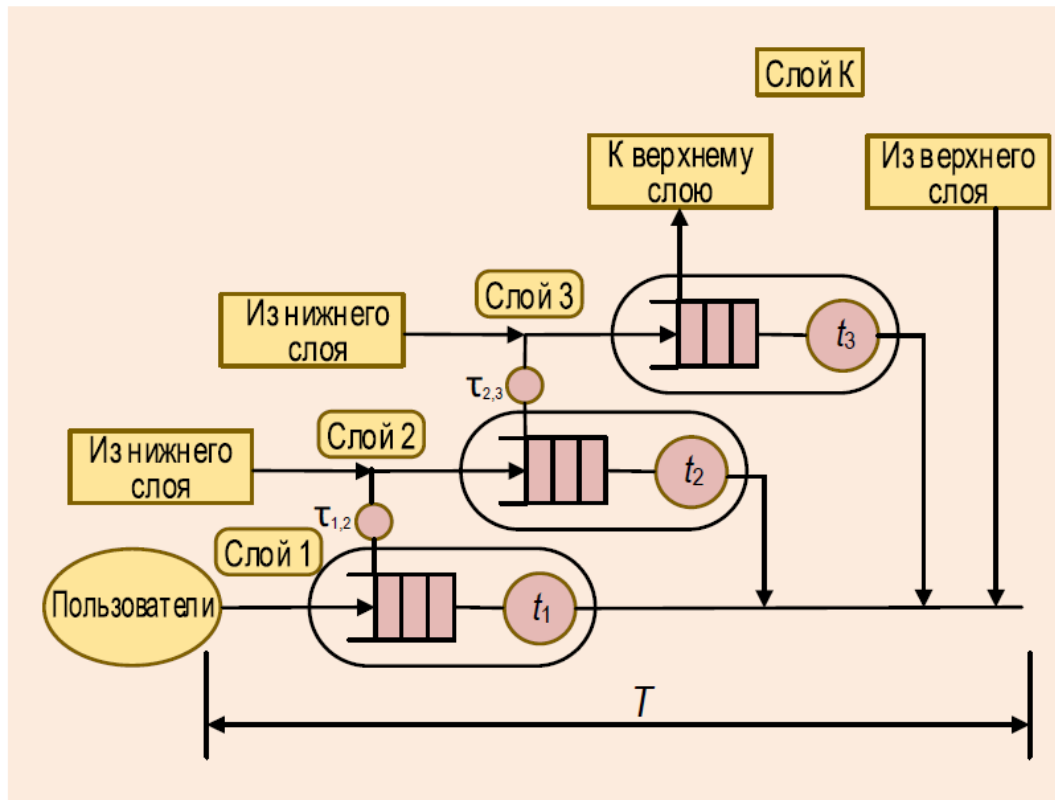


Рисунок 2.6 – Структура сети

Каждый слой модели состоит из одного сервера и одной очереди, и каждая очередь имеет два выхода и только один вход. Вход очереди принимает входящую информацию от этого слоя. Выходом является верхняя часть очереди, подключенная к серверу. Если некоторые запросы не были удовлетворены на данном уровне (потерянные рекомендации), они выходят из очереди и продолжают поступать на следующий уровень через этот выход. Существуют разные причины, по которым запросы не были обслужены от одной среды к другой. Для среды сетей автотранспорта использовалась следующая структура модели: каждый слой описывает стационарную ячейку базовой станции и потерянные запросы из-за чрезмерного трафика в первом случае; во втором случае потери вызваны слишком большой задержкой, превышающей T_m .

Обычно в этих двух случаях можно использовать несколько приоритетных запросов. Тем не менее, предполагалось, что все пакеты (сообщения) в среде сетей автотранспорта однородны, и из-за этого использовались не приоритетные очереди.

2.5 Результаты моделирования

Осуществляется прогнозирование трафика на основе подхода глубокого обучения с использованием BILSTM и LSTM сетей для автономных транспортных средств с многоуровневыми облачными вычислениями. Точность прогнозирования измерялась с помощью RMSE, MAPE, R² и времени обработки, с использованием функции потерь MSE и скорости обучения 0,1. Было проведено сравнение между BI-LSTM и однонаправленной LSTM с использованием RMSE, MAPE, R² и времени обработки при различных размерах для среды сетей автотранспорта. Наборы данных для обучения были получены из многоуровневых облачных вычислений с поддержкой автономного транспорта. Задача была выполнена с помощью MATLAB, так как набор данных был собран и обработан, он был разделен на 70 и 30 % для обучения, а также 30 % для тестирования.

Для расчета точности прогнозирования применялись математические формы для RMSE, MAPE и R², как описано в уравнениях (2.30), (2.31) и (2.32):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.30)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{x_t} \right| \quad (2.31)$$

$$R^2 = 1 - \frac{SS_{Regression}}{SS_{Total}} = 1 - \frac{\sum_i (y_i - \hat{y}_i)}{\sum_i (y_i - \underline{y}_i)} \quad (2.32)$$

где N - общее число наблюдений, y_i - фактическое значение, \hat{y}_i - предсказанное значение, \bar{y}_i - среднее значение всех значений. SS_{Total} - сумма общих квадратичных ошибок, а $SS_{Regression}$ - сумма квадратичных ошибок регрессии.

В таблице 2.1 показана точность прогнозирования скорости трафика в случае использования среды сетей автотранспорта при трех различных частях обучающей выборки (BatchSizes) с точки зрения использования двух различных BI-LSTM и LSTM-моделей с учетом функции потерь MSE в качестве меры производительности и скорости обучения 0,1. Чтобы исследовать модель прогнозирования, которая обеспечивает парадигмальную точность и максимальное среднее улучшение, масштабировалась точность прогнозирования с помощью среднеквадратичной ошибки (RMSE, аббр. от англ. Root Mean Square Error), средней абсолютной процентной ошибки (MAPE, аббр. от англ. Mean Absolute Percentage Error) и коэффициента детерминации R^2 .

Таблица 2.1 – Точность прогнозирования трафика в среде сетей автотранспорта

Часть выборки	BI-LSTM				LSTM			
	RMSE	MAPE%	R^2	Время обработки	RMSE	MAPE%	R^2	Время обработки
8	0.0241	2.9902	0.9959	44.5000	0.0547	5.1858	0.9862	27.7969
16	0.0350	4.3937	0.9958	39.8750	0.0954	10.3052	0.9732	28.6563
64	0.0943	10.8848	0.9721	25.1094	0.1379	15.3204	0.9436	36.1719

Как видно из результатов в таблице 2.1, при использовании BatchSizes = 8 точность прогнозирования превосходит конкурентов и имеет наилучшие показатели для BI-LSTM и LSTM сетей.

Соответственно, максимальное среднее улучшение в обоих случаях составляет 7.9 и 10.135 %. Однако это занимает больше всего времени обработки для BI-LSTM и быстрее всего для LSTM. Точность прогнозирования при BatchSizes = 16 примерно такая же, как и при BatchSizes = 8. В этом случае

максимальное среднее улучшение составляет 6.5 и 5.12 % соответственно для BI-LSTM и LSTM. Однако, точность прогнозирования при использовании BatchSizes = 64 достаточно низкая по сравнению с другими, хотя имеет самое быстрое время обработки для BI-LSTM, но самое длительное для LSTM. Кроме того, коэффициент детерминации R^2 примерно одинаков в обоих случаях и близок к 1, что указывает на хорошее соответствие. С другой стороны, точность прогнозирования с помощью BI-LSTM выше, чем у LSTM во всех случаях, а максимальное среднее улучшение BI-LSTM по сравнению с LSTM во всех случаях: 2.2, 5.9 и 4.4 %, соответственно.

На рисунках 2.7 показаны результаты прогнозирования для различных частей выборки Batch Size в BI-LSTM и LSTM-моделях: кривые (слева) представляет собой вероятности ошибки прогнозирования скорости трафика, а гистограммы (справа) – вероятности потери с течением времени (в секундах).

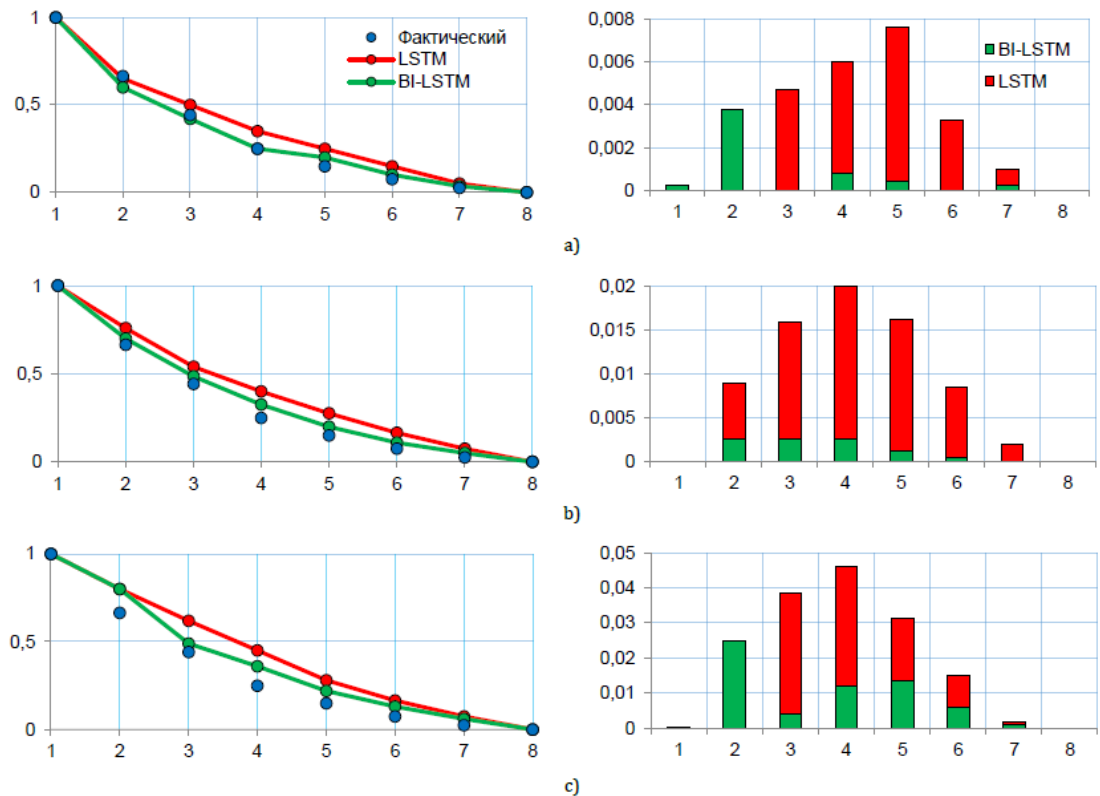


Рисунок 2.7 – Прогнозирование выходных паттернов в случае использования BatchSize, равной: а) 8, б) 16 и в) 64

В таблице 2.2 показана точность прогнозирования скорости трафика в случае использования среды движущегося тумана при трех различных частях обучающей выборки (BatchSizes) с точки зрения использования двух различных BI-LSTM и LSTM-моделей с учетом функции потерь MSE в качестве меры производительности и скорости обучения 0,1. Чтобы исследовать модель прогнозирования, которая обеспечивает парадигмальную точность и максимальное среднее улучшение, масштабировалась точность прогнозирования с помощью RMSE MAPE и R^2 .

Таблица 2.2. Точность прогнозирования трафика в среде движущегося тумана

Часть выборки	BI-LSTM				LSTM			
	RMSE	MAPE%	R^2	Время обработки	RMSE	MAPE%	R^2	Время обработки
8	0.0039	0.3615	0.9999	25.5313	0.0186	1.4719	0.9972	29.5156
16	0.0539	4.1281	0.9772	36.4375	0.0768	6.6099	0.9669	27.2188
64	0.0874	7.5498	0.9593	45.7031	0.1127	9.9158	0.9529	44.6406

Как видно из результатов в таблице 3, при использовании BatchSizes = 8 точность прогнозирования превосходит конкурентов и имеет наилучшие показатели для BI-LSTM и LSTM сетей.

Соответственно, максимальное среднее улучшение в обоих случаях составляет 7,2% и 8,4%. Кроме того, для BI-LSTM требуется самое быстрое время обработки. Точность прогнозирования при BatchSizes = 16 примерно такая же, как и при BatchSizes = 8. В этом случае максимальное среднее улучшение составляет 3,8% и 5,14% соответственно для BI-LSTM и LSTM. Однако, точность прогнозирования при использовании BatchSizes = 64 достаточно низкая по сравнению с другими, хотя имеет самое быстрое время обработки для BI-LSTM, но самое длительное для LSTM. Кроме того, коэффициент детерминации R^2 примерно одинаков в обоих случаях и близок к 1, что указывает на хорошее соответствие. С другой стороны, точность прогнозирования с помощью BI-LSTM выше, чем у

LSTM во всех случаях, а максимальное среднее улучшение BI-LSTM по сравнению с LSTM во всех случаях: 1,11%, 2,5% и 2,4%, соответственно.

На рисунках 2.8 показано, что модели прогнозирования на основе BI-LSTM и LSTM незначительно отличаются от идеальной модели. Более того, BI-LSTM имеет меньшие потери, чем LSTM, а самые высокие потери наблюдаются при 2s и 3s для 16 и 64 размеров лота.

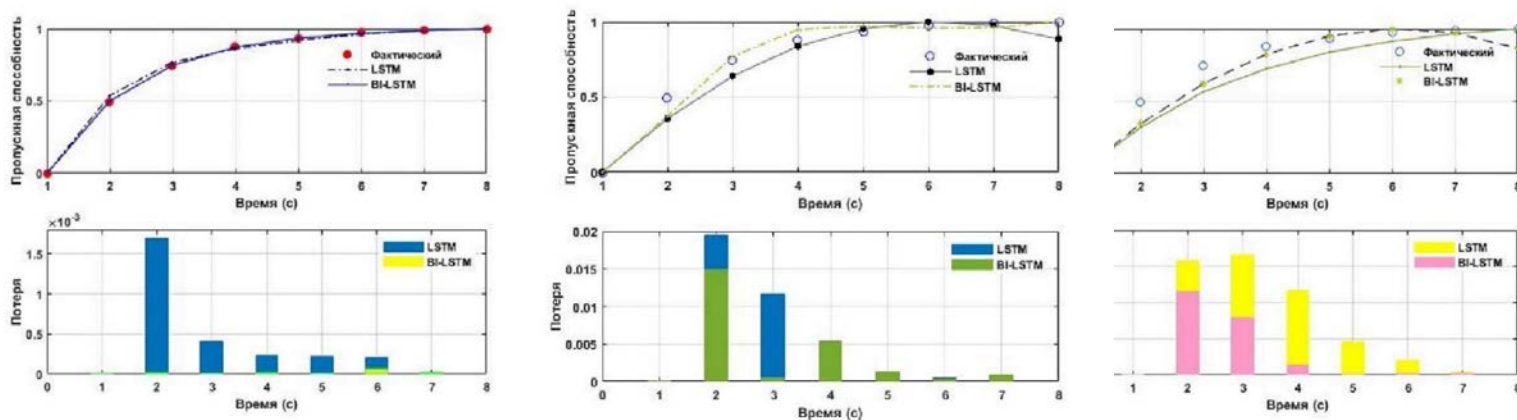


Рисунок 2.8. – Прогнозирование выходных паттернов в случае использования BatchSize, равной: а) 8, б) 16 и в) 64

Результаты моделирования точности прогнозирования показывают, что BI-LSTM-предсказатель превосходит LSTM-предсказатель во всех случаях. При использовании 8 частей выборки точность прогнозирования превосходит конкурентов с наилучшими показателями для BI-LSTM и LSTM сетей. Для 64 частей выборки точность прогнозирования низкая по сравнению с другими. Коэффициент детерминации (R^2) примерно одинаков в обоих случаях и близок к 1, что означает, что сеть хорошо подогнана.

В среде сетей автотранспорта, при использовании 64 частей выборки, модель BI-LSTM имеет самое быстрое время обработки и самое медленное время обработки при использовании 8 частей выборки. В среде тумана, модель BI-LSTM имеет самое быстрое время обработки при использовании 8 частей выборки, а

модель LSTM имеет самое быстрое время обработки при использовании 16 частей выборки но, самое медленное время обработки при использовании 64 частей выборки.

2.7 Выводы по главе 2

1. Были предложены методы глубокого обучения с использованием BI-LSTM и LSTM для прогнозирования трафика в автономных транспортных средствах с многоуровневыми облачными вычислениями.

2. Выполнено прогнозирование в двух средах: в среде сетей автотранспорта и в среде тумана.

3. Точность прогнозирования трафика измерялась с помощью RMSE, MAPE, R^2 и времени обработки, с использованием функции потерь MSE и скорости обучения 0,1.

4. Было проведено сравнение между BI-LSTM и однонаправленной LSTM с использованием RMSE, MAPE, R^2 и временем обработки при различных частях выборки в двух средах: в среде сетей автотранспорта и в среде тумана.

5. Наборы данных для обучения были получены из многоуровневых облачных вычислений с поддержкой БА.

6. Исследование было выполнено с использованием MATLAB. Так как набор данных был собран и обработан, он был разделен на 70%, 30% для обучения и 30% для тестирования.

ГЛАВА 3 МЕТОД ПРОГНОЗИРОВАНИЯ СКОРОСТИ ДВИЖЕНИЯ АВТОТРАНСПОРТА В ЗОНАХ С ИНТЕНСИВНЫМ ДВИЖЕНИЕМ НА ОСНОВЕ ДВИЖУЩЕГО ЛЕТАЮЩЕГО ТУМАНА И МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

3.1 Введение

В последнее время автономные транспортные средства завоевали популярность, поскольку они оказывают большое влияние на общество, повышая безопасность и комфорт, снижая расход топлива, уменьшая количество пробок и аварий, экономя затраты и повышая надежность. Тем не менее, до сих пор существуют некоторые функциональные недостатки автономных транспортных средств, которые необходимо устранить, прежде чем они смогут быть полностью развернуты на основных автомагистралях. Прогнозирование транспортного потока важно для автономного транспорта, чтобы определить свой маршрут и принимать адаптивные решения относительно окружающей среды. Глубокое обучение - это мощный метод для разработки адаптивных и прогнозирующих систем, который также успешно используется в автомобильных сетях. В данном разделе мы предлагаем подход глубокого обучения с использованием стековой двунаправленной модели долговременной краткосрочной памяти (SBILSTM) для прогнозирования движения транспортных средств в местах с интенсивным движением на основе летающих туманных вычислений. С точки зрения точности прогнозирования проводится сравнение между предложенной моделью SBILSTM и обычными моделями BILSTM и LSTM. Точность прогнозирования рассчитывается с помощью среднеквадратичной ошибки (RMSE), средней абсолютной процентной

ошибки (MAPE), коэффициента детерминации (R-квадрат) и времени обработки. Результаты показывают, что точность прогнозирования с помощью предложенной SBILSTM превосходит традиционные модели BILSTM и LSTM.

С появлением 5G и последующих технологий отрасль переходит от подключенных автомобилей к автономному вождению и автономному транспортному средству, что позволяет предоставлять новые услуги. Фундаментальными проблемами являются обработка и хранение больших объемов данных, генерируемых постоянно растущим количеством датчиков в БА, а также обеспечение реального времени и надежности сети, при этом ключевые позиции занимают Fog и edge computing. В рамках развития концепции автономных транспортных средств и их инфраструктуры необходимо решить проблему дополнительных внешних вычислительных мощностей, необходимых для распределения вычислений цифровых моделей дорог. Это происходит при большом скоплении автомобилей и, в принципе, всех движущихся управляемых объектов. Учитывая технологические преимущества сетей 5G, описанные выше, особенно метод разгрузки и Fog computing, есть возможность реализовать нашу задачу. Когда требуется дополнительная энергия, собирается сеть летающих дронов, которые должны находиться на соответствующем участке дороги с высоким трафиком [78]. Мы можем определить количество дронов, необходимых для данного участка, и местоположение вычислительного летающего тумана для обеспечения необходимой вычислительной мощности.

В настоящее время БА стали новой областью изучения искусственного интеллекта (AI), и ожидается, что их популярность будет расти. Мы все еще находимся на ранних стадиях развития самоуправляемых автомобилей, но технология быстро совершенствуется. Ожидается, что технология самодвижения окажет значительное влияние на автомобильную промышленность. Она обеспечивает безопасное вождение за счет автоматического управления транспортными средствами. Это снижает аварийность на дорогах и экономические

затраты, а также является более безопасной альтернативой водителям-людям. Автомобиль без водителя способный безопасно и эффективно ездить без помощи человека-водителя - это БА. Среди многих потенциальных преимуществ автономного вождения - повышение безопасности, эффективности и комфорта. Например, БА могут помочь снизить количество дорожно-транспортных происшествий, заторов и вредных выбросов. Хотя технология все еще совершенствуется, несколько компаний уже проводят испытания автономных автомобилей на дорогах общего пользования. По мере развития технологий мы можем ожидать, что в ближайшие годы на дорогах будет появляться все большее количество автомобилей.

С развитием транспортных средств растет и потребность в машинном обучении (ML). Чтобы быть полностью автономными, БА должны выполнять множество задач. К ним относятся обнаружение и объезд препятствий, соблюдение правил дорожного движения и принятие решений в зависимости от меняющихся условий. Каждая из этих задач представляет собой уникальный вызов, который должен быть преодолен системой ML. Чтобы разработать БА, способный выполнять все эти задачи, инженеры должны сначала создать систему, которая сможет взаимодействовать с различными системами ML и понимать их. Это непростая задача, поскольку каждая система предназначена для выполнения конкретной задачи и может использовать различные форматы данных и стандарты. Однако это необходимо для разработки полностью БА. Такое большое количество задач, которые ML должен объединить, представляет собой уникальный вызов.

ML - это ветвь искусственного интеллекта (AI), которая анализирует и интерпретирует шаблоны и структуры данных для обеспечения обучения, рассуждений и принятия решений без участия человека. В машинном обучении пользователи могут снабжать компьютерный алгоритм большим количеством данных и позволять ему принимать решения на основе данных. Алгоритм может использовать корректировки для улучшения будущих решений. Машинное

обучение (ML) - одна из самых важных и популярных развивающихся отраслей (AI) сегодня. В последнее время машинное обучение стало важной и развивающейся областью исследований для инженерии дорожного движения, особенно для прогнозирования дорожного движения. Дорожные заторы оказывают прямое или косвенное влияние на экономику. Каждый день из-за пробок на дорогах тратится драгоценное время и топливо. Поскольку заторы на дорогах являются серьезной проблемой для всех слоев общества, необходимо мелкомасштабное прогнозирование дорожного движения, чтобы люди могли жить без разочарования и напряжения. В обеспечении экономического роста страны главным приоритетом должно быть снижение загруженности дорог. Это возможно только при условии быстрого движения транспорта. Поэтому для оценки или прогнозирования дорожного движения нам необходимы прогнозы движения.

В последнее время многие исследователи приложили большие усилия и сосредоточились на прогнозировании трафика беспроводных сетей в автономных транспортных средствах на основе вычислений летающего тумана. Данная работа посвящена прогнозированию трафика в автономных транспортных средствах в оживленных районах с помощью вычислений на основе летающего тумана с использованием подхода глубокого обучения на основе SBILSTM. Поэтому в этом разделе представлены предыдущие работы, имеющие отношение к нашей области.

Abdellah и др. [27] предложили однонаправленный алгоритм глубокого обучения на основе LSTM для прогнозирования сетевого трафика V2X в зависимости от пакетов, отправляемых в секунду. В [28] обсуждались как ML, так и статистические методы для прогнозирования сетевого трафика. Исследование показывает, что большинство существующих решений неэффективны в реальных приложениях из-за особенностей обработки сетевых данных в современных сетевых технологиях, таких как теория сетей, проблема переобучения и "земляная правда". В [29] исследователи разрабатывают приложение для Android, которое удовлетворяет потребность пользователей видеть трафик в реальном времени,

используя IoT, машинное обучение и расширенные API на основе GPS. API собирают данные с помощью краудсорсинга и накапливают местоположение пользователя в реальном времени на серверах с помощью микросервисов. Приложение для Android основано на механизме сбора данных о трафике в режиме реального времени с использованием передовых облачных API, IoT, машинного обучения и облачных вычислений.

В [30] исследователи сосредоточились на полном изучении экспериментальных характеристик и оценок архитектуры глубокого обучения нейронной сети для обнаружения семи категориальных атак, обнаруженных в наборе данных трафика Distributed Smart Space Orchestration System. В [31] была разработана новая система прогнозирования трафика в плотно развернутых сетях IoT на основе искусственного интеллекта (AI). Это облегчает управление трафиком и позволяет избежать перегруженности сети. Разработанный алгоритм AI представляет собой модель глубокого обучения на основе сверточной нейронной сети, которая является легким алгоритмом, который может быть реализован распределенным вычислительным узлом на границе, таким как узел Fog, с ограниченными вычислительными мощностями.

В [32] основной целью было изучение пробелов в роли ML в сервисах и системах вычислений Fog. В работе представлено участие ML в трех аспектах Fog computing: Управление ресурсами, Точность и Безопасность. Результат показывает, что ML оказывает значительное влияние на улучшение приложений и услуг Fog computing. В работе [33] исследована роль ML в Fog Computing и представлено участие ML в трех аспектах Fog Computing: улучшение парадигмы, безопасность и конфиденциальность, а также прикладные решения. Наиболее распространенными методами ML являются статистические алгоритмы или алгоритмы контролируемого обучения. В [34, 35] исследовалось долгосрочное и краткосрочное прогнозирование трафика беспроводной сети с помощью LSTM-сети с поддержкой глубокого обучения.

Основные вклады в этом разделе:

- для прогнозирования движения транспортных средств в зонах с интенсивным движением на основе вычислительной среды тумана был предложен подход глубокого обучения с использованием стековой двунаправленной модели долговременной краткосрочной памяти (SBILSTM);
- было проведено сравнение между предложенной SBILSTM и традиционными BILSTM и LSTM для точности прогнозирования;
- модели глубокого обучения были обучены с использованием метода оптимизации Адама, частоты выборки 16, функции потерь MSE и скорости обучения 0,1;
- мы оценивали точность прогнозирования с помощью среднеквадратичной ошибки (RMSE), средней абсолютной процентной ошибки (MAPE), коэффициента детерминации (R-квадрат) и времени обработки.

Окончательные результаты моделирования показали следующее:

- предложенная модель SBILSTM превосходит своих конкурентов и имеет наилучшую производительность;
- при использовании обычной модели BILSTM точность прогнозирования выше, чем у модели LSTM;
- точность прогнозирования при использовании традиционной модели LSTM низкая по сравнению с другими;
- коэффициент детерминации (R^2) примерно одинаков во всех случаях и близок к 1, что означает, что сеть настроена правильно;
- традиционная BILSTM имеет самое короткое время процесса, в то время как предложенная SBILSTM имеет самое длинное время процесса.

3.2 Постановка задачи

Стековая BILSTM является надежным методом для решения сложных задач прогнозирования последовательности. Архитектура стековой LSTM - это модель BILSTM, состоящая из нескольких слоев. Вышележащий слой BILSTM посылает нижележащему слою BILSTM последовательность значений, а не одно значение. Один выходной сигнал на каждый шаг входного времени, в отличие от одного выходного сигнала на все шаги входного времени.

Архитектура сетей LSTM была первоначально разработана Хохрайтером и Шмидхубером. Более формально, задан вектор входной последовательности $x = (x_1, x_2, \dots, x_n)$, где n обозначает длину входного предложения. Основной структурой LSTM является использование трех управляющих ворот для управления вектором активации ячеек памяти s . Первые ворота забывания определяют, какая часть состояния ячейки s_{t-1} в предыдущий момент времени сохраняется до текущего состояния ячейки; вторые входные ворота определяют, в какой степени вход x_t сети сохраняется до текущего состояния ячейки; третьи выходные ворота определяют, какая часть состояния ячейки передается в текущее выходное значение сети LSTM. Три гейта представляют собой полностью подключенный слой, вход которого - вектор, а выход - вещественное число в $[0, 1]$.

Основная архитектура ячейки LSTM показана на рисунке 3.2, а ее представление выглядит следующим образом:

$$it = \sigma(Wi xt + Ui ht- 1 + bi), \quad (3.1)$$

$$ft = \sigma(Wf xt + Uf ht- 1 + bf) \quad (3.2)$$

$$ot = \sigma(Wo xt + Uo ht- 1 + bo) \quad (3.3)$$

$$ct = ft * ct-1 + it * \tanh(Wc xt + Uc ht-1 + bc) \quad (3.4)$$

$$h_t = ot * \tanh(ct), \quad (3.5)$$

где σ - логистическая сигмоидная функция, x_t обозначает вектор t -го слова предложения, h_t означает скрытое состояние, термины W и b представляют весовые матрицы, соответственно (например, W_f представляет весовую матрицу забытых ворот), и векторы смещения (например, b_i представляет вектор смещения входных ворот) для трех ворот.

Чтобы преодолеть недостаток одной ячейки LSTM, которая может улавливать только предыдущий контекст, но не может использовать будущий контекст, Шустер и Паливал изобрели двунаправленные рекуррентные нейронные сети (BRNN), которые объединяют два отдельных скрытых слоя LSTM с противоположными направлениями к одному выходу. Благодаря такой структуре выходной слой может использовать связанную информацию как из предыдущего, так и из будущего контекста. BiLSTM вычисляет входную последовательность $x=(x_1, x_2, \dots, x_n)$ с противоположного направления к прямой скрытой последовательности $\vec{h}_t = ((\vec{h}_1, \vec{h}_2, \dots, \vec{h}_n)$, и обратная скрытая последовательность $\overleftarrow{h}_t = (h_1^{\leftarrow}, h_2^{\leftarrow}, \dots, h_n^{\leftarrow})$, и y_t Это векторы для прямого, обратного и выходного слоев. W - весовые коэффициенты. \vec{b} , b^{\leftarrow} и b_y - соответствующие векторы смещения.

$$\vec{h}_t = H(W_1 x_t + W_2 \vec{h}_{t-1} + \vec{b}) \quad (3.6)$$

$$h_t^{\leftarrow} = H(W_3 x_t + W_5 h_{t-1}^{\leftarrow} + b^{\leftarrow}) \quad (3.7)$$

$$y_t = W_4 \vec{h}_t + W_6 h_t^{\leftarrow} + b_y \quad (3.8)$$

где $y = (y_1, y_2, \dots, y_t, \dots, y_n)$ - выходная последовательность первого скрытого слоя.

Некоторые предыдущие работы показали, что путем объединения нескольких BiLSTM в нейронные сети можно дополнительно улучшить производительность классификации и регрессии. Более того, существует ряд теоретических доказательств того, что глубокая иерархическая модель более эффективна в представлении некоторых функций, чем неглубокая. Мы определили стековую сеть BiLSTM, где выход y_t из нижнего слоя становится входом верхнего слоя. Структура стековой BiLSTM показана на рисунке 3.2:

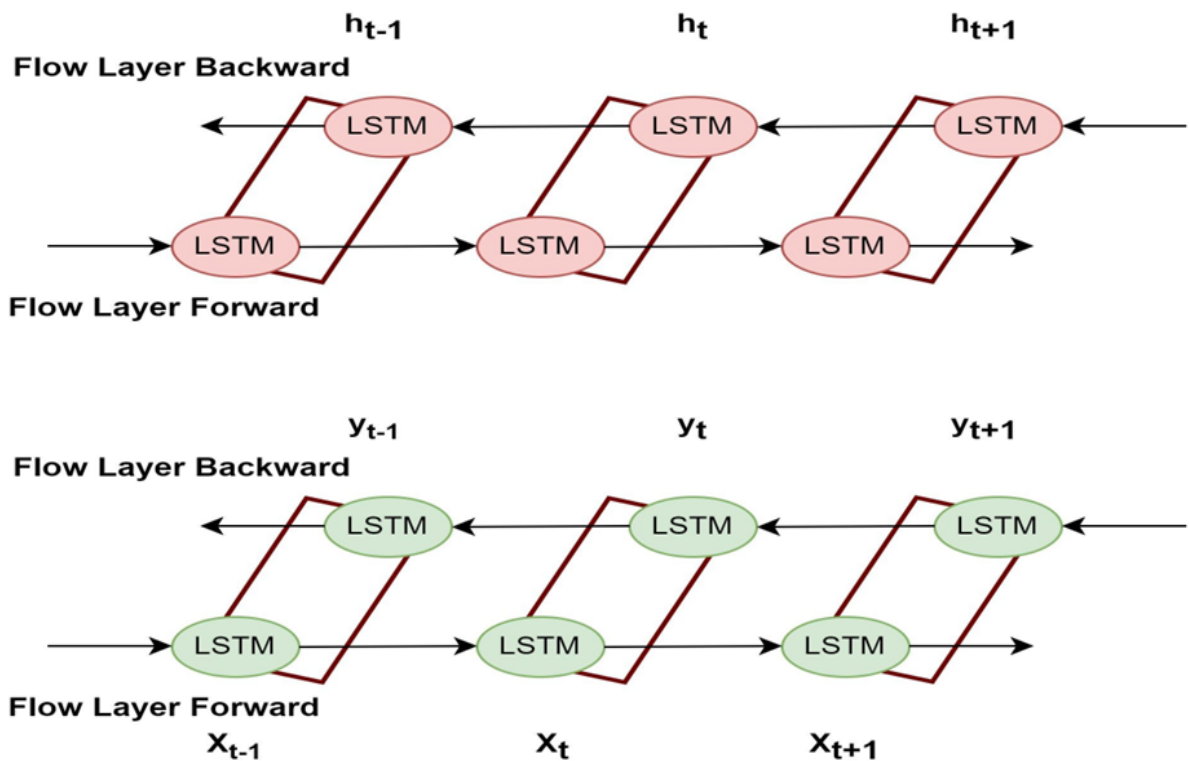


Рисунок 3.2 – Структура стековой BiLSTM(SBiLSTM)

3.3 Предлагаемое решение

Общая архитектура метода разгрузки трафика в местах с высокой интенсивностью движения основана на вычислениях "движущего летающего тумана"

В приведенных выше разделах определены технологические тенденции в вычислениях Fog, довольно подробно описаны возможности этих технологий, а в отдельном разделе описана проблема, решение которой является целью данной диссертации.

Поставленная задача заключается в определении количества летающих туманов, а также расположения этих вычислительных летающих туманов для обеспечения необходимой вычислительной мощности.

При большом скоплении автомобилей и, в принципе, всех движущихся управляемых объектов (например, велосипедов, пешеходов и т.д.), необходимо обеспечить дополнительную вычислительную мощность снаружи (относительно самих объектов) для распределения вычислений цифровой модели дороги.

Для этого, когда требуется дополнительная пропускная способность, создается сеть летающих дронов, которые размещаются в соответствующих местах на дороге, где наблюдается высокая интенсивность движения. в данном разделе мы предлагаем использовать вычисления на основе летающего тумана для обеспечения необходимой вычислительной мощности.

На рисунке 3.3 показана общая архитектура, включающая элементы физического мира (автомобили, дороги, беспилотники и т.д.). Как уже было показано на практике, при всех доступных сегодня вычислительных возможностях и технологиях, БА необходимо обеспечить дополнительную внешнюю вычислительную мощность (относительно самих объектов) для распределения

вычислений цифровой модели дороги при наличии большого скопления автомобилей или движущихся управляемых объектов.




Рисунок 3.3 – Общая архитектура модели системы

На рисунке выше показаны элементы, которые присутствуют и могут взаимодействовать друг с другом. Чтобы выяснить, сколько вычислительной мощности требуется для этих элементов, мы предложили решение проблемы, отправив группу дронов в район, где наблюдается перегрузка для этих элементов. Мы собрали данные для нескольких возможных случаев и записали их в скрипт Python, одним из которых был случай, когда конкретный участок дороги был выбран на определенный период. Результаты программирования этих данных позволили нам определить количество и расположение беспилотников, необходимых для этой дороги.

3.4 Результаты моделирования

В этом разделе мы выполняем прогнозирование трафика с помощью подхода глубокого обучения с использованием предложенной SBILSTM и традиционных BILSTM и LSTM сетей для БА в зонах с высоким трафиком на основе летающих туманных вычислительных сред. Точность прогнозирования оценивалась с помощью RMSE, MAPE, R2 и времени обработки, с MSE в качестве функции потерь и скоростью обучения 0,1. Было проведено сравнение между SBILSTM и традиционными моделями на основе RMSE, MAPE, R2 и времени обработки.

Мы смоделировали систему автономного транспорта с помощью программы Python для создания обучающего набора данных глубокого обучения. Мы также использовали программу MATLAB для моделирования прогнозирования трафика с помощью модели глубокого обучения. После сбора и обработки набор данных для прогнозирования был подан в модель глубокого обучения, а затем разделен на 70% для обучения и 30% для тестирования.

Для расчета точности прогнозирования использовались математические формы для RMSE, MAPE и R^2 , как описано в уравнениях (9), (10) и (11).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.9)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{x_t} \right| \quad (3.10)$$

$$R - squared = 1 - \frac{SS_{Regression}}{SS_{Total}} = 1 - \frac{\sum_i (y_i - \hat{y}_i)}{\sum_i (y_i - \underline{y}_i)} \quad (3.11)$$

где N - общее число наблюдений, y_i - фактическое значение, \hat{y}_i - предсказанное значение, \bar{y}_i - среднее значение всех значений. SS_{Total} - сумма общих квадратичных ошибок, $SS_{regression}$ - сумма квадратичных ошибок регрессии.

Таблица 3.1 – Точность прогнозирования скорости движения в условиях летающего тумана

Оптимизатор Adam; Часть выборки 16; эпохи 500				
RNNs	RMSE	MAPE	R-squared	Время обработки
Staked BILSTM	1.26	10.87	0.99	285.09
BI-LSTM	1.28	11.04	0.98	70.28
LSTM	1.54	13.13	0.98	179

В таблице 3.1 показана точность прогнозирования для трафика тумана при использовании глубокого обучения, когда используются три различные модели: стековая BILSTM, BILSTM и LSTM, с использованием метода оптимизации Адама, частей выборки 16, функции потерь MSE и скорости обучения 0,1. Точность прогнозирования оценивалась с помощью RMSE, MAPE и R2.

Из приведенной выше таблицы видно, что модель, предсказанная с помощью стековой BILSTM модели, превосходит своих конкурентов и имеет наилучшие показатели. В обоих случаях максимальное среднее улучшение составляет 2,26%. Однако у модели SBILSTM самое длительное время обработки. Точность прогнозирования модели BILSTM примерно такая же, как и у модели SBILSTM. В этом случае максимальное среднее улучшение составляет 2,09%, и она также имеет самое быстрое время обработки по сравнению с другими моделями. Однако точность прогнозирования модели LSTM невысока по сравнению с другими моделями, хотя время обработки у нее быстрее, чем у модели BILSTM. Более того,

коэффициент детерминации (R^2) близок к 1, что указывает на хорошее соответствие, и во всех случаях он примерно одинаков.

На рисунках 3.4 есть предсказанные модели в которых две кривые: одна показывает прогнозирование во времени, а другая - потери при обучении во времени. Как видно из рисунков, модели прогнозирования предложенной стековой BILSTM и BILSTM примерно одинаковы и уменьшаются со временем. Однако модель прогнозирования с LSTM увеличивается до значения 9 с, а затем случайным образом уменьшается. Кроме того, потери со временем на второй кривой показывают, что модель LSTM имеет самые высокие потери по сравнению с другими моделями при 9с, а в случае использования стековой BILSTM и BILSTM при 44 с и 49 с, соответственно.

Гистограммы на рисунках 3.5 показывают зависимость между скоростью трафика и значениями MSE. Мы отмечаем, что при использовании стековой BILSTM и BILSTM модели уровень трафика составляет 14% и 15%, соответственно, при значениях MSE от 0 до 0,12, а при использовании модели LSTM самый высокий уровень трафика составляет 29%, при значениях MSE от 0 до 0,071.

На рисунке 3.6 показана зависимость между потерями при обучении и количеством итераций во время обучения, причем все потери уменьшаются по мере увеличения количества итераций.




Рисунок 3.4.а – Прогнозируемый выходной сигнал с использованием предложенной стековой модели BILSTM

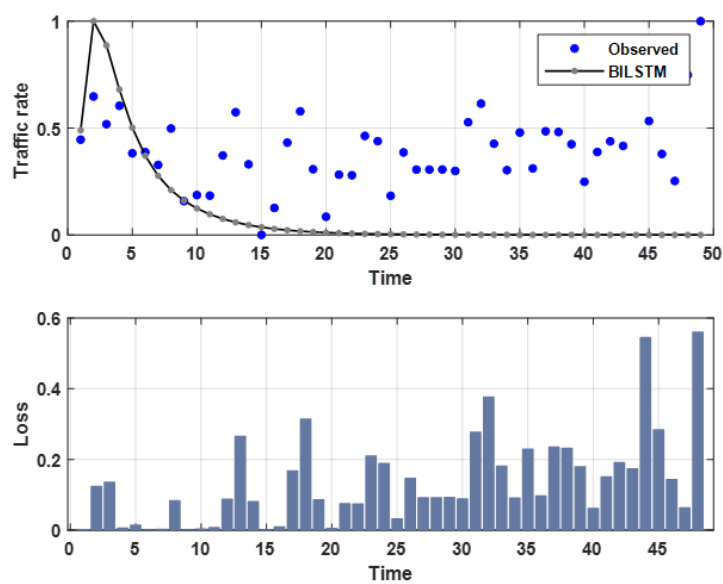


Рисунок 3.4.б – Предсказанный вывод с использованием модели BILSTM




Рисунок 3.4.с – Предсказанный выход с помощью модели LSTM




Рисунок 3.5.а – Гистограмма потерь при обучении при использовании предложенной модели




Рисунок 3.5.б – Гистограмма потерь при обучении при использовании модели
BILSTM




Рисунок 3.5.с – Гистограмма потерь при обучении при использовании модели
LSTM

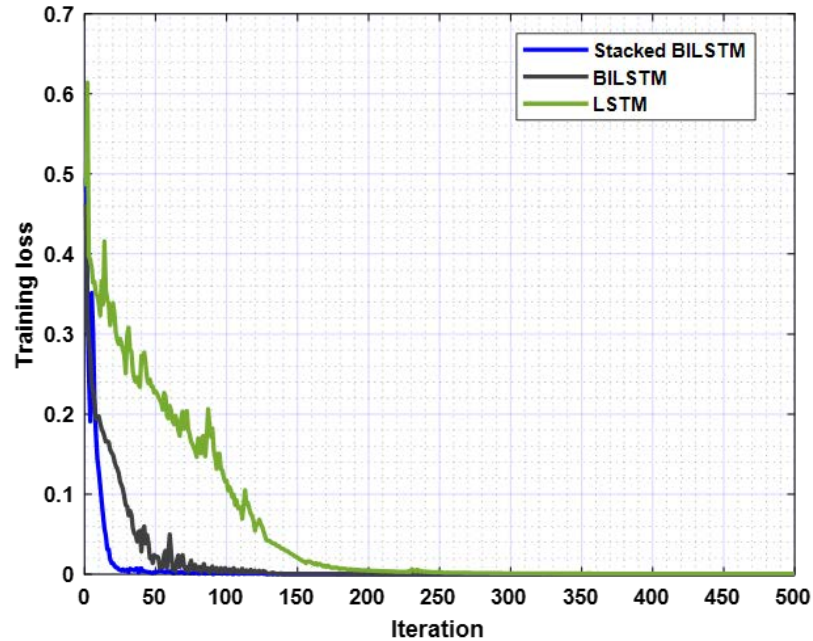


Рисунок 3.6 Зависимость потерь при обучении от количества итераций

3.5 Выводы по главе 3

1. Модель глубокого обучения на основе стековой BiLSTM модели предлагается для прогнозирования движения автономных транспортных средств в перегруженных районах на основе вычислительной среды летающего тумана.

2. Модель глубокого обучения основана на гипотезе, что глубокая иерархическая модель может представлять некоторые функции экспоненциально более эффективно, чем традиционные модели.

3. Укладка скрытых слоев BiLSTM углубляет модель, более точно подтверждая ее статус глубокого обучения. Успех этого подхода при решении многих сложных задач прогнозирования обычно связывают с глубиной нейронной сети.

4. Предиктор SBILSTM превосходит своих конкурентов и имеет наилучшие показатели.

5. Точность прогнозирования с помощью традиционной модели LSTM низкая по сравнению с другими.

6. Традиционный BILSTM имеет наименьшее время обработки, а предложенный SBILSTM - наибольшее.

7. R-квадрат для всех предикторов приблизительно равен и близок к 1, что означает, что сеть хорошо подогнана.

ГЛАВА 4 МЕТОД МОНИТОРИНГА ТРАФИКА УСЛУГ БЕСПИЛОТНЫХ АВТОМОБИЛЕЙ В СЕТЯХ СВЯЗИ ПЯТОГО И ПОСЛЕДУЮЩИХ ПОКОЛЕНИЙ ДЛЯ ОБНАРУЖЕНИЯ И РАСПОЗНАВАНИЯ АКТИВНОСТИ БИОЛОГИЧЕСКИХ ОБЪЕКТОВ

4.1 Введение

Обсуждается возможность применения бортовых платформ с целью поддержки наземных сетей для использования ресурсов автономных транспортных средств как части критичных к задержкам приложений. Бортовые платформы могут повысить безопасность поездок транспортных средств, доставляя на них своевременную информацию об окружающей обстановке даже в отдаленных районах земного шара. Обсуждаются требования и потенциальные решения для поддержки инфраструктуры автономных транспортных средств как части интеллектуальной транспортной системы. Предлагается использовать вдоль дороги энергоэффективные сенсоры, которые могут объединяться друг с другом в Mesh-сети. Кроме того, предлагается новый подход к обнаружению активности биологических объектов на обочине дороги, основанный на технологиях искусственного интеллекта.

Технологии 5G предназначены не только для увеличения пропускной способности беспроводной сети до 20 Гбит/с, но и для значительного увеличения объема передаваемых данных [36]. Сеть 5G/IMT-2020 поддерживает такие важные функции, как ультрамалые задержки (более быстрое реагирование) [37], широкополосные каналы (ускорение передачи данных) и одновременное

подключение нескольких устройств (например, датчиков или интеллектуальных устройств).

Программно-конфигурируемые сети (Software-Defined Network позволяют разделить уровни управления и данных [38]. SDN обеспечивает гораздо более эффективное распределение ресурсов и поддерживает работу сетевых приложений с заданным качеством обслуживания. Не случайно в настоящее время общепринятым является концептуальное решение о замене эволюционирующего пакетного ядра EPC (Evolved Packet Core) на программно конфигурируемые сети, в том числе и мультиконтроллерные [63].

Виртуализация сетевых функций (Network Function Virtualization, NFV) – это технология виртуализации физических сетевых элементов телекоммуникационной сети, когда сетевые функции выполняются программными модулями, работающими на стандартных серверах и виртуальных машинах. Эти программные модули могут взаимодействовать друг с другом для предоставления услуг связи, в которых ранее использовались аппаратные платформы. Концепция NFV берет начало из SDN, но эти технологии являются независимыми, хотя они дополняют друг друга [82]: SDN требует новых интерфейсов, модулей управления и приложений, а NFV предполагает перемещение сетевых приложений с выделенного оборудования в виртуальные контейнеры на готовом коммерческом оборудовании [39].

Автономные транспортные средства могут использовать преимущества технологии 5G для достижения ультрамалой задержки при передаче данных. Чтобы добиться ультрамалой задержки для автономного транспортного средства, объект управления сетью должен вовремя принимать решения об услугах, запросы на которые поступают от транспортных средств.

С развитием технологий и появлением искусственного интеллекта, автономные транспортные средства стали центром внимания во многих отраслях. Прогнозы показывают, что в ближайшие годы, автономные транспортные средства

будут появляться на дорогах все чаще [40]. Они сочетают в себе множество технологий, работающих без участия человека, помогают разрешить дорожный кризис, сократить количество аварий, которые происходят по вине людей, уменьшить загрязнение окружающей среды, вызванное обычными автомобилями, и снизить потребление энергии [41].

Концепция граничных вычислений (*Mobile Edge Computing*, MEC) заключается в том, чтобы разместить облачные ресурсы как можно ближе к пользователям или даже непосредственно в терминалах пользователей. Технология MEC позволяет использовать услуги облачных вычислений и среду информационных технологий на границе базовой сети, что обеспечивает быстрый отклик на услуги автономных транспортных средств и повышает эффективность использования ресурсов [42]. Дорожные карты также могут храниться и обрабатываться на сетевых серверах MEC. Сервер MEC может управлять вычислительными службами для большого количества автономных транспортных средств. Поэтому в последние годы исследования в области автономных транспортных средств с сетевой поддержкой становятся все более и более актуальными.

В [43] рассмотрены достижения в развитии сетей MEC, а также основные проблемы, возникающие при организации сетевой архитектуры с MEC. Также помимо трех уровней сетевой архитектуры (уровень конечного пользователя, уровень границы сети радиодоступа с серверами MEC, связанными с базовыми станциями, и уровень удаленного облачного сервера) предложен дополнительный уровень между серверами MEC и удаленным облаком, который позволяет конечным пользователям взаимодействовать с серверами MEC, удаленным облаком и друг с другом.

4.2 Задачи, решаемые в главе

С момента появления автомобилей на скоростных дорогах между городами возникла проблема столкновений с животными, которые могут внезапно появляться на проезжей части. Учитывая тенденции в развитии автомобильного транспорта, а именно широкое внедрение автономных транспортных средств, стоит взглянуть на проблему аварий с участием животных более широко. Если за рулем находится человек, то он может заметить изменения в окружающей обстановке (тень, кусты, предупреждение встречных водителей и т.д.), что позволит ему заранее снизить скорость и быть готовым к неожиданной ситуации, в том числе к столкновению с животным. Однако даже с учетом возможностей человека несчастные случаи с животными не редкость. Поэтому в рамках разработки концепции автономных транспортных средств и их инфраструктуры необходимо рассмотреть проблему аварий с биологическими объектами и разработать соответствующие решения, которые позволят спасти жизни людей и животных, а также сохранить имущество (автомобили, элементы дорожной инфраструктуры и т.д.). Именно в этом и состоит научная задача, которая решается в данной главе диссертационной работы, а именно: разработка системы обнаружения и распознавания движущихся биологических объектов для автономных транспортных средств на основе интеллектуальных граничных вычислений.

Учитывая рассмотренные выше технологические преимущества сетей 5G, в частности сетевых технологий SDN/NFV, а также облачных MEC и туманных FoG вычислений, появляется возможность реализовать эту задачу в рамках установленных требований к скорости принятия решения с учетом прогнозирования активности биологических объектов. Кроме того, необходимо предусмотреть возможность дальнейшей разработки соответствующих

программных модулей для задач прогнозирования движения биологических объектов.

Поставленная проблема обнаружения биологических объектов в придорожной зоне включает в себя множество сложных системных задач, решение которых, в свою очередь, позволит выйти на новый уровень безопасности движения, особенно в рамках концепции автономных транспортных средств.

В этой главе диссертационной работы можно резюмировать Результаты исследований следующим образом:

1. было предложено использовать технологию организации облачных структур МЕС. Эта технология обеспечит выполнение критерия производительности системы, сведя к минимуму сетевые задержки;

2. было предложено использовать сеть общедоступных датчиков с коммуникационными модулями LoRa Mesh. Использование данной радиотехнологии позволит соответствовать критерию удаленности отдельных участков дорог от базовых станций, а также обеспечит низкое энергопотребление системы;

3. было предложено использовать нейронные сети в рамках задачи обработки поступающей информации и с учетом необходимости высокой достоверности аналитических данных для распознавания типов биологических объектов.

На рис. 4.1 показана обобщенная архитектура, включающая элементы физического мира (автомобиль, дорога, животные и т. д.) [44]. Данное решение может входить в состав информационной системы, включающей аналитические цифровые модели инфраструктуры (дорожной и придорожной) и автономного транспорта. Как уже выяснилось на практике, само автономное транспортное средство со всеми доступными сегодня вычислительными возможностями и технологиями машинного зрения не может учесть некоторые сочетания внешних явлений и обеспечить абсолютную безопасность как для пассажиров, так и для всего остального окружения. Поэтому предлагается разрабатывать и учитывать

данные из цифровых моделей дорог и инфраструктуры, в которых автономный транспорт является частично самостоятельной структурой. Взаимодействие различных элементов системы друг с другом должно обеспечиваться сетевой и вычислительной инфраструктурой сетей связи 5G (а в последующем – шестого поколения и сетей 2030) [45].

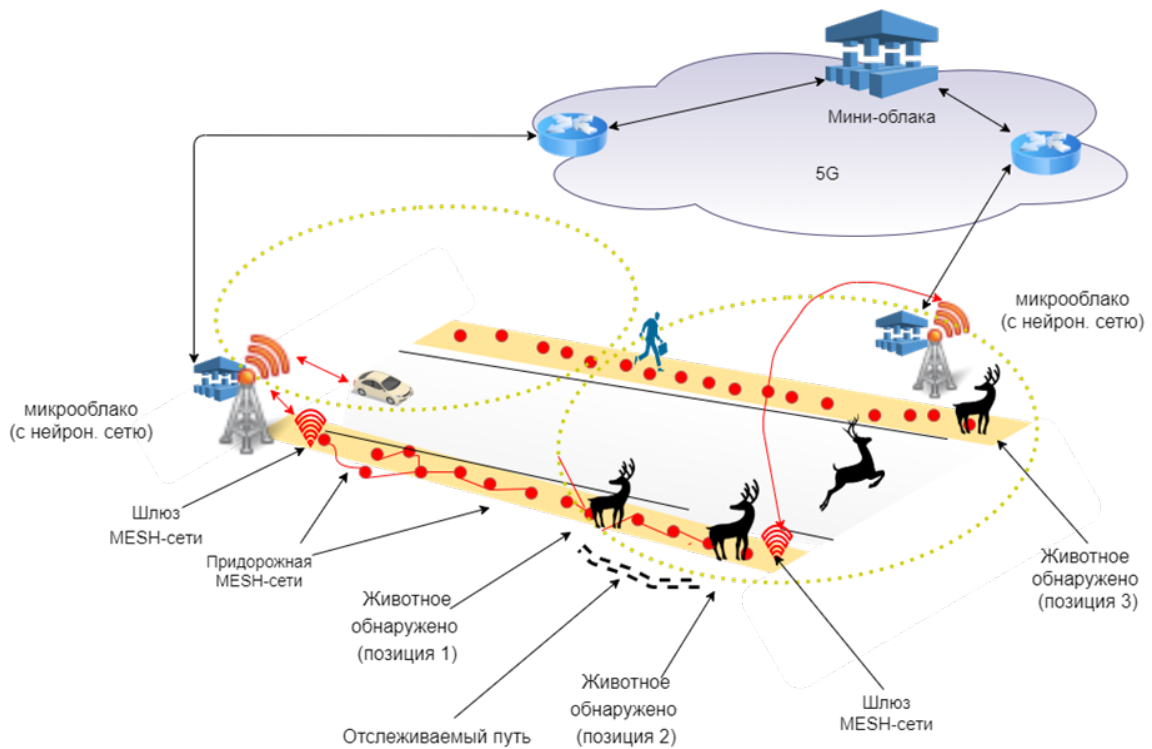


Рисунок 4.1 – Обобщенная архитектура

На рисунке 4.1 показаны элементы системы, а также их возможное взаимодействие. Одним из принципов, заложенных в требованиях к разрабатываемому решению, является осуществимость в условиях удаленности дорог от населенных пунктов. Как уже было отмечено выше, для выполнения этого требования предложено использовать новое поколение технологии LoRa, которое позволяет передавать данные с удаленных датчиков, расположенных вдоль дороги в несколько рядов. После срабатывания датчика его данные передаются в облако MEC, которое находится на ближайшей базовой станции, поэтому всю придорожную полосу можно разделить на «зоны» (круги, очерченные пунктирной линией на рис.4.1). После передачи данных в ближайшее облако происходит их

первичная обработка, что позволяет создать необходимую структуру данных для аналитического модуля распознавания объектов, реализованного с использованием технологии машинного обучения [46]. После этого определенные сообщения транслируются в широковещательном режиме на ближайшие базовые станции, которые передают соответствующие сообщения автономным транспортным средствам. В свою очередь, эти транспортные средства, заблаговременно получив информацию о возможности встречи с биологическими объектами, определяют их скоростные и временные параметры и прогнозируют дальнейшую модель их движения. Таким образом снижается вероятность несчастных случаев, которые могли бы произойти, если бы автономное транспортное средство полагалось только на бортовую сенсорную систему и бортовую систему видеоаналитики с машинным зрением. Также можно отметить, что предлагаемое решение благодаря использованию сетевых технологий обладает существенно бóльшими возможностями, чем индивидуальный набор датчиков и интеллектуальных систем отдельного автомобиля или даже группы автомобилей. В предлагаемом решении автомобиль будет знать об объектах еще до того, как лидар или радар сможет заметить, проанализировать и отреагировать на дорожную ситуацию.

4.3 Сетевая архитектура и протоколы Mesh

LoRa – это стандарт крупномасштабной сети с низким энергопотреблением и широким покрытием (LPWAN). Широкая зона покрытия и крупномасштабная сеть необходимы для устройств интернета вещей, так как при использовании локальных технологий (например, Wi-Fi) охват сети будет ограничен несколькими десятками и сотнями метров вокруг точек доступа, в то время как сети интернета вещей

должны покрывать гораздо большие территории. Для передачи данных на дальние расстояния обычно требуется передатчик большой мощности, однако для устройств интернета вещей важно низкое энергопотребление, так как, по крайней мере, часть из них работает от общеупотребительных батареек. Здесь есть дилемма между максимизацией расстояния передачи данных и минимизацией потребления энергии приемопередатчиком, которую можно решить при помощи уменьшения пропускной способности канала связи. Для передачи радиосигнала на заданное расстояние мы можем либо увеличить мощность сигнала, либо уменьшить полосу пропускания канала. Второй вариант решения и предлагается в технологии LoRa.

Принцип работы ячеистой сети LoRaWAN показан на рис.4. 2. Датчики (1, 2, 3) являются промежуточными звеньями между датчиком 4 и сетевым сервером. Когда один из них выходит из строя, датчик 5 играет роль промежуточного звена, и соединение между сервером и датчиком 4 восстанавливается. Шлюзы (1, 2) служат точкой входа и выхода между сетевым сервером и датчиками, информация передается сервером приложений при запросе.

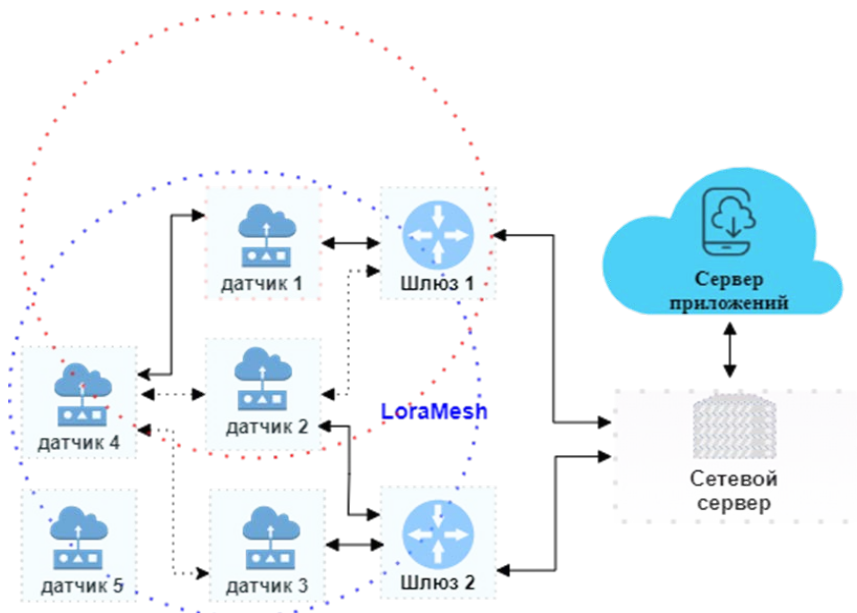


Рисунок 4.2 – Топология сети LoRaWAN

Сеть LoRaWAN Mesh предлагает надежный способ передачи данных [47]. Технология позволяет создавать большие гибкие сети, потребляющие мало

энергии. Это делает сеть LoRaWAN одним из лучших способов одновременного сбора данных с большого числа удаленных датчиков.

4.4 Вычислительная инфраструктура

На рис. 4.1. была представлена обобщенная архитектура предлагаемого решения. В рамках рассматриваемой архитектуры выделен ряд элементов, реализующих определенные вычислительные и сетевые функции. На рис.4.3 показана функциональная схема решения для вычислительной инфраструктуры.

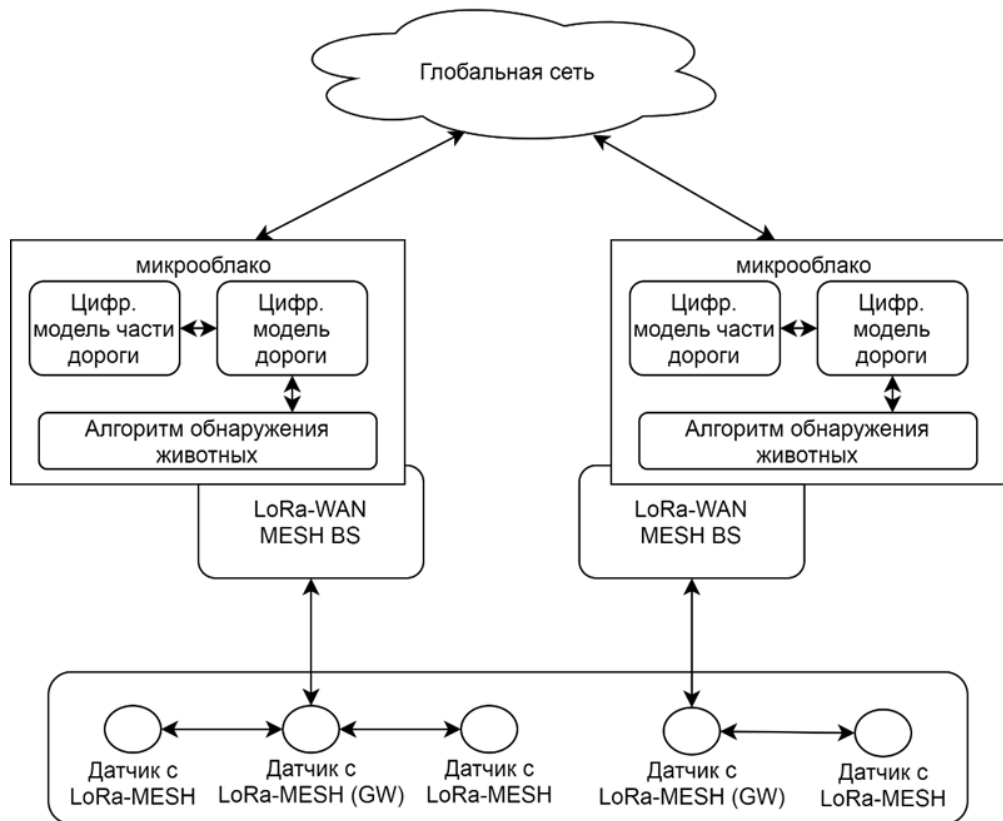


Рисунок 4.3 – Функциональная схема предлагаемого решения

На рис. 4.3 показаны следующие элементы: датчики с модулем LoRaWAN MESH для сбора и последующей передачи данных через MESH-сеть (LoRa-MESH (GW)) на базовую станцию (LoRa-WAN MESH BS) и на виртуальный сервер; базовые станции LoRaWAN MESH BS для агрегации трафика LoRa и последующей передачи данных в придорожные облака (микрооблако в структуре MEC); микрооблака, в рамках которых развернуто приложение серверной аналитики. В состав этого приложения входят следующие основные модули:

1. алгоритм обнаружения животных на обочине дороги. Данный алгоритм реализован на основе архитектуры рекуррентных нейронных сетей, предварительно обученных обнаружению соответствующих биологических объектов;

2. цифровая модель обочины. Этот модуль представляет собой программный комплекс, который реализует придорожные математические модели и аналитические модели более высокого порядка (например, систему прогнозирования), а также хранит данные и обрабатывает их для дальнейшей передачи [48];

3. цифровая модель части дороги. Данный модуль представляет собой программный пакет, реализующий математические модели части дорожной инфраструктуры, управляемой из облака. Это программное обеспечение предоставляет, хранит, обрабатывает данные обо всей дорожной ситуации и управлении динамическими элементами дороги (например, железнодорожным переездом и т.д.). На основе этих данных формируются определенные прогнозные аналитические данные для развития соответствующего участка дороги, информируются любые прибывающие автономные транспортные средства, путем передачи запрашиваемых данных бортовой системой транспортного средства.

4.5 Алгоритм распознавания биологических объектов

Предлагается новый алгоритм, помогающий распознавать биологические объекты, которые находятся рядом с дорогой и пытаются ее пересечь. Этот алгоритм должен распознавать следующие ситуации: рядом с проезжей частью находятся один человек, группа людей или крупное животное (например, олень, лось и т.п.).

На рис.4.4. показана карта датчиков в двух соседних зонах (2 соседних зоны на трассе длиной каждой из них 4 метра).

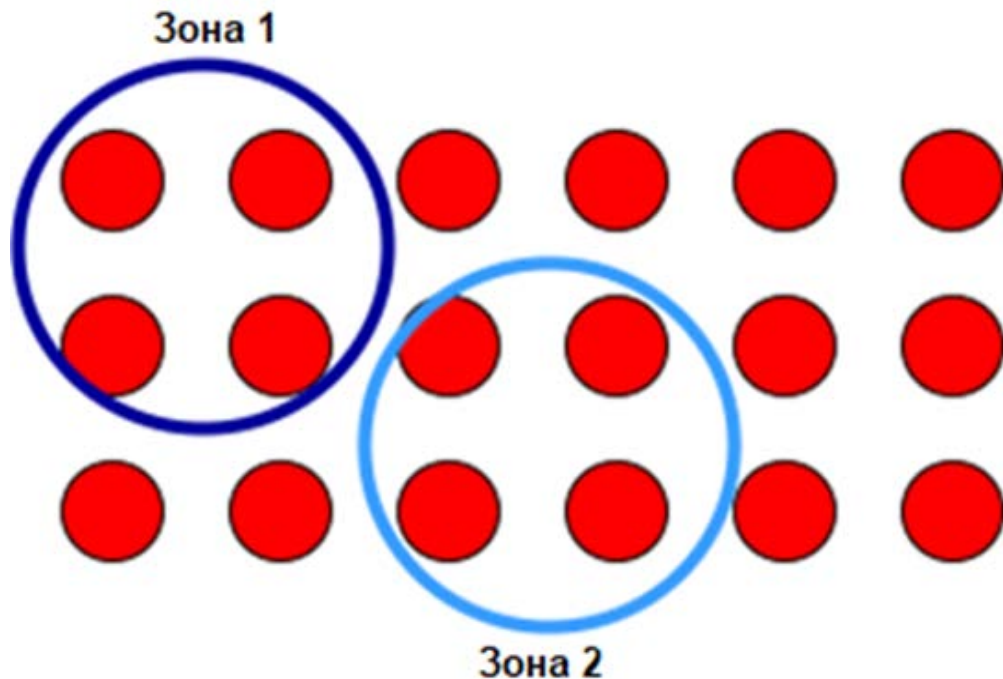


Рисунок 4.4. – Карта датчиков в зонах

Обработка данных происходит следующим образом. Пусть число активных датчиков в одной зоне (4 метра) составляет N , где $M := [x, y] = [3, 4] = 12$ (количество датчиков в одной зоне). Обозначим T – время срабатывания (Дельта между датчиками с соседних зон). Тогда разница между временами срабатывания датчиков из соседних зон.

$$Ts = Ts_{1_1} - Ts_{1_2}; \quad (4.1)$$

где Ts_{1_1} – время срабатывания первого датчика в первой зоне, Ts_{1_2} – время срабатывания первого датчика во второй зоне.

Сумма сил нажатия датчиков биологическим объектом в одной зоне:

$$F = \sum_{n=0}^N F_n, N \in M. \quad (4.2)$$

где F_n – сила нажатия n датчиков в одной зоне.

С физической точки зрения F_0 означает не одной датчик не нажат.

Среднее время нажатия датчиков в одной зоне:

$$\Delta T_{avg} = \frac{\sum_{n=0}^N \Delta t_n}{N}, N \in M \quad (4.3)$$

где Δt_n – дельта времени нажатия n датчиков

Расстояние между первым сработавшим датчиком в первой зоне и последним сработавшим датчиком во второй зоне:

$$S = \sqrt{(N_{12} - N_{11})^2 + (N_{22} - N_{21})^2} \quad (4.4)$$

где, N_{12} – первый сработавший датчик во второй зоне. N_{11} – первый сработавший датчик в первой зоне. N_{22} – второй сработавший датчик во второй зоне. N_{21} – второй сработавший датчик в первой зоне.

4.6 Обучение искусственной нейронной сети

Сегодня искусственная нейронная сеть широко используется для решения различных задач в различных аспектах нашей жизни. Например, области распознавания речи, компьютерного зрения (комплексная интегрированная видеоаналитика графических объектов), в последнее время - сложные инженерные системы и их модули (например, нефтеперерабатывающие автомобильные заводы и так далее). Столь сложные задачи анализа больших объемов информации решаются с помощью разработки инструментов, относящихся к классу искусственного интеллекта. Одним из наиболее активно развивающихся методов прогнозирования моделей на основе больших объемов данных является технология искусственных нейронных сетей.

На данный момент существует большое количество разнообразных нейронных сетей. Классификация – это одна из типичных задач, которые они решают. Одним из наиболее распространенных методов классификации является метод, основанный на описании объектов с помощью знаков:

Каждый объект характеризуется набором числовых или нечисловых знаков [49]. Однако для некоторых типов данных открытые знаки не дают точности классификации [50], например, цвет точек изображения или цифровой аудиосигнал. Причина в том, что эти данные содержат скрытые особенности. Глубокое обучение – это набор алгоритмов машинного обучения, которые пытаются моделировать высокоуровневые абстракции данных или, говоря другими словами, извлекать скрытые особенности из данных. Поэтому, учитывая особенности объекта (трафика) и его атрибуты (числовые ряды), была выбрана нейронная сеть с глубоким обучением [51].

Для решения задачи распознавания биологического объекта с учетом специфики поступающих данных для исследуемой задачи, а также требований,

предъявляемых к изучаемой и разрабатываемой системе, была выбрана рекуррентная нейронная сеть.

Так как выбранная архитектура нейронной сети реализует принцип обучения с учителем, требуется составить обучающие наборы данных с размеченными данными, а затем сохранить состояние обученной сети. Для обучения нейронной сети входной набор данных был преобразован в тренировочный набор данных путем добавления нового столбца данных, каждая ячейка которого имела идентификатор статистической выборки. Соответственно, для обучения распознаванию большего трафика этот обучающий набор данных необходимо расширить, пометив соответствующую статистическую выборку меткой биологического объекта, например: олени, люди или группа людей. Структура обучающего набора представлена в таблице.

Таблица 4.1 – Структура обучающего набора

Тип биологического объекта	Число активных датчиков	Время срабатывания датчика	Сумма сил	Среднее время нажатия датчика	Расстояние
Олень	N_{11}	TS_{12}	F_{13}	$\Delta T_{avg_{24}}$	T_{15}
Человек	N_{21}	TS_{22}	F_{23}	$\Delta T_{avg_{24}}$	T_{25}
Группа людей	N_{31}	TS_{32}	F_{33}	$\Delta T_{avg_{34}}$	T_{35}
...
...	N_{N1}	TS_{N2}	F_{N3}	$\Delta T_{avg_{N4}}$	T_{N5}
Другие	$N_{(N+1)1}$	$TS_{(N+1)2}$	$F_{(N+1)3}$	$\Delta T_{avg_{(N+1)4}}$	$T_{(N+1)5}$

Сетевая модель содержит четыре полносвязных уровня рекуррентной нейронной сети, каждый из которых содержит 12 скрытых узлов.

Гиперпараметры (параметры алгоритмов, значения которых устанавливаются перед запуском процесса обучения) обучения:

1. оптимизатор: Adam;
2. количество эпох (количество полных проходов по обучающему набору данных): 60;
3. количество выборок на итерацию: 1024;
4. скорость обучения: 0,0025. (имеет небольшое положительное значение, часто в диапазоне от 0,0 до 1,0).

4.7 Алгоритм моделирования

Для проверки работоспособности предложенного метода обнаружения биологического объекта на обочине дороги в соответствии с вышеизложенным был разработан генератор данных. В качестве имитации была разработана имитационная модель на языке программирования Python с реализованной искусственной рекуррентной нейронной сетью. После создания набора данных разработанная нейронная сеть была активирована, а после успешного обучения ее состояние было сохранено (получившаяся архитектура, веса и другие параметры).

С помощью генератора модельных данных с последующей обработкой был сформирован тренировочный набор данных, который поступил на вход нейронной сети, конфигурация которой описана выше.

Во время обучения отслеживались параметр «точность» (функция, обратная функции ошибок при распознавании активности биологического объекта) и параметр «ошибок» (перекрестная энтропия, определяющая близкое к истинному предсказуемое распределение). Процесс обучения проиллюстрирован на рис.4.5,

где «Пров. точность» обозначает процент правильных прогнозирований для тестовых данных, а «Пров. потерь» результат плохого прогнозирования. Кроме того, в дополнение к графикам, показанным на рис. 4.5., была построена матрица ошибок обучения нейронной сети. Матрица ошибок (она также может называться матрицей путаницы) представлена на рис. 4.6. На рис.4.6. хорошо видно, что нейронная сеть успешно завершила процесс обучения. Здесь в розовых прямоугольниках показано число правильных предсказанных наблюдений, а в черных прямоугольниках – количество неправильных предсказанных наблюдений; линейка справа – это нормированная матрица ошибок. Разработанная нейронная сеть прошла обучение, после чего прошла проверка ее работы на тестовых датасетах. Оказалось, что в обученном состоянии разработанная нейронная сеть может определить тип биологического объекта с вероятностью 99,8%. Матрица ошибок на рис. 4.6. показывает, что сеть допустила ошибку три раза (три черных прямоугольника с единицами). Также стоит отметить, что выбранная архитектура стала эффективным решением поставленной задачи. При меньшем количестве нейронов во вложенных слоях искусственная нейронная сеть работает нестабильно, она не достигает должного уровня в качестве обнаружения объекта и допускает значительное количество ошибок. При большем значении количества вложенных нейронов сеть также работает нестабильно и возникает эффект так называемого «переобучения» сети, о чем можно судить по графикам на рис. 4.5., которые были получены в рамках исследования архитектуры нейронной сети и ее обучения на тестовых данных. Также стоит отметить, что на графике процесса обучения на рис. 5 есть резкий скачок параметра качества обучения искусственной нейронной сети во время 40-й эпохи обучения.

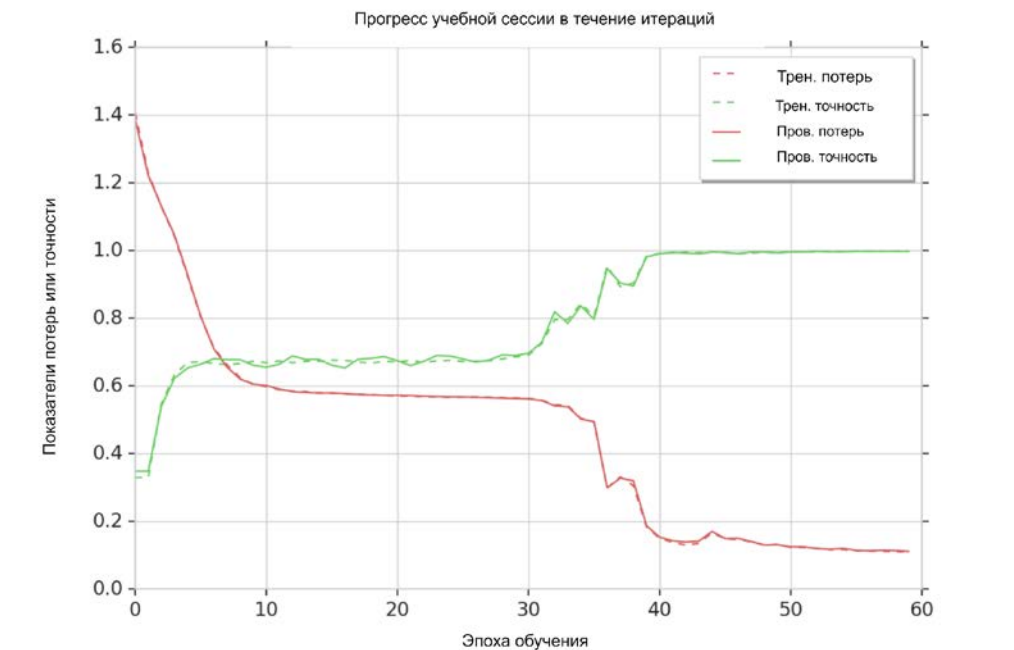


Рисунок 4.5 – Процесс машинного обучения

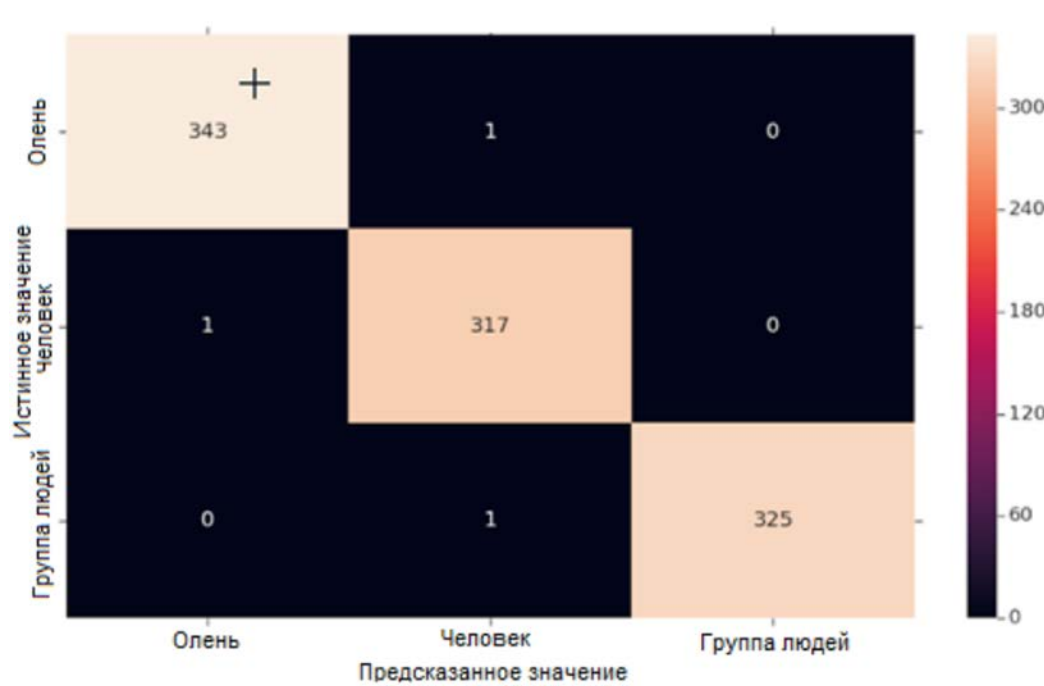


Рисунок 4.6 – Матрица ошибок

4.8 Выводы по главе 4

1. Представлено решение научной задачи по обнаружению и распознаванию активности биологических объектов на обочине дороги. Это решение может помочь уменьшить количество аварий, вызванных животными или людьми на дороге. В нем для обеспечения передачи данных между удаленными магистральными сетями и главной станцией использованы технология МЕС и ячеистая беспроводная технология LoRa.

2. Предложен алгоритм, использования рекуррентной нейронной сети для определения движения людей и животных по шоссе.

3. Разработана имитационная модель на языке программирования Python с реализацией искусственной нейронной сети для проверки работоспособности предложенного алгоритма. Результаты моделирования показали, что предложенные решения позволяют идентифицировать тип биологического объекта с вероятностью 99,8%.

ЗАКЛЮЧЕНИЕ

1. Анализ развития сетей связи пятого поколения показывает что, сеть может обеспечить очень высокую скорость передачи данных, сверх низкую задержку, большую надежность, огромную емкость сети и высокую пропускную способность, что приводит к быстрому соединению, и также большее количество устройств и больше людей могут подключиться к интернету.

2. Проанализированы возможности использования методов: туманных вычислений в сетях 5G для решения задач автономного управляемого транспорта; ов машинного обучения для определения данных необходимых для отправки в облако, что уменьшит задержку при отправке данных в облако. Определен круг задач в которых можно эффективно применить машинное и глубокое обучение прогнозирования трафика в сетях связи пятого и последующих поколений. К этим задачам относится прогнозирование потерь пакетов, задержки и пропускной способности в сетях связи пятого поколения для Интернета Вещей и Тактильного Интернета.

3. Предложено применять эффективные методы передачи информации собрав и проанализировав окружающие данные для коммуникации автономных управляемых транспортов между собой.

4. Исследована возможность и эффективность использования автомобильных туманных вычислений, т.к требуется большая вычислительная мощность и обратная связь в реальном времени для коммуникации автономных управляемых транспортов между собой.

5. Представлено решение научной задачи по обнаружению и распознаванию активности биологических объектов на обочине дороги. Это решение может помочь уменьшить количество аварий, вызванных животными или людьми на дороге. В нем для обеспечения передачи данных между удаленными магистральными сетями

и главной станцией использованы технология МЕС и ячеистая беспроводная технология LoRa.

6. Предложен алгоритм, использующий рекуррентную нейронную сеть для определения движения людей и животных по шоссе.

7. Разработана имитационная модель на языке программирования Python с реализацией искусственной нейронной сети для проверки работоспособности предложенного алгоритма. Результаты моделирования показали, что предложенные решения позволяют идентифицировать тип биологического объекта с вероятностью 99,8%.

8. Разработан метод глубокого обучения с использованием BI-LSTM и LSTM для прогнозирования трафика в автономных транспортных средствах с многоуровневыми облачными вычислениями.

9. Разработана модель глубокого обучения на основе стековой двунаправленной модели долговременной краткосрочной памяти SBILSTM для прогнозирования движения автономного транспорта в перегруженных районах на основе вычислительной среды летающего тумана.

СПИСОК ЛИТЕРАТУРЫ

1. Raphael Kiesel, Johannes van Roessel, Robert H. Schmitt, Quantification of economic potential of 5G for latency critical applications in production, *Procedia Manufacturing*, Volume 52, 2020, Pages 113-120, ISSN 2351-9789, <https://doi.org/10.1016/j.promfg.2020.11.021>.
2. Kröger, Fabian. (2016). Automated Driving in Its Social, Historical and Cultural Contexts. 10.1007/978-3-662-48847-8_3.
3. Schmidhuber, Jürgen (January 2015). "Deep learning in neural networks: An overview". *Neural Networks*. 61: 85–117. arXiv:1404.7828. doi:10.1016/j.neunet.2014.09.003. PMID 25462637.
4. Hawkins, Andrew J. (13 May 2018). "MIT built a self-driving car that can navigate unmapped country roads". *theverge.com*. Retrieved 14 May 2018.
5. Connor-Simons, Adam; Gordon, Rachel (7 May 2018). "Self-driving cars for country roads: Today's automated vehicles require hand-labeled 3-D maps, but CSAIL's MapLite system enables navigation with just GPS and sensors". Retrieved 14 May 2018
6. Abdellah A.R., Alshahrani A., Muthanna A., Koucheryavy A. Performance Estimation in V2X Networks Using Deep Learning Based M-Estimator Loss Functions in the Presence of Outliers // *Symmetry*. 2021. Vol. 13. Iss. 11. P. 2207. DOI:10.3390/sym13112207.
7. Chochliouros I.P., Spiliopoulou A.S., Lazaridis P., Dardamanis A., Zaharis Z., Kostopoulos A. Dynamic Network Slicing: Challenges and Opportunities // *Proceedings of the International Conference on Artificial Intelligence Applications and Innovations (AIAI 2020, Neos Marmaras, Greece, 5–7 June 2020)*. IFIP WG 12.5 International Workshops. IFIP Advances in Information and Communication Technology. Vol. 585. Cham: Springer, 2020. DOI:10.1007/978-3-030-49190-1_5

8. Miglani A., Kumar N. Deep learning models for traffic flow prediction in autonomous vehicles: A review, solutions, and challenges // *Vehicular Communications*. 2019. Vol. 20. P. 100184. DOI:10.1016/j.vehcom.2019.100184
9. Gillani M., Niaz H.A., Farooq M.U., Ullah A. Data collection protocols for VANETs: a survey // *Complex & Intelligent Systems*. 2022. Vol. 8. Iss. 3. PP. 2593–2622. DOI:10.1007/s40747-021-00629-x
10. Grigorescu S, Trasnea B, Cocias T, Macesanu G. A survey of deep learning techniques for autonomous driving // *Journal of Field Robotics*. 2020. Vol. 37. Iss. 3. PP. 362–386. DOI:10.1002/rob.21918
11. Pfülb B., Hardegen C., Gepperth A., Rieger S. A Study of Deep Learning for Network Traffic Data Forecasting // *Proceedings of the 28th International Conference on Artificial Neural Networks and Machine Learning (ICANN 2019, Munich, Germany, 17–19 September 2019)*. Lecture Notes in Computer Science. Vol. 11730. Cham: Springer, 2019. PP. 497–512. DOI:10.1007/978-3-030-30490-4_40
12. Ateeq M., Ishmanov F., Afzal M.K., Naeem M. Predicting Delay in IoT Using Deep Learning: A Multiparametric Approach // *IEEE Access*. 2019. Vol. 7. PP. 62022–62032. DOI:10.1109/ACCESS.2019.2915958
13. Abdellah A.R., Koucheryavy A. Deep Learning with Long Short-Term Memory for IoT Traffic Prediction // *Proceedings of the 20th International Conference on Next Generation Networks and Systems, NEW2AN 2020, and 13th Conference on Internet of Things, Smart Spaces, ruSMART 2020 (St. Petersburg, Russia, 26–28 August 2020)*. Lecture Notes in Computer Science. Vol. 12525. Cham: Springer, 2020. PP. 267–280. DOI:10.1007/978-3-030-65726-0_24
14. Almutairi M.S. Deep Learning-Based Solutions for 5G Network and 5G-Enabled Internet of Vehicles: Advances, Meta-Data Analysis, and Future Direction // *Mathematical Problems in Engineering*. 2022. Vol. 2022. P. 6855435. DOI:10.1155/2022/6855435

15. Kaur J., Khan M.A., Iftikhar M., Imran M., Haq Q.E.U. Machine Learning Techniques for 5G and Beyond // IEEE Access. 2021. Vol. 9. PP. 23472–23488. DOI:10.1109/ACCESS.2021.3051557
16. Abdellah A.R., Volkov A., Muthanna A., Gallyamov D., Koucheryavy A. Deep Learning for IoT Traffic Prediction Based on Edge Computing // Proceedings of the 23rd International Conference on Distributed Computer and Communication Networks: Control, Computation, Communications (DCCN 2020, Moscow, Russia, 14–18 September 2020). Communications in Computer and Information Science. Vol. 1337. PP. 18–29. Cham: Springer, 2020. DOI:10.1007/978-3-030-66242-4_2
17. Khedkar S.P., Canessane R.A., Najafi M.L. Prediction of Traffic Generated by IoT Devices Using Statistical Learning Time Series Algorithms // Wireless Communications and Mobile Computing. 2021. Vol. 2021. P. 5366222. DOI:10.1155/2021/5366222
18. Selvamanju E., Shalini V.B. Machine Learning Based Mobile Data Traffic Prediction in 5G Cellular Networks // Proceedings of the 5th International Conference on Electronics, Communication and Aerospace Technology (ICECA, Coimbatore, India, 02–04 December 2021). IEEE, 2021. PP. 1318–1324. DOI:10.1109/ICECA52323.2021.9675887
19. Choi D., Yim J., Baek M., Lee S. Machine Learning Based Vehicle Trajectory Prediction Using V2V Communications and On-Board Sensors // Electronics. 2021. Vol. 10. Iss. 4. P. 420. DOI:10.3390/electronics10040420
20. Rasouli A., Tsotsos J.K. Autonomous Vehicles That Interact With Pedestrians: A Survey of Theory and Practice // IEEE Transactions on Intelligent Transportation Systems. 2020. Vol. 21. Iss. 3. PP. 900–918. DOI:10.1109/TITS.2019.2901817
21. Badicu A., Suci G., Balanescu M., Dobre M., Birdici A., Orza O., Pasat A. PMs concentration forecasting using ARIMA algorithm // Proceedings of the 91-st Vehicular Technology Conference (VTC2020-Spring, Antwerp, Belgium, 25–28 May 2020). IEEE, 2020. DOI:10.1109/VTC2020-Spring48590.2020.9129390

22. Shang Q., Tan D., Gao S., Feng L. A Hybrid Method for Traffic Incident Duration Prediction Using BOA Optimized Random Forest Combined with Neighborhood Components Analysis // *Journal of Advanced Transportation*. 2019. Vol. 2019. P. 4202735. DOI:10.1155/2019/4202735
23. Кучерявый А.Е. Сети связи с ультрамалыми задержками // *Труды научно-исследовательского института радио*. 2019. № 1. С. 69–74.
24. Мутханна А.С. Интеллектуальная распределенная архитектура сети связи для поддержки беспилотных автомобилей // *Электросвязь*. 2020. № 7. С. 29–34. DOI:10.34 832/ELSV.2020.8.7.004
25. Владыко А.Г., Мутханна А.С., Кучерявый А.Е. Метод выгрузки трафика в V2X/5G сетях на основе системы граничных вычислений // *Электросвязь*. 2020. № 8. С. 24–30. DOI:10.34 832/ELSV.2020.9.8.004
26. Shrestha R., Bajracharya R., Nam S.Y. Challenges of Future VANET and Cloud-Based Approaches // *Wireless Communications and Mobile Computing*. 2018. Vol. 2018. P. 5603518. DOI:10.1155/2018/5603518
27. Abdellah, Ali R., Ammar Muthanna, Mohamed H. Essai, and Andrey Koucheryavy. 2022. "Deep Learning for Predicting Traffic in V2X Networks" *Applied Sciences*, Vol. 12, Issue. 19: 10030. <https://doi.org/10.3390/app121910030>
28. Lohrasbinasab I., Shahraki A., Taherkordi A., Delia Jurcut A. From statistical to machine learning-based network traffic prediction. *Trans. Emerg. Telecommun. Technol.* (2021), Article e4394
29. Singh, D.P.; Sharma, D. Traffic Prediction Using Machine Learning and IoT. In *Integration of Cloud Computing with Internet of Things*; Wiley: Hoboken, NJ, USA, 2021; pp. 111–129. [CrossRef]
30. Dukka K. R.; H. B.; Janmenjoy N.; Pandi V.; Bighnaraj N.; Pradeep K. S.; Deep neural network based anomaly detection in Internet of Things network traffic tracking for the applications of future smart cities in Special Issue: "Deep Network Based

Industrial Internet of Things Applications” and “Integration of Satellite-Aerial-Terrestrial Networks” July 2021, Article e4121

31. Ateya, A.A., Soliman, N.F., Alkanhel, R. et al. Lightweight Deep Learning-Based Model for Traffic Prediction in Fog-Enabled Dense Deployed IoT Networks. *J. Electr. Eng. Technol.* (2022). <https://doi.org/10.1007/s42835-022-01314-w>

32. Abdulkareem, Karrar & Mohammed, Mazin & Gunasekaran, Saraswathy & Al-Mhiqani, Mohammed & Mutlag, Ammar & Mostafa, Salama & Ali, Nabeel & Ibrahim, Dheyaa. (2019). A Review of Fog Computing and Machine Learning: Concepts, Applications, Challenges, and Open Issues. *IEEE Access.* 7. 1-1. 10.1109/ACCESS.2019.2947542.

33. Samann, F. E. F., Abdulazeez, A. M., & Askar, S. (2021). Fog Computing Based on Machine Learning: A Review. *International Journal of Interactive Mobile Technologies (iJIM)*, 15(12), pp. 21–46. <https://doi.org/10.3991/ijim.v15i12.21313>.

34. Ali R. Abdellah, Andrey Koucheryavy. "Deep Learning with Long Short-Term Memory for IoT Traffic Prediction," Galinina O., Andreev S., Balandin S., Koucheryavy Y. (eds) *Internet of Things, Smart Spaces, and Next Generation Networks and Systems (NEW2AN /SMART)*, Lecture Notes in Computer Science, Springer, Cham., Vol 12525, pp. 267–280, 2020. https://doi.org/10.1007/978-3-030-65726-0_24.

35. Ali R. Abdellah, Andrey Koucheryavy. "VANET Traffic Prediction Using LSTM with Deep Neural Network Learning," Galinina O., Andreev S., Balandin S., Koucheryavy Y. (eds) *Internet of Things, Smart Spaces, and Next Generation Networks and Systems. (NEW2AN/ruSMART)*. Lecture Notes in Computer Science, Springer, Cham. Vol 12525. pp. 281–294, 2020, https://doi.org/10.1007/978-3-030-65726-0_25.

36. Атея, А.А. Интеллектуальное ядро для сетей связи 5G и тактильного интернета на базе программно конфигурируемых сетей / А.А. Атея, А.С. Мутханна, А.Е. Кучерявый // *Электросвязь*. – 2019. – № 3. – С. 34-40.

37. Кучерявый, А.Е. Сети связи с ультрамалыми задержками / А.Е. Кучерявый // *Труды НИИР*. – 2019. – № 1. – С. 69-74.

38. Мухизи, С. Модели сегментации и кластеризации ресурсов в программно-конфигурируемых сетях / С. Мухизи, А.А. Атея, А.С. Мутханна, Р.В. Киричек // Электросвязь. – 2019. – № 4. – С. 26-31.

39. Muthanna, A. Framework of QoS Management for Time Constraint Services with Requested Network Parameters based on SDN/NFV Infrastructure / A. Muthanna, A. Volkov, A. Khakimov et al. // 2018 10th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT). – IEEE, 2018. – [https:// doi.org/10.1109/ICUMT.2018.8631274](https://doi.org/10.1109/ICUMT.2018.8631274).

40. Bonnefon, J.F. The social dilemma of autonomous vehicles / J.F. Bonnefon, A. Shariff, I. Rahwan // Science. – 2016. – Vol. 352, Issue 6293. – P. 1573 1576. – DOI:10.1126/science.aaf2654.

41. Gerla, M. Internet of vehicles: From intelligent grid to autonomous cars and vehicular clouds / M. Gerla, E.K. Lee, G. Pau, U. Lee // 2014 IEEE World Forum on Internet of Things, WF-IoT. – DOI:10.1109/WFIoT. 2014.6803166.

42. Ateya, A. Intelligent core network for Tactile Internet system / A. Ateya, A. Muthanna, I. Gudkova et al. // ICFNDS '17: Proceedings of the International Conference on Future Networks and Distributed Systems. – <https://doi.org/10.1145/3102304.3102326>.

43. Tran, T.X. Collaborative mobile edge computing in 5G networks: new paradigms, scenarios, and challenges / T.X. Tran, A. Hajisami, P. Pandey, D. Pompili // IEEE Communications Magazine. – 2017. – Vol. 55, Issue 4. – P. 54-61.

44. Volkov, A. Interaction of the IoT traffic generated by a smart city segment with SDN core network / A. Volkov, A. Khakimov, A. Muthanna et al. // 2017 International Conference on Wired/Wireless Internet Communication (WWIC). – Springer, 2017. – P. 115 126. – http://doi-org-443.webvpn.fjmu.edu.cn/10.1007/978-3-319-61382-6_10.

45. Volkov, A. Novel AI-Based Scheme for Traffic Detection and Recognition in 5G Based Networks / A. Volkov, A.A. Ateya, A. Muthanna, A. Koucheryavy //

Proceedings of 19th International Conference, NEW2AN 2019, and 12th Conference, ruSMART 2019, St. Petersburg, Russia, August 26–28, 2019. – P. 243–255. – https://doi.org/10.1007/978-3-030-30859-9_21.

46. Rathore, H. Malware Detection Using Machine Learning and Deep Learning / H. Rathore, S. Agarwal, S.K. Sahay, M. Sewak // International Conference on Big Data Analytics, 2018. – Springer, 2018. – P. 402–411.

47. Pham, V.D. Method for Organizing Mesh Topology Based on LoRa Technology / V.D. Pham, T.D. Dinh, R. Kirichek // 2018 10th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT). – IEEE, 2018. DOI:10.1109/ICUMT.2018.8631270.

48. Volkov, A. SDN Load Prediction Algorithm Based on Artificial Intelligence / A. Volkov, K. Proshutinskiy, A.B.M. Adam et al. // Distributed Computer and Communication Networks. – Springer, 2019. – P. 27–40. – DOI:10.1007/978-3-030-36625-4_3.

49. Sewak, M. Comparison of deep learning and the classical machine learning algorithm for the malware detection / M. Sewak, S.K. Sahay, H. Rathore // 2018 19th IEEE/ ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD). – IEEE, 2018. – DOI:10.1109/SNPD.2018.8441123.

50. Roul, R.K. Extreme learning machines in the field of text classification / R.R. Kumar, A. Nanda, V. Patel, S.K. Sahay // 2015 IEEE/ ACIS 16th International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD). – IEEE, 2015. – DOI:10.1109/SNPD.2015.7176204.

51. Sewak, M. An investigation of a deep learning-based malware detection system / M. Sewak, S.K. Sahay, H. Rathore // Proceedings of the 13th International Conference on Availability, Reliability and Security (ARES-2018). – DOI:10.1145/3230833.3230835.

52. Qiao, L.; Li, Y.; Chen, D.; Serikawa, S.; Guizani, M.; Lv, Z. A survey on 5G/6G, AI, and Robotics. *Comput. Electr. Eng.* 2021, 95, 107372.
53. Dogra, A.; Jha, R.K.; Jain, S. A survey on beyond 5G network with the advent of 6G: Architecture and emerging technologies. *IEEE Access* 2020, 9, 67512–67547.
54. Long, Q.; Chen, Y.; Zhang, H.; Lei, X. Software defined 5G and 6G networks: A survey. *Mob. Netw. Appl.* 2019, 1–21.
55. Navarro-Ortiz, J.; Romero-Diaz, P.; Sendra, S.; Ameigeiras, P.; Ramos-Munoz, J.J.; Lopez-Soler, J.M. A survey on 5G usage scenarios and traffic models. *IEEE Commun. Surv. Tutor.* 2020, 22, 905–929.
56. Siriwardhana, Y.; Porambage, P.; Liyanage, M.; Ylianttila, M. A Survey on Mobile Augmented Reality with 5G Mobile Edge Computing: Architectures, Applications, and Technical Aspects. *IEEE Commun. Surv. Tutor.* 2021, 23, 1160–1192.
57. De Alwis, C.; Kalla, A.; Pham, Q.V.; Kumar, P.; Dev, K.; Hwang, W.J.; Liyanage, M. Survey on 6G frontiers: Trends, applications, requirements, technologies and future research. *IEEE Open J. Commun. Soc.* 2021, 2, 836–886.
58. Mahmoud, H.H.H.; Amer, A.A.; Ismail, T. 6G: A comprehensive survey on technologies, applications, challenges, and research problems. *Trans. Emerg. Telecommun. Technol.* 2021, 32, e4233.
59. Morgado, A.; Huq, K.M.S.; Mumtaz, S.; Rodriguez, J. A survey of 5G technologies: Regulatory, standardization and industrial perspectives. *Digit. Commun. Netw.* 2018, 4, 87–97.
60. Jeong, J.; Shen, Y.; Oh, T.; Céspedes, S.; Benamar, N.; Wetterwald, M.; Härri, J. A comprehensive survey on vehicular networks for smart roads: A focus on IP-based approaches. *Veh. Commun.* 2021, 29, 100334.
61. Ismael, H.R.; Ameen, S.Y.; Kak, S.F.; Yasin, H.M.; Ibrahim, I.M.; Ahmed, A.M.; Rashid, Z.N.; Omar, N.; Salih, A.A.; Ahmed, D.M. Reliable communications for vehicular networks. *Asian J. Res. Comput. Sci.* 2021, 10, 33–49.

62. Zeadally, S.; Guerrero, J.; Contreras, J. A tutorial survey on vehicle-to-vehicle communications. *Telecommun. Syst.* 2020, 73, 469–489.
63. Al-Heety, O.S.; Zakaria, Z.; Ismail, M.; Shakir, M.M.; Alani, S.; Alsariera, H. A comprehensive survey: Benefits, services, recent works, challenges, security, and use cases for SDN-VANET. *IEEE Access* 2020, 8, 91028–91047.
64. Arena, F.; Pau, G.; Severino, A. A review on IEEE 802.11 p for intelligent transportation systems. *J. Sens. Actuator Netw.* 2020, 9, 22.
65. Balador, A.; Cinque, E.; Pratesi, M.; Valentini, F.; Bai, C.; Gómez, A.A.; Mohammadi, M. Survey on decentralized congestion control methods for vehicular communication. *Veh. Commun.* 2021, 33, 100394.
66. Ji, B.; Zhang, X.; Mumtaz, S.; Han, C.; Li, C.; Wen, H.; Wang, D. Survey on the internet of vehicles: Network architectures and applications. *IEEE Commun. Stand. Mag.* 2020, 4, 34–41.
67. Bhatia, J.; Dave, R.; Bhayani, H.; Tanwar, S.; Nayyar, A. SDN-based real-time urban traffic analysis in VANET environment. *Comput. Commun.* 2020, 149, 162–175.
68. Yu, H.; Liu, R.; Li, Z.; Ren, Y.; Jiang, H. An RSU Deployment Strategy based on Traffic Demand in Vehicular Ad Hoc Networks (VANETs). *IEEE Internet Things J.* 2021.
69. Sharma, S.; Kaul, A. VANETs Cloud: Architecture, Applications, Challenges, and Issues. *Arch. Comput. Methods Eng.* 2021, 28, 2081–2102.
70. Ahmed, A.A.; Alzahrani, A.A. A comprehensive survey on handover management for vehicular ad hoc network based on 5G mobile networks technology. *Trans. Emerg. Telecommun. Technol.* 2019, 30, e3546.
71. Tayyab, M.; Gelabert, X.; Jäntti, R. A survey on handover management: From LTE to NR. *IEEE Access* 2019, 7, 118907–118930.
72. Duo, R.; Wu, C.; Yoshinaga, T.; Zhang, J.; Ji, Y. SDN-based handover scheme in cellular/IEEE 802.11 p hybrid vehicular networks. *Sensors* 2020, 20, 1082.

73. Choi, J.H.; Han, Y.H.; Min, S.G. A network-based seamless handover scheme for VANETs. *IEEE Access* 2018, 6, 56311–56322.
74. Pham, Q.V.; Fang, F.; Ha, V.N.; Piran, M.J.; Le, M.; Le, L.B.; Hwang, W.J.; Ding, Z. A survey of multi-access edge computing in 5G and beyond: Fundamentals, technology integration, and state-of-the-art. *IEEE Access* 2020, 8, 116974–117017.
75. Filali, A.; Abouaomar, A.; Cherkaoui, S.; Kobbane, A.; Guizani, M. Multi-access edge computing: A survey. *IEEE Access* 2020, 8, 197017–197046.
76. Liu, L.; Chen, C.; Pei, Q.; Maharjan, S.; Zhang, Y. Vehicular edge computing and networking: A survey. *Mob. Netw. Appl.* 2020, 26, 1145–1168.
77. Boukerche, A.; Soto, V. Computation offloading and retrieval for vehicular edge computing: Algorithms, models, and classification. *ACM Comput. Surv. (CSUR)* 2020, 53, 1–35.
78. Sharma, A.; Vanjani, P.; Paliwal, N.; Basnayaka, C.M.W.; Jayakody, D.N.K.; Wang, H.C.; Muthuchidambaranathan, P. Communication and networking technologies for UAVs: A survey. *J. Netw. Comput. Appl.* 2020, 168, 102739.
79. Hussain, R.; Lee, J.; Zeadally, S. Trust in VANET: A survey of current solutions and future research opportunities. *IEEE Trans. Intell. Transp. Syst.* 2020, 22, 2553–2571.
80. Gyawali, S.; Xu, S.; Qian, Y.; Hu, R.Q. Challenges and solutions for cellular based v2x communications. *IEEE Commun. Surv. Tutor.* 2020, 23, 222–255.
81. Souza, V.B.; Pereira, M.H.; Lelis, L.H.; Masip-Bruin, X. Enhancing resource availability in vehicular fog computing through smart inter-domain handover. In *Proceedings of the GLOBECOM 2020-2020 IEEE Global Communications Conference, Taipei, Taiwan, 7–11 December 2020*; IEEE: Manhattan, NY, USA, 2020; pp. 1–6.
82. Muthanna, A.; Shamilova, R.; Ateya, A.A.; Paramonov, A.; Hammoudeh, M. A mobile edge computing/software-defined networking-enabled architecture for vehicular networks. *Internet Technol. Lett.* 2020, 3, e109.

ПРИЛОЖЕНИЕ

МИНИСТЕРСТВО ЦИФРОВОГО РАЗВИТИЯ,
СВЯЗИ И МАССОВЫХ КОММУНИКАЦИЙ
РОССИЙСКОЙ ФЕДЕРАЦИИ

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ
ВЫСШЕГО ОБРАЗОВАНИЯ
«САНКТ-ПЕТЕРБУРГСКИЙ ГОСУДАРСТВЕННЫЙ
УНИВЕРСИТЕТ ТЕЛЕКОММУНИКАЦИЙ
ИМ. ПРОФ. М.А. БОНЧ-БРУЕВИЧА»
(СПбГУТ)

Юридический адрес: набережная реки Мойки,
д. 61, литера А, Санкт-Петербург, 191186

Почтовый адрес: пр. Большевиков, д. 22, корп. 1,
Санкт-Петербург, 193232

Тел.(812) 3263156, Факс: (812) 3263159
<http://sut.ru>

E-mail: rector@sut.ru
ОКПО 01179934 ОГРН 1027809197635
ИНН 7808004760 КПП 784001001
ОКТМО 40909000

18.03.2023 № *817/34*
на № _____ от _____

Утверждаю

Первый проректор-проректор по учебной
работе, к.т.н., доцент


Абилов А.В.



Акт

о внедрении научных результатов, полученных Аль-Свейти Малик А. М.
в диссертационной работе «Исследование и разработка моделей и методов
построения инфраструктуры сетей автономного транспорта с использованием
технологий Искусственного Интеллекта»

Комиссия в составе декана факультета Инфокоммуникационных сетей и систем Д.В. Окуновой, доцента кафедры сетей связи и передачи данных Р.А. Дунайцев и заведующей лабораторией кафедры сетей связи и передачи данных О.И. Ворожейкиной составила настоящий акт в том, что научные результаты, полученные результаты, полученные Аль-Свейти Малик А. М., использованы:

1. При чтении лекций и проведении практических занятий для бакалавров по дисциплине «Интернет вещей и самоорганизующиеся сети» (Рабочая Программа № 20.05/534-Д, раздел Программы:

- Концепции развития сетей связи. Текущее состояние развития сетей.
Прогнозы развития сетей связи;

- Самоорганизующиеся сети. Примеры самоорганизующихся сетей, услуги и приложения таких сетей.

2. При чтении лекций и проведении практических занятий по дисциплине «Машинное и глубокое обучение в телекоммуникациях» (Рабочая Программа регистрационный номер № 21.05/765-Д, раздел Программы:

- Машинное обучение,
- Приложения машинного и глубокого обучения.

3. При чтении лекций проведении практических занятий для аспирантов по дисциплине «Системы, сети и устройства телекоммуникаций» (Рабочая Программа регистрационной номер № 20.05/713-Д), раздел Программы:

- Основные задачи построения и эксплуатации систем, сетей и устройств связи.

В указанных дисциплинах используются следующие новые научные результаты, полученные Аль-Свейти Малик А. М. в диссертационной работе:

- Метод глубокого обучения с использованием алгоритма долговременной краткосрочной памяти LSTM и алгоритма двунаправленной LSTM (BI-LSTM), обеспечивает повышение точности прогнозирования скорости движения, в частности, при использовании группы из 8, в среде VANET и тумана в многоуровневых граничных сетях. максимальное среднее повышение точности в обоих случаях составляет 7,9% и 10,1%.

- Метод прогнозирования скорости движения автотранспорта в зонах с интенсивным движением на основе движущего летающего тумана и Stacked двунаправленной модели кратковременной памяти (SBILSTM), позволяет повысить точность прогнозирования на 0.2%.

- Метод мониторинга трафика услуг беспилотных автомобилей в сетях связи пятого и последующих поколений, позволяет обнаруживать и распознавать активности биологических объектов на обочине дороги на основе технологии интеллектуальных граничных вычислений и ячеистой беспроводной технологии LoRa.

Декан факультета ИКСС

к.т.н., доцент

Доцент кафедры ССиПД

к.т.н., PhD

Зав. лабораторией кафедры ССиПД

Д.В. Окунева

Р.А. Дунайцев

О.И. Ворожейкина