

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

Автореферат  
диссертации на соискание ученой степени  
кандидата технических наук

Санкт-Петербург – 2023

Работа выполнена в федеральном государственном бюджетном образовательном учреждении высшего образования «Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича» на кафедре сетей связи и передачи данных.

Научный руководитель: кандидат технических наук,  
**Мутханна Аммар Салех Али**

Официальные  
оппоненты: **Татарникова Татьяна Михайловна,**  
доктор технических наук, профессор,  
Санкт-Петербургский государственный  
университет аэрокосмического приборостроения,  
Институт информационных технологий  
и программирования, директор института

**Кайсина Ирина Алексеевна,**  
кандидат технических наук,  
Ижевский государственный технический  
университет имени М.Т. Калашникова, кафедра  
сетей связи и телекоммуникационных систем,  
доцент кафедры

Ведущая организация: Федеральное государственное бюджетное  
учреждение науки Институт проблем управления  
им. В.А Трапезникова Российской академии наук,  
г. Москва

Защита состоится 21 июня 2023 года в 14.00 на заседании диссертационного совета 55.2.004.01, созданном на базе Федерального государственного бюджетного образовательного учреждения высшего образования «Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича», по адресу: Санкт-Петербург, пр. Большевиков, д. 22, корп. 1, ауд. 554/1.

С диссертацией можно ознакомиться в библиотеке СПбГУТ по адресу Санкт-Петербург, пр. Большевиков, д. 22, корп. 1 и на сайте [www.sut.ru](http://www.sut.ru).

Автореферат разослан 21 апреля 2023 года.

Ученый секретарь  
диссертационного совета 55.2.004.01,  
д-р техн. наук, доцент

М.А. Маколкина

## ОБЩАЯ ХАРАКТЕРИСТИКА ДИССЕРТАЦИИ

**Актуальность темы диссертации.** Эффективное развитие сетей связи пятого и шестого поколения 5G/6G сложно представить без использования методов прогнозирования трафика. Достаточно точное и своевременное знание о поведении трафика и обеспечения 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 местным пользователям благодаря обработке данных в непосредственной близости, а не маршрутизации данных в удаленный центральный 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 преодоления этих проблем 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. Бородина, Ю.В. Гайдамаки, Р.В. Киричка, Е.А. Кучерявого, М.А. Маколкиной, Д.А. Молчанова, А.С.А. Мутханны, 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 сводит к минимуму сетевых задержек и обеспечивает 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 архитектур было 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 MEC 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 MEC и сетью общедоступных датчиков с коммуникационными модулями LoRa Mesh для автономного управляемого транспорта что сводит к минимуму сетевых задержек 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-Петербургском государственном университете телекоммуникаций им. проф. М.А. Бонч-Бруевича» (СПбГУТ) при чтении лекций, проведении практических занятий и лабораторных работ.

**Методология и методы исследования.** При работы 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" (Санкт-Петербург, 2020), 75-я научно-техническая конференция Санкт-Петербургского НТОРЭС им. А.С. Попова, посвященная Дню

радио (Санкт-Петербург, 2020), 24th International Conference on Distributed Computer and Communication Networks: Control, Computation, Communications (2021), «Актуальные проблемы инфотелекоммуникаций в науке и образовании» (Санкт-Петербург, 2019, 2022).

**Публикации по теме диссертации.** Всего по теме диссертации опубликовано 10 работ, из них 2 статьи в рецензируемых научных журналах, входящих в перечень изданий, рекомендуемых ВАК Министерства высшего образования и науки Российской Федерации, 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.

**Структура и объем диссертации.** Диссертация состоит из четырех глав, заключения, списка литературы, одного приложения и содержит 122 страницы, иллюстрированных 23 рисунками и 6 таблицами. Список литературы содержит 82 наименования.

## ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

**Во введении** определена актуальность темы диссертации, сформулированы цель и задачи диссертационной работы, научная новизна результатов диссертации, теоретическая и практическая значимость, приведены сведения об опубликованных работах и выступлениях на конференциях и семинарах, а также положения, выносимые на защиту.

**В первой главе** диссертационной работы проведен анализ направлений развития сетей связи, в том числе 5G, развития автономных транспортных средств, перспектив использования технологий МЕС и туманных вычислений в сетях связи пятого поколения, преспектив использования туманных вычислений в автономных транспортных средств.

**Вторая глава диссертации** посвящена применению методов глубокого обучения с использованием алгоритма долговременной краткосрочной памяти

LSTM и алгоритма двунаправленной LSTM (BI-LSTM) в многоуровневых граничных сетях автотранспорта. В таких сетях связи как автомобильные сети, прогнозирование потоков данных необходимо для автономных транспортных средств для улучшения передачи данных и уменьшения задержки. Предлагается подход глубокого обучения с двунаправленной моделью долговременной краткосрочной памяти (BI-LSTM) для прогнозирования интенсивности движения транспортных средств с многоуровневыми сервисами облачных вычислений. Точность прогнозирования рассчитывается с помощью среднеквадратичной ошибки (RMSE), средней абсолютной процентной ошибки (MAPE), коэффициента детерминации ( $R^2$ ) и времени обработки.

Предложен новый алгоритм, основанный на глубоком обучении для прогнозирования трафика в автономных транспортных средствах с многоуровневыми облачными вычислениями на основе двунаправленной модели с долговременной краткосрочной памяти) и LSTM (однонаправленная модель).

Модель глубокого обучения была построена на основе блоков LSTM и BI-LSTM для прогнозирования спроса, создали систему автономных транспортных средств 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.

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 1).



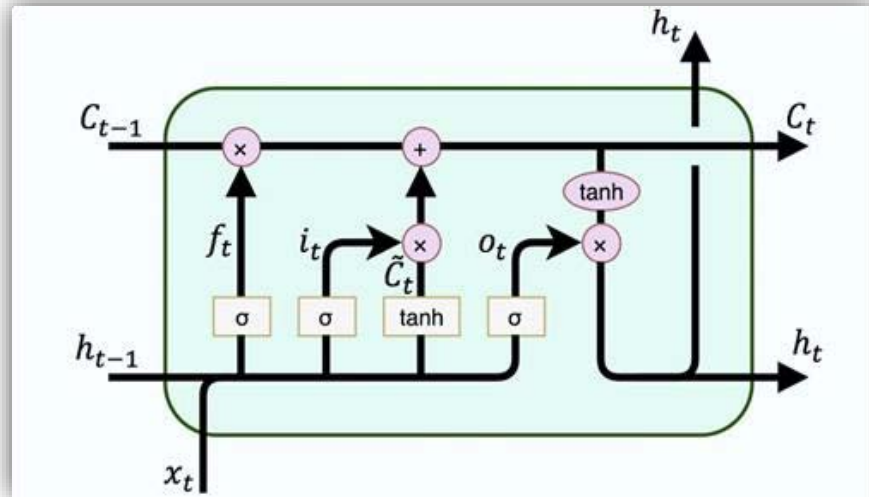


Рисунок 1 – Структура сети LSTM

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

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

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:

$$\tanh \tanh (x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (2)$$

Другие связи увеличивают связность модели. 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:

$$i_t = \sigma(w_i x_t + g_i h_{t-1} + b_i), \quad (3)$$

$$f_t = \sigma(w_f x_t + g_f h_{t-1} + b_f), \quad (4)$$

$$o_t = \sigma(w_o x_t + g_o h_{t-1} + b_o), \quad (5)$$

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:

$$C'_t = \tanh(w_c x_t + g_c h_{t-1} + b_c), \quad (6)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot C'_t, \quad (7)$$

$$h_t = o_t \odot \tanh(C'_t). \quad (8)$$

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

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. В каждый момент времени  $t$  вход подается на прямой и обратный пути сети LSTM.

Выход BI-LSTM может быть представлен следующим образом:

$$\vec{h}_t = H(W_1 x_t + W_2 \vec{h}_{t-1} + \vec{b}), \quad (9)$$

$$h^{\leftarrow}_t = H(W_3 x_t + W_5 \vec{h}_{t-1} + \vec{b}), \quad (10)$$

$$y_t = W_4 \vec{h}_t + W_6 h^{\leftarrow}_t + b_y, \quad (11)$$

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

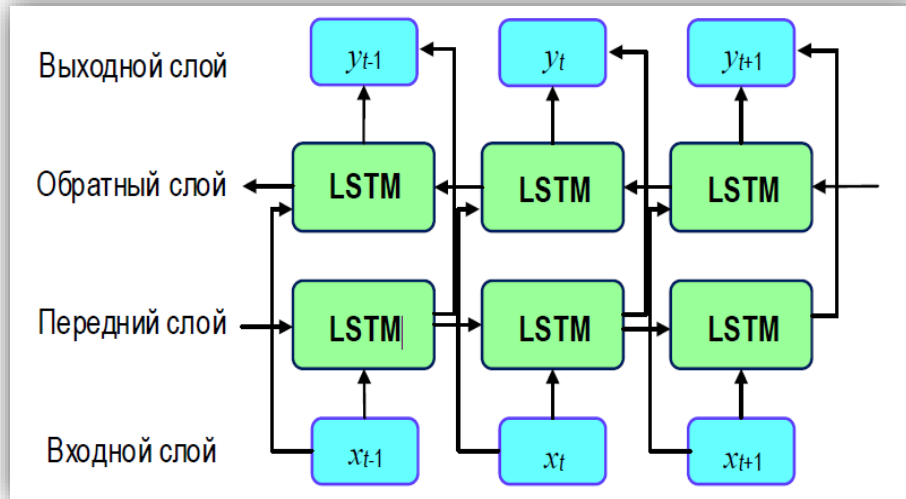


Рисунок 2 – Структура нейронной сети Bi-LSTM

На рисунке 2 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.

Структура моделируемой сети представляет собой некую реализацию метода очередей.

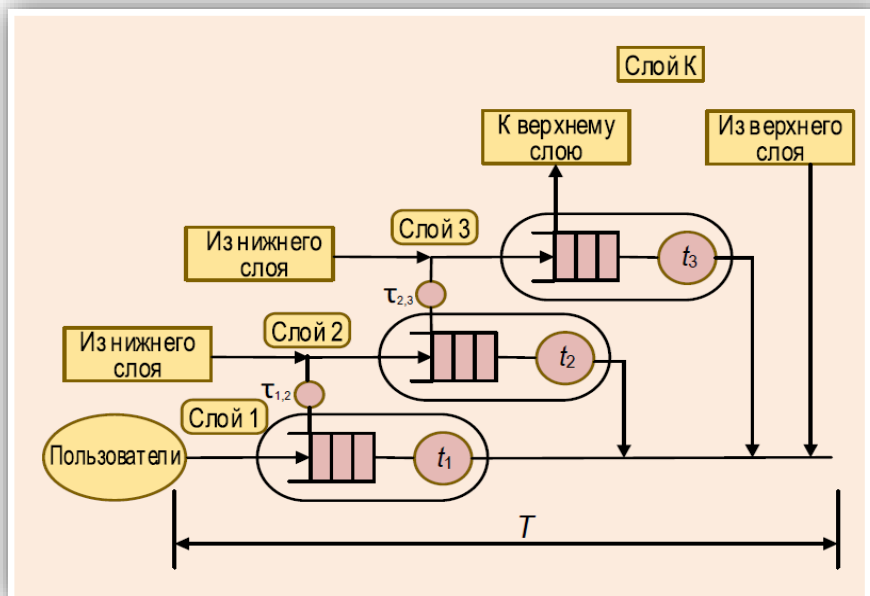


Рисунок 3 – Структура сети

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. 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  $T_m$ .

Таблица 1 – Точность прогнозирования трафика в среде сетей автотранспорта

Часть выборки	BI-LSTM				LSTM			
	RMSE	MAPE%	R <sup>2</sup>	Время обработки	RMSE	MAPE%	R <sup>2</sup>	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

Таблица 2 – Точность прогнозирования трафика в среде тумана

Часть выборки	BI-LSTM				LSTM			
	RMSE	MAPE%	R <sup>2</sup>	Время обработки	RMSE	MAPE%	R <sup>2</sup>	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 таблицах 1 и 2, при использовании части выборки (BatchSizes) = 8, точность прогнозирования превосходит конкурентов и имеет наилучшие показатели для BI-LSTM и LSTM сетей. Модель позволяет уменьшить корень среднеквадратичной ошибки на 60% в среде сетей автотранспорта, и на 95% в среде сетей автотранспорта с использованием движущегося тумана.

**В третьей главе** разработан метод прогнозирования скорости движения автотранспорта в зонах с интенсивным движением на основе движущего летающего тумана и стековой двунаправленной модели долговременной краткосрочной памяти (SBILSTM). Был предложен подход глубокого обучения с использованием

стековой двунаправленной модели долговременной краткосрочной памяти (SBILSTM).

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  $c$ . Первые ворота забывания определяют, какая часть состояния ячейки  $c_{t-1}$  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  $[0, 1]$ .

Структура стековой BILSTM показана на рисунке 4, а ее представление выглядит следующим образом:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \quad (12)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f), \quad (13)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o), \quad (14)$$

$$c_t = f_t * c_{t-1} + i_t * \tanh(W_c x_t + U_c h_{t-1} + b_c), \quad (15)$$

$$h_t = o_t * \tanh(c_t), \quad (16)$$

где  $\sigma$  – 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.

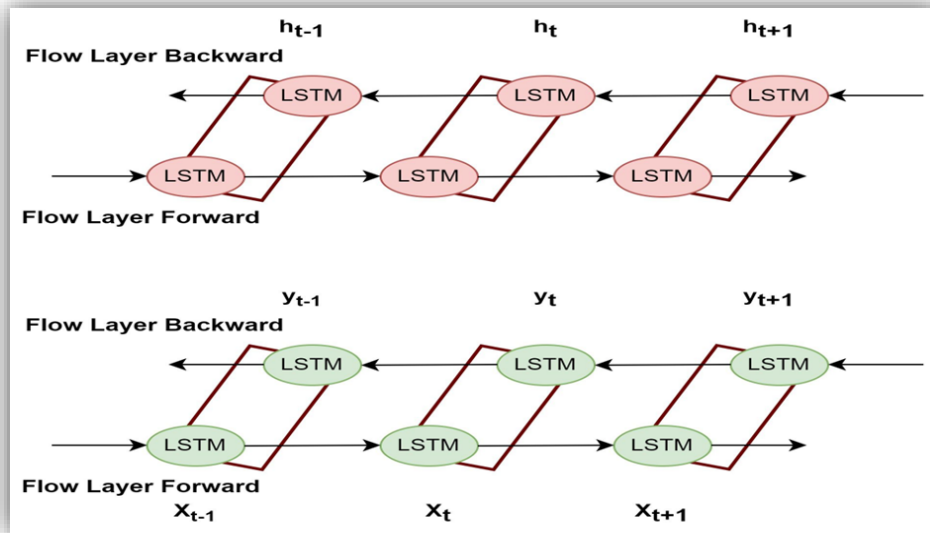


Рисунок 4 – Структура стековой BiLSTM(SBiLSTM)

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.

Для расчета точности прогнозирования использовались математические формы для RMSE, MAPE и  $R^2$ , как описано в уравнениях (17), (18) и (19).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (17)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{x_t} \right|, \quad (18)$$

$$R - squared = 1 - \frac{SS_{Regression}}{SS_{Total}} = 1 - \frac{\sum_i (y_i - \hat{y}_i)}{\sum_i (y_i - \underline{y}_i)}. \quad (19)$$

В таблице 3 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  $R^2$ .

Таблица 3 – Точность прогнозирования скорости движения автотранспорта в условиях летающего тумана

Оптимизатор Adam; Часть выборки (BatchSize) 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

Из приведенной выше таблицы видно, что модель прогнозирования с помощью стековой BILSTM модели, превосходит своих конкурентов и имеет наилучшие показатели. Метод прогнозирования скорости движения автотранспорта позволит уменьшить корень среднеквадратичной ошибки на 18%.

На рисунке 5 есть прогнозируемые 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.

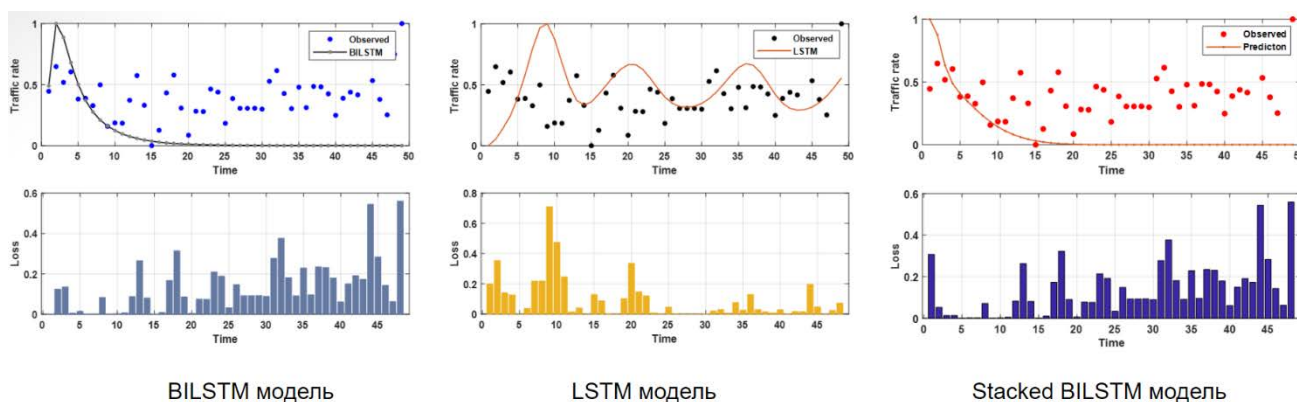


Рисунок 5 – Прогнозируемый выходной сигнал с использованием BILSTM, LSTM и Стековой моделей

**Четвертая глава** посвящена мониторингу трафика услуг беспилотных автомобилей в сетях связи пятого и последующих поколений для обнаружения и распознавания активности биологических объектов.

Взаимодействие различных элементов системы друг с другом должно обеспечиваться сетевой и вычислительной инфраструктурой сетей связи 5G, на рисунке 6 показаны элементы системы, а также их возможное взаимодействие.

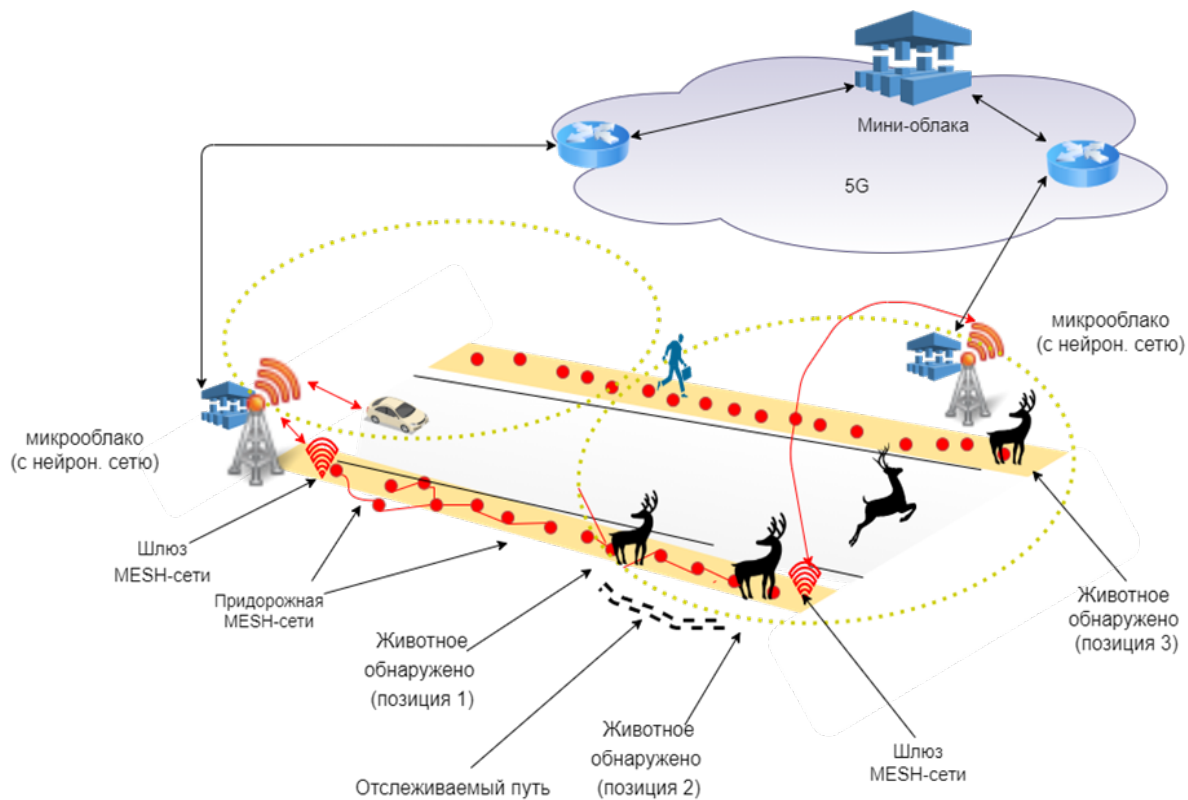


Рисунок 6 – Обобщенная архитектура

Одним из принципов, заложенных в требованиях к разрабатываемому решению, является осуществимость в условиях удаленности дорог от населенных пунктов, для выполнения этого требования предложено использовать новое поколение технологии LoRa, которое позволяет передавать данные с удаленных датчиков, расположенных вдоль дороги в несколько рядов.

На рисунке 7 показана карта датчиков в двух соседних зонах (2 соседних зон на трассе длиной каждой из них 4 метра).



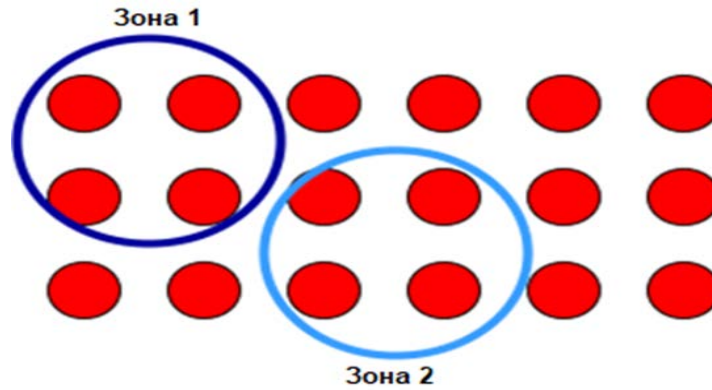


Рисунок 7 – Карта датчиков в зонах

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.

$$Ts = Ts_{1_1} - Ts_{1_2}, \quad (20)$$

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:

$$F = \sum_{n=0}^N F_n, N \in M, \quad (21)$$

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:

$$\Delta T_{avg} = \frac{\sum_{n=0}^N \Delta t_n}{N}, N \in M, \quad (22)$$

где  $\Delta t_n$  – дельта времени нажатия  $n$  датчиков

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

$$S = \sqrt{(N_{12} - N_{11})^2 + (N_{22} - N_{21})^2}, \quad (23)$$

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.

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 4.

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 рисунке 8, где «Пров. точность» обозначает процент правильных прогнозов для тестовых данных, а «Пров. потерь» результат плохого прогнозирования.

Таблица 4 – 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	$N_{(N+1)1}$	$TS_{(N+1)2}$	$F_{(N+1)3}$	$\Delta T_{avg_{(N+1)4}}$	$T_{(N+1)5}$

В дополнение к графикам, показанным на рисунке 8, была построена матрица ошибок обучения нейронной сети. Матрица ошибок (она также может называться матрицей путаницы) представлена на рисунке 9. На рисунке 9 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 проверку 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 рисунке 9. показывает, что сеть допустила ошибку три раза (три черных прямоугольника с единицами).

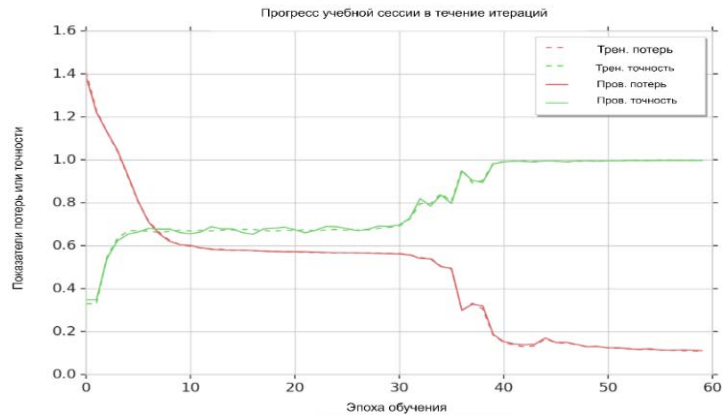


Рисунок 9 – Процесс машинного обучения

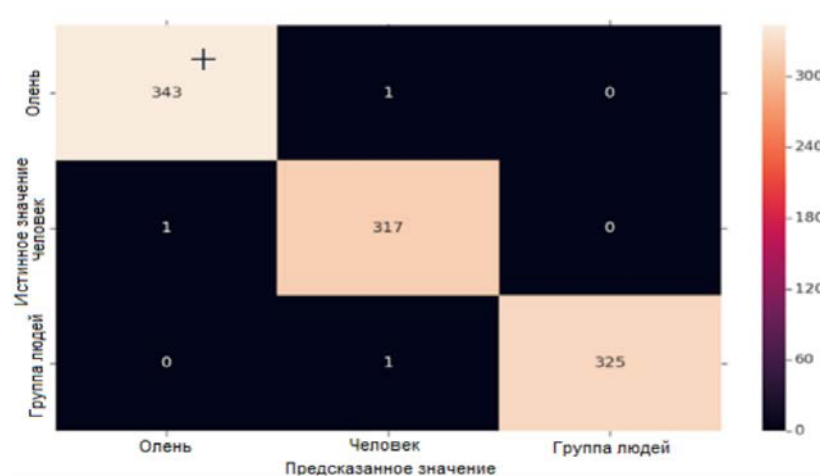


Рисунок 10 – Матрица ошибок

## 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 больше количество устройств и больше людей могут подключиться к интернету.

2. Проанализированы возможности использования методы туманных вычисления в сетях 5G для решения задач автономного управляемого транспорта, методы машинного обучения для определения данных необходимы для отправки в

облако, что уменьшить задержку при отправке данных в облако, определен круг задач в которых можно эффективно применить машинного и глубокого обучения 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.

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

4. Исследовано 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 MEC 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 ОПУБЛИКОВАННЫХ РАБОТ ПО ТЕМЕ ДИССЕРТАЦИИ**

### **Научные статьи, опубликованные в рецензируемых научных изданиях**

1. Аль-Свейти М. Методы машинного обучения для прогнозирования трафика в многоуровневой облачной архитектуре для сервисов автономных транспортных средств // Труды учебных заведений связи. 2022. Т. 8. № 4. С. 89-99.
2. Аль-Свейти М.А. Система обнаружения и распознавания движущихся биологических объектов для беспилотных автомобилей на основе интеллектуальных граничных вычислений / Аль-Свейти М.А., Мутханна А.С., Бородин А.С., Кучерявый А.Е. // Электросвязь. 2021. № 9. С. 35-41.

### **Научные статьи, опубликованные в изданиях, индексируемых в международных базах данных**

3. Al-Sveiti M. Detection and recognition of moving biological objects for autonomous vehicles using intelligent edge computing/lorawan mesh system / Artem V., Al-Sveiti M., Muthanna A., Elgendy I.A., Kovtunen A.S. // Lecture Notes in Computer Science. 2020. Т. 12526 LNCS. С. 3-15.
4. AlSweity, M., Muthanna, A., Elgendy, I.A., Koucheryavy, A. (2021). Traffic Management Algorithm for V2X-Based Flying Fog System // In: Vishnevskiy, V.M., Samouylov, K.E., Kozyrev, D.V. (eds) Distributed Computer and Communication Networks: Control, Computation, Communications. DCCN 2021. Lecture Notes in Computer Science(), vol 13144. Springer, Cham.

### **Научные статьи, опубликованные в других изданиях и материалах научных конференций**

5. Аль-Свейти Малик А.М. Сравнительный анализ технологий C-V2X и DSRC / Аль-Свейти Малик А.М., Мутханна А.С.А. // Актуальные проблемы инфотелекоммуникаций в науке и образовании (АПИНО 2022). XI Международная научно-техническая и научно-методическая конференция. Санкт-Петербург, 2022. С. 75-79.
6. Аль-Свейти Малик А.М. Сценарии и методы применения бпла в концепции автономного управляемого транспорта / Аль-Свейти Малик А.М., Мутханна А.С.А. // Актуальные проблемы инфотелекоммуникаций в науке и образовании (АПИНО 2022). XI Международная научно-техническая и научно-методическая конференция. Санкт-Петербург, 2022. С. 79-82.

7. Аль-Свейти Малик А.М. Модель выгрузки трафика в многоуровневой системе пограничных вычислений для беспилотных автомобилей / Аль-Свейти Малик А.М., Коваленко В.Н., Мутханна А.С.А. // Информационные технологии и телекоммуникации. 2022. Т. 10. № 1. С. 1-8.

8. Аль-Свейти Малик А.М. Архитектура сети автотранспорта на основе БПЛА, SDN и гетерогенных граничных вычислений / Коваленко В.Н., Аль-Свейти Малик А.М., Мутханна А.С.А. // Информационные технологии и телекоммуникации. 2022. Т. 10. № 2. С. 25-35.

9. Аль-Свейти М.А.М. Проблемы и требования для реализации технологии V2X / Аль-Свейти М.А.М., Волков А.Н., Мутханна А.С.А. // Информационные технологии и телекоммуникации. 2020. Т. 8. № 3. С. 20-26.

10. Аль-Свейти М. Исследование современных методов ускорения видеотрафика с использованием граничных облачных вычислений / Аль-Свейти М., Мутханна А.С.А. // Актуальные проблемы инфотелекоммуникаций в науке и образовании (АПИНО 2019). сборник научных статей VIII Международной научно-технической и научно-методической конференции : в 4 т. 2019. С. 47-50.