

На правах рукописи

Мохамед Али Рефае Абделлах

**ПРОГНОЗИРОВАНИЕ ХАРАКТЕРИСТИК ТРАФИКА
ДЛЯ СЕТЕЙ 5G НА ОСНОВЕ ТЕХНОЛОГИЙ
ИСКУССТВЕННОГО ИНТЕЛЛЕКТА**

2.2.15. Системы, сети и устройства телекоммуникаций

Автореферат
диссертации на соискание ученой степени
кандидата технических наук

Санкт-Петербург – 2022

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: доктор технических наук, профессор
Кучерявый Андрей Евгеньевич

Официальные оппоненты:

Татарникова Татьяна Михайловна,
доктор технических наук, профессор,
Санкт-Петербургский государственный
электротехнический университет «ЛЭТИ»
им. В.И. Ульянова (Ленина), кафедра
информационных систем, профессор кафедры

Степанов Михаил Сергеевич,
кандидат технических наук ,
Московский технический университет связи
и информатики, кафедра сетей связи и систем
коммутации, доцент кафедры

Ведущая организация:

Федеральное государственное автономное
образовательное учреждение высшего образования
«Российский университет дружбы народов»,
г. Москва

Защита состоится 15 июня 2022 года в 16.00 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.

Автореферат разослан 15 апреля 2022 года.

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

М.А. Маколкина

ОБЩАЯ ХАРАКТЕРИСТИКА ДИССЕРТАЦИИ

Актуальность темы диссертации. Задачи прогнозирования характеристик трафика всегда занимали и занимают приоритетное место в исследованиях по сетям связи. Действительно, эффективность функционирования сетей связи в большой степени зависит от распределения ресурсов сети для обслуживания трафика, и достигнуть эффективного функционирования сети практически невозможно без знания характеристик трафика и прогноза их изменения. Еще в большей степени возрастает роль прогнозирования характеристик трафика при переходе к гетерогенным сетям связи пятого и последующих поколений. Действительно, гетерогенный характер таких сетей требует и дифференцированного подхода к прогнозированию характеристик трафика. Для прогнозирования характеристик трафика, например, сетей автомобильного трафика VANET (Vehicular Ad Hoc Networks) в условиях высокоскоростного перемещения пользователей требуется один подход, а, скажем, для прогнозирования характеристик трафика Интернета Вещей в сверхплотных сетях с очень большим числом устройств совсем иной.

И решение такого комплекса задач могло бы не только потребовать очень много времени, но и унификация решений для таких сложных гетерогенных сетей представлялась бы весьма сомнительной. Однако в настоящее время все более и более набирает силу использование прикладных технологий искусственного интеллекта в разнообразных задачах в различных отраслях хозяйственной деятельности. И здесь естественным выбором является исследование проблем прогнозирования трафика для гетерогенных сетей связи пятого и последующих поколений на основе технологий искусственного интеллекта.

В диссертации предложено использовать машинное обучение и глубокое обучение для решения задач прогнозирования пропускной способности сетей связи пятого и последующих поколений в условиях внедрения Интернета Вещей, потерь и задержек в сетях связи пятого и последующих поколений применительно к сетям Интернета Вещей и Тактильного Интернета, пропускной способности и потерь в автомобильных сетях VANET.

Исходя из сказанного, тема диссертационной работы, посвященная исследованию методов прогнозирования характеристик трафика в сетях связи пятого поколения на основе технологий искусственного интеллекта, представляется актуальной.

Степень разработанности темы. В области прогнозирования характеристик трафика в сетях различных поколений существует достаточно много работ отечественных и зарубежных ученых В.М. Вишневского, Б.С. Гольдштейна, В.Г. Карташевского, А.Е. Кучерявого, А.И. Парамонова, К.Е. Самуйлова, С.Н. Степанова, Т.М. Татарниковой, В.О. Тихвинского, Ю.В. Гайдамаки, Р.В. Киричка,

Е.А. Кучерявого, М.А. Маколкиной, Д.А. Молчанова, А.С.А. Мутханны, А.А.А. Ateya, G.P. Fettweis, M. Dohler, M. Maier, Z. Li, M. Uusitalo, H. Sharariatmadari, B. Singh, P. Popovski и других.

Отмеченные выше работы внесли весомый вклад в исследования в области прогнозирования характеристик трафика. Однако до настоящего времени практически отсутствовали работы, в которых прогнозирование характеристик трафика осуществлялось бы на основе машинного и глубокого обучения как единой научной базы для гетерогенных сетей связи, включая сети VANET, Интернета Вещей и Тактильного Интернета. Комплекс таких задач в целом и определяет цель, задачи, объект и предмет диссертационной работы.

Объект и предмет диссертации. Объектом исследования являются сети связи пятого поколения, а предметом – разработка методов прогнозирования характеристик трафика для них.

Цель и задачи диссертации. Цель диссертационной работы состоит в разработке методов прогнозирования характеристик трафика VANET, Интернета Вещей и Тактильного Интернета в сетях связи 5G на основе применения машинного и глубокого обучения с использованием робастных оценок, что должно повысить точность прогнозирования при наличии выбросов в наблюдаемых данных.

Указанная цель достигается путем решения в диссертационной работе следующих задач:

- анализ принципов построения и предоставляемых пользователям услуг в сетях 5G,
- анализ возможности применения машинного и глубокого обучения для прогнозирования характеристик трафика в сетях 5G,
- анализ различных робастных оценок для возможности использования при прогнозировании трафика в сетях 5G,
- разработка метода прогнозирования потерь пакетов в сети VANET в условиях искажения собираемых данных гауссовским шумом и случайными выбросами,
- определение наилучшего робастного алгоритма обучения с обратным распространением для прогнозирования потерь пакетов в сети VANET,
- разработка метода прогнозирования потерь пакетов в сетях связи 5G для Интернета Вещей и Тактильного Интернета,
- определение наилучшего робастного алгоритма обучения с обратным распространением для прогнозирования потерь пакетов в сетях связи 5G для Интернета Вещей и Тактильного Интернета,
- разработка метода прогнозирования задержки в сетях связи 5G для Интернета Вещей и Тактильного Интернета,

– определение наилучшего робастного алгоритма обучения с обратным распространением для прогнозирования задержки в сетях связи 5G для Интернета Вещей и Тактильного Интернета,

– разработка методов прогнозирования пропускной способности в сетях связи 5G для Интернета Вещей и для сети VANET.

Научная новизна полученных результатов состоит в следующем:

– В отличие от известных методов прогнозирования потерь пакетов в сетях VANET предложено использовать многослойную нейронную сеть глубокого обучения и робастную справедливую оценку и робастную оценку Коши в условиях, когда данные искажены гауссовским шумом и случайными выбросами.

– В отличие от известных методов прогнозирования задержки и потерь для Интернета Вещей и Тактильного Интернета предложено для прогнозирования использовать машинное обучение на основе нелинейной рекуррентной авторегрессионной нейронной сети NARX и доказано, что наилучшие результаты при ее обучении достигаются при использовании алгоритма Левенберга-Марквардта, превосходя при этом алгоритм обучения Флетчера-Ривса и устойчивый алгоритм обучения по значениям срднеквадратичной ошибки и абсолютной ошибки на порядок и более как при прогнозировании на один шаг, так и при прогнозировании на несколько шагов.

– В отличие от известных методов прогнозирования предложено для прогнозирования пропускной способности сетей 5G для трафика Интернета Вещей использовать глубокое обучение и алгоритм долговременной краткосрочной памяти (LSTM), что обеспечивает результаты прогноза с приемлемой для практики точностью при 500 скрытых нейронах.

Теоретическая и практическая значимость диссертации.

Теоретическая значимость диссертационной работы состоит, прежде всего, в применении робастных оценок для прогнозирования потерь пакетов в условиях сети VANET, когда данные искажены гауссовским шумом и случайными выбросами. Применение нелинейных рекуррентных авторегрессионных нейронных сетей для прогнозирования задержки и потерь в сетях Интернета Вещей и Тактильного Интернета также значимо для прогнозирования трафика в сетях связи пятого и последующих поколений. Кроме того, предложено использовать для прогнозирования пропускной способности сетей 5G для трафика Интернета Вещей глубокое обучение и алгоритм долговременной краткосрочной памяти (LSTM).

Практическая значимость диссертационной работы состоит в том, что полученные новые научные результаты могут быть использованы при планировании сетей связи для Интернета Вещей и Тактильного Интернета, а также при обучении в университетах.

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 и проведении практических занятий по курсам «Интернет Вещей», «Современные проблемы науки в области инфокоммуникаций», «Машинное и глубокое обучение в телекоммуникациях» и «Искусственный интеллект в сетях и системах связи».

Методология и методы исследования. Для решения поставленных в диссертации задач использовались методы теории вероятностей, теории телетрафика, машинного и глубокого обучения, математической статистики.

Основные положения, выносимые на защиту:

1. Разработанный метод прогнозирования потерь пакетов в сетях VANET на основе глубокого обучения и многослойной нейронной сети в условиях, когда данные искажены гауссовским шумом и случайными выбросами при использовании робастной справедливой оценки и робастной оценки Коши позволяет уменьшить среднеквадратичную ошибку более, чем в пять раз, а абсолютную ошибку примерно в 2 раза по сравнению с использованием метода наименьших квадратов.

2. Разработанный метод прогнозирования задержки и потерь в сетях Интернета вещей и Тактильного Интернета на основе нелинейной рекуррентной авторегрессионной нейронной сети NARX дает наилучшие результаты при его обучении алгоритмом Левенберга-Марквардта, превосходя при этом алгоритм обучения Флетчера-Ривса и устойчивый алгоритм обучения по значениям среднеквадратичной ошибки и абсолютной ошибки на порядок и более как при прогнозировании на один шаг, так и при прогнозировании на несколько шагов.

3. Разработанный метод прогнозирования пропускной способности сетей 5G/6G для трафика Интернета Вещей на основе алгоритма долговременной краткосрочной памяти (LSTM) обеспечивает результаты прогноза с приемлемой для практики точностью при 500 скрытых нейронах.

Степень достоверности и апробация результатов.

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

Апробация результатов. Основные результаты диссертационной работы докладывались и обсуждались на следующих международных и российских конференциях и семинарах: конференциях Internet of Things, Smart Spaces, and Next Generation Networks and Systems (NEW2AN, Санкт-Петербург, 2019–2021), International conference on Distributed Computer and Communication Networks: Control, Computation,

Communications (DCCN, Москва, 2019, 2020), 11th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT, Dublin, Ireland, 2019), 12th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT, Brno, Czech Republic, 2020), 75-й конференции СПбНТОРЭС им. А.С. Попова (Санкт-Петербург, 2020), X Юбилейной международной научно-технической и научно-методической конференции «Актуальные проблемы инфокоммуникаций в науке и образовании» (АПИНО, Санкт-Петербург, 2021), а также на семинарах кафедры сетей связи и передачи данных СПбГУТ.

Публикации по теме диссертации. Всего по теме диссертации опубликовано 18 работ, из них 3 статьи в рецензируемых научных журналах, входящих в перечень изданий, рекомендуемых ВАК Министерства высшего образования и науки Российской Федерации, 12 статей в рецензируемых изданиях, входящих в международные базы данных SCOPUS и WoS (1 статья в Q1 и 4 статьи в Q2), 3 статьи в журналах и сборниках конференций, включенных в РИНЦ.

Соответствие паспорту специальности. Содержание диссертации соответствует пп. 3, 11, 12 и 14 паспорта специальности 05.12.13 – Системы, сети и устройства телекоммуникаций.

Личный вклад автора. Основные результаты диссертации получены автором самостоятельно.

Структура и объем диссертации. Диссертация состоит из введения, четырёх глав, заключения, списка литературы и 1 приложения. Общий объём работы – 146 страниц машинописного текста, из них основного текста 143 страниц. Работа содержит 34 рисунка и 7 таблиц. Список литературы включает 83 источника.

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, перспектив использования технологий искусственного интеллекта в сетях связи пятого поколения, особенностей машинного и глубокого обучения, искусственных нейронных сетей.

Вторая глава диссертации посвящена применению машинного глубокого обучения с использованием робастных М-оценок для сетей автомобильного транспорта VANET. В таких сетях связи как автомобильные сети вследствие высоких

скоростей перемещения узлов сети в сложных условиях городской застройки, собранные для прогноза данные, могут содержать как данные гауссового шума, так и случайные выбросы. В связи с этим необходимо в задачах прогнозирования характеристик трафика исследовать возможность и эффективность использования робастных оценок максимального правдоподобия – М-оценок.

Предложен новый алгоритм, основанный на глубоком обучении, для оценки производительности сети VANET (потерь пакетов) с использованием робастных М-оценок вместо традиционной оценки среднеквадратической ошибки MSE (Mean Square Error) при наличии выбросов, которые искажают данные обучения. При этом используется трехслойная нейронная сеть прямого распространения, причем скрытый слой содержит 100 скрытых нейронов (рис.1).

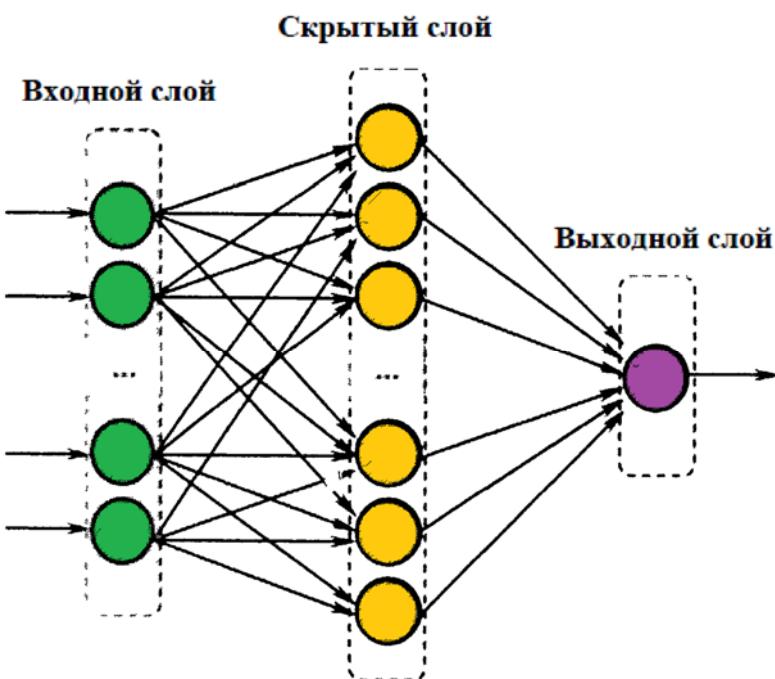


Рисунок 1 – Трехслойная нейронная сеть прямого распространения

Набор данных трафика VANET был создан на основе моделирования среды VANET. Набор данных был дифференцирован на подмножество обучения, тестирования и проверки как 70%, 15% и 15% данных соответственно. Модель глубокой нейронной сети DNN (Deep Neural Network) была разработана для оценки производительности VANET. Обучение DNN проводилось с помощью робастного алгоритма обратного распространения. Сравнивались характеристики производительности при использовании робастных и традиционных DNN в отношении RMSE и MAPE для каждой модели.

Производительность сети VANET при использовании глубокого обучения и соответствующей нейронной сети DNN была изучена для трех случаев при различном значении процента выбросов:

Набор А: DNN обучается на высококачественных чистых данных без шума.

Набор В: сеть обучается на идеальных данных, загрязненных небольшим гауссовским шумом (GN): $G \sim N(0, 0,1)$.

Набор С: DNN обучается на данных, загрязненных GN, $G \sim N(0,0,1)$, в дополнение к рандомизированным выбросам вида: $H_1 \sim N(+15, 2)$, $H_2 \sim N(-20, 3)$, $H_3 \sim N(+30, 1,5)$, $H_4 \sim N(-12, 3)$.

Зашумление данных, используемое в этом случае, выглядит следующим образом:

$$\text{Данные} = (1-\varepsilon) G + \varepsilon(H_1+H_2+H_3+H_4).$$

При этом $\varepsilon = 10\%$ данных.

Набор данных, используемый для этого эксперимента, был сгенерирован на модели сети V2X. Затем точки данныхискажались в координатах x и у гауссовским шумом со средним значением равным нулю и стандартным отклонением 0,1, $G \sim N(0,0,1)$. Переменная ε точек данных был выбрана случайным образом, а затем заменена с вероятностью ε фоновым шумом, равномерно распределенным в определенном диапазоне.

Архитектура DNN представляет собой многослойную нейронную сеть прямого распространения MFNN, состоящую из трех слоев с одним скрытым слоем, содержащим 100 скрытых нейронов, как это показано на рис.2.4. Сеть обучена с помощью робастного алгоритма обратного распространения BP (Back Propagation) с использованием ранее упомянутых функций потерь. Для модели глубокого обучения DL (Deep Learning) были выбраны наиболее подходящие архитектурные параметры (например, размер пакета, эпохи, функция активации, функция потерь, скорость обучения, минимальные потери). В диссертационной работе выбран размер пакета 32, эпохи 5000, функция обучения — Traincfg, скорость обучения 1e-3 и минимальные потери 1e-3. В качестве функции активации для всех нейронов в скрытых слоях была выбрана сигмоидная функция (Tansig), а в качестве функции активации для нейрона в выходном слое была выбрана линейная функция активации.

Нормализация входных данных должна быть в интервале $[-1, 1]$, который соответствует фактическим минимальным и максимальным значениям. DNN может оценить оптимальную производительность сети VANET на основе собранного набора данных VANET, используя пропускную способность VANET в качестве входных данных и потерь пакетов в качестве выходных данных (прогнозируемый результат). Цель состоит в том, чтобы разработать робастную нейронную сеть DNN, которая может оценивать производительность VANET, когда данные содержат выбросы. Было использовано сравнительное исследование робастных и традиционных DNN относительно среднеквадратичной ошибки RMSE и средней абсолютной ошибки в процентах MAPE, чтобы доказать, какие оценки дают лучшие результаты для анализируемого приложения:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (t_i - y_i)^2}{N}}, \quad (1)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{t_i - y_i}{t_i} \right|, \quad (2)$$

где n – общее число точек данных, t_i – действительная величина, в то время как y_i – прогнозируемое значение.

Таблица 1 показывает значения RMSE и MAPE для сетей, обученных на основе MSE, робастных справедливых оценок (Fair) и робастных оценок Коши (Cauchy) для оценки трафика VANET.

Таблица 1 – Значения RMSE и MAPE для сетей, обученных на основе MSE, справедливых оценок и оценок Коши для оценки трафика VANET

Функция потерь	Набор А		Набор В		Набор С	
	RMSE	MAPE%	RMSE	MAPE%	RMSE	MAPE%
MSE	0.0156	1.3	0.1786	10.6	0.5179	16.7
Cauchy	0.0194	1.5	0.0630	5.4	0.0923	9.8
Fair	0.0132	1.1	0.0740	6.2	0.0756	8.6

Как видим, при использовании робастной справедливой оценки и робастной оценки Коши среднеквадратичная ошибка более, чем в пять раз, а абсолютная ошибка примерно в 2 раза меньше по сравнению с использованием метода наименьших квадратов.

В третьей главе разработан метод прогнозирования сетевого трафика (коэффициента потери пакетов) с использованием подхода прогнозирования на несколько шагов вперед MSP (Multi Step Prediction) на основе рекуррентной нейронной сети RNN (Recurrent Neural Network) и нелинейной авторегрессионной модели с внешними входами NARX (Nonlinear AutoRegressive eXogenous). В таких задачах требуется прогнозирование временных рядов, поскольку необходимо прогнозирование следующих значений системы на основе предыдущей и текущей информации.

В главе также разработан метод прогнозирования задержки в IoT (Internet of Things) и Тактильном Интернете с использованием прогнозирования на несколько шагов вперед MSP и прогнозирования на один шаг вперед SSP (Simple Step Prediction) с рекуррентной нейронной сетью NARX. Точность прогноза при этом будет оценена с использованием трех алгоритмов обучения нейронной сети: Trainlm (Алгоритм обучения Левенберга-Марквардта с обратным распространением), Traincgv (Алгоритм обучения сопряженных градиентов Флетчера – Ривса с обратным распространением и обновлениями), Trainrp (Устойчивый алгоритм обучения с обратным распространением) с MSE по значениям среднеквадратичной ошибки (RMSE) и средней абсолютной процентной ошибки (MAPE) в качестве меры точности прогноза.

Сети NARX лучше работают с прогнозами, когда прогнозируемый результат зависит от входных данных, которые существуют в прошлые моменты времени.

Потенциальные значения для временной последовательности $y(n+1)$ предсказываются на основе прошлых значений для этой временной последовательности и конечной меры для временной последовательности $u(n)$:

$$y(n+1) = f[y(n); u(n)]. \quad (3)$$

Здесь $y(n) \in R$ и $u(n) \in R$ определяют входные и выходные параметры модели в момент времени (n) соответственно. Кроме того, $y(n)$ и $y(n+1)$ являются истинным и прогнозируемыми выходными элементами соответственно.

На рисунке 2 представлена архитектура нейронной сети NARX, где d_y и d_u – временные задержки выходных и входных переменных.

Как правило, прогнозирование временных рядов определяет прогнозирование фактических данных для следующего временного шага. Это называется одношаговым прогнозированием, разомкнутым циклом или прогнозированием на один шаг вперед (SSP), поскольку можно прогнозировать только один временной шаг. Одношаговое ($n+1$) прогнозирование выполняется путем передачи текущей и предыдущей точек данных ($n, n-1, \dots, n-k$).

В К-шаговом прогнозировании одна и та же модель используется повторно для прогнозирования всех выходных значений. Модель прогнозирования в этом методе можно описать следующим уравнением:

$$y(n+k) = f(y(n), y(n-1), \dots, y(n-k_y), u(n), x(n-1), \dots, u(n-k_u)), \quad (4)$$

где $y(n+k)$ – прогнозируемый результат, k_u – количество входных задержек (единичная задержка), а k_u – количество выходных задержек.

Метод прогнозирования на несколько шагов вперед предсказывает будущие значения известной временной последовательности шаг за шагом. Сначала прогнозируется $u(n+1)$ на основе предыдущих значений $x, u(n+1-x), \dots, u(n-1), u(n)$, затем прогнозируется $u(n+2)$ в зависимости от прошлых значений x , которые содержат прогнозируемое значение для $u(n+1)$. Процесс повторяется до тех пор, пока не будет оценено последнее значение $u(n+h)$.

Далее в главе представлены три алгоритма обучения, которые использованы при сравнении эффективности использования NARX при прогнозировании потерь и задержки.

Алгоритм Левенберга-Марквардта был разработан для аппроксимации скорости обучения второго порядка без вычисления матрицы Гессе. Если функция потерь

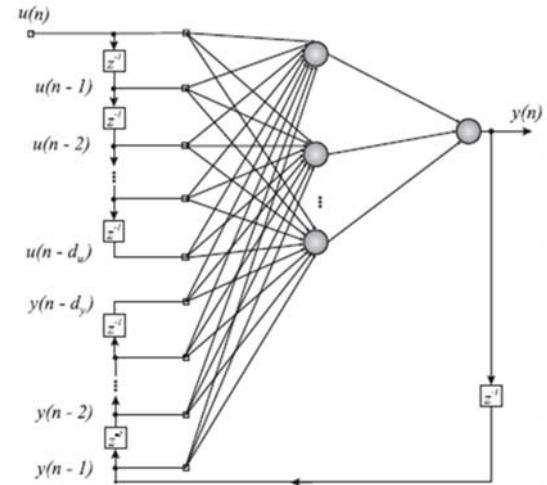


Рисунок 2 – Архитектура нейронной сети NARX

представлена в виде суммы квадратов (что типично при обучении сетей с прямым распространением), то матрица Гессе может быть аппроксимирована следующим образом:

$$H = J^T J. \quad (5)$$

Градиент при этом может быть вычислен как:

$$g = J^T e, \quad (6)$$

где J – матрица Якоби, содержащая первые производные сетевых ошибок по весам и смещениям, а e – вектор сетевых ошибок. Матрица Якоби может быть вычислена стандартным методом обратного распространения ошибки, который намного менее сложен, чем вычисление матрицы Гессе.

Алгоритм Левенберга-Марквардта использует это приближение к матрице Гессе в следующем ньютоновском обновлении:

$$X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T e. \quad (7)$$

Когда скаляр μ равен нулю, это просто метод Ньютона, использующий приближенную матрицу Гессе. Когда μ велико, он становится градиентным спуском с малым размером шага. Метод Ньютона быстрее и точнее вблизи минимума ошибки, поэтому цель состоит в том, чтобы как можно быстрее перейти к методу Ньютона. Следовательно, μ уменьшается после каждого успешного шага (уменьшение функции потерь) и увеличивается только тогда, когда шаг улучшит функцию потерь. Таким образом, функция потерь непрерывно уменьшается на каждой итерации алгоритма.

Алгоритм сопряженного градиента Флэтчера – Ривса с обновлениями выполняет поиск в направлении наискорейшего спуска (отрицательный градиент) на первой итерации:

$$P_0 = -g_0. \quad (8)$$

Затем выполняется линейный поиск, чтобы определить оптимальное расстояние для перемещения в текущем направлении поиска:

$$X_{k+1} = X_k - \alpha_k P_k. \quad (9)$$

Затем определяется следующее направление поиска таким образом, чтобы оно было сопряжено с предыдущими направлениями поиска. Общая процедура определения нового направления поиска заключается в объединении нового направления наискорейшего спуска с последним поиском направления:

$$P_k = -g_k + \beta_k P_{k-1}. \quad (10)$$

Различные версии алгоритмов сопряженного градиента различаются тем, как вычисляется константа β_k . Для обновления алгоритма Флэтчера-Ривза используется следующая процедура:

$$\beta_k = \frac{g_k^T g_k}{g_{k-1}^T g_{k-1}}. \quad (11)$$

Многослойные сети обычно используют сигмоидные передаточные функции в скрытых слоях. Эти функции часто называют «сжатием», потому что они сжимают бесконечный диапазон ввода в конечный диапазон вывода. Сигмоидные функции характеризуются тем, что их наклоны должны стремиться к нулю, когда входные данные становятся большими. Это вызывает проблему, когда вы используете метод наискорейшего спуска для обучения многослойной сети с помощью сигмоидных функций. Градиент может иметь минимальную величину и, следовательно, вызывать небольшие изменения весов и смещений, даже если они далеки от оптимальных значений.

Цель устойчивого алгоритма обучения с обратным распространением Trainrp состоит в том, чтобы устранить эти вредные эффекты величин частных производных. Только знак производной используется для определения направления обновления веса; величина производной не влияет на обновление веса. Отдельное значение обновления определяет величину изменения веса. Однако производительность ухудшается по мере уменьшения цели ошибки. Далее рассмотрим прогнозирование задержки для Интернета Вещей и Тактильного Интернета на основе рекуррентной нейронной сети NARX с использованием прогнозирования на один шаг и на несколько шагов вперед. Моделирование проводилось на процессоре Intel (R) Core™ i5-3210M с тактовой частотой 2,40 ГГц и 6 ГБ памяти. Был использован пакет моделирования Matlab R2020a для прогнозирования задержки с использованием прогнозирования на один шаг вперед (SSP) и на несколько шагов вперед (MSP) с применением рекуррентных нейронных сетей NARX.

Точность прогнозирования оценивалась с использованием трех алгоритмов обучения нейронной сети: Trainlm, Traincgf, и Trainrp, с точки зрения использования, а корень из среднеквадратичной ошибки (RMSE) и средняя абсолютная ошибка в процентах (MAPE) в качестве меры точности прогнозирования.

Наборы данных были сгенерированы для модели модели IoT и Тактильного Интернета с помощью системы моделирования AnyLogic. После сбора и подготовки набора данных он был разделен на 70% для обучения, 15% для тестирования и 15% для валидации соответственно.

В таблице 2 показана точность прогнозирования значения задержки в трех случаях в соответствии с алгоритмами обучения Trainlm, Traincgf и Trainrp при использовании в качестве мер точности прогнозирования RMSE и MAPE.

Как видим, алгоритм обучения нейронной сети Левенберга-Марквардта с обратным распространением Trainlm имеет лучшую точность прогнозирования и с RMSE, и с MAPE как при прогнозировании на один шаг вперед, так и при прогнозировании на несколько шагов вперед.

Таблица 2 – Точность прогнозирования при оценке задержки

Алгоритм обучения	Прогнозирование на шаг вперед		Прогнозирование на несколько шагов вперед	
	RMSE	MAPE	RMSE	MAPE
Trainlm	0.0551	0.0429	0.0521	0.1301
Traincfg	0.2163	0.5178	0.3704	3.2367
Trainrp	1.4734	0.7245	0.6996	4.7953

Точность прогнозирования в случае использования алгоритма обучения сопряженных градиентов Флетчера-Ривса с обратным распространением и обновлениями для обучения нейронной сети Traincfg занимает промежуточное место, а при использовании устойчивого алгоритма обучения нейронной сети с обратным распространением Trainrp получаем самую низкую точность прогнозирования и с RMSE, и с MAPE, как при прогнозировании на один шаг вперед, так и прогнозировании на несколько шагов вперед.

Четвертая глава посвящена прогнозированию пропускной способности в сетях связи пятого и последующих поколений на основе глубокого обучения.

В этой главе разработан метод прогнозирования временных рядов трафика IoT с использованием глубокого обучения нейронной сети (DNN) на основе сети долговременной краткосрочной памяти LSTM (Long Short-term Memory). Точность прогноза оценивается с использованием среднеквадратичной ошибки (RMSE) и абсолютной ошибки (MAPE). Предложено три модели глубокого обучения в зависимости от числа скрытых нейронов в слое LSTM, чтобы исследовать влияние изменения числа скрытых нейронов в глубоком обучении LSTM на точность прогнозирования.

Кроме того, разработан также метод прогнозирования временных рядов с использованием LSTM с глубоким обучением для трафика VANET. При этом, исследованы проблемы прогнозирования в разных случаях в зависимости от числа отправленных пакетов: 4 пакета/с, 6 пакетов/с, 8 пакетов/с, 10 пакетов/с, 12 пакетов/с и 14 пакетов/с. Отметим, что LSTM более эффективен и быстрее подбирает данные, чем обычные модели временных рядов. Точность предсказания оценивается, как и в предыдущих главах, с использованием RMSE и MAPE.

В отличие от обычных нейронных сетей, сеть LSTM хорошо подходит для изучения задач классификации, обработки и прогнозирования временных рядов, когда важные события разделены временными задержками неопределенной продолжительности и границ. Относительная нечувствительность к длительности временных промежутков дает LSTM преимущество перед альтернативными рекуррентными нейронными сетями, скрытыми марковскими моделями и другими методами обучения временных рядов в различных областях применения. Архитектура LSTM, показанная на рисунке 3, состоит из трех фильтров ячейки: забывание, ввод и

вывод. Они представляют собой сигмоидные функции, которые принимают значения в диапазоне [0,1] и передают информацию в ячейку и из нее с последующим умножением процесса для определения того, следует ли помнить или забывать прошлую информацию. LSTM широко используется для реализации распознавания речи, управления роботом и во многих других задач прогнозирования. После того, как входные данные вошли в структуру LSTM, часть памяти была сохранена для дальнейшего использования. Мы можем использовать метки входных данных для выполнения классификации, регрессии или прогнозирования. Важным компонентом LSTM является состояние ячейки, линия, которая проходит из памяти предыдущего блока (C_{t-1}) в память текущего блока (C_t), позволяя информации течь непосредственно по линии. Сеть может сама решать, сколько данных она хочет пересылать. В состоянии ячейки C_{t-1} для каждого числа является скрытым состоянием (h_{t-1}) и входным и выходным числом от 0 до 1.

Первым шагом является состояние ячейки LSTM. Этот уровень представляет сигмоидный уровень, называемый фильтром забывания:

$$\sigma(x) = 1/(1 + e^{-x}). \quad (12)$$

Входной фильтр выбирает новые данные для сохранения в ячейке памяти. Вектор новых значений-кандидатов может быть применен к состоянию в слое тангенса \tanh . Входной фильтр объединяется со слоем \tanh для создания изменения состояния. Функция \tanh взвешивает значения от -1 до 1, чтобы определить их значимость. В измерении используется функция тангенса следующим образом:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (13)$$

Поскольку значение \tanh находится в диапазоне от -1 до 1, это хорошая функция активации для описания вклада как активного, так и отрицательного. А слой \tanh , как правило, является фильтром входа в структуру ячейки LSTM. Здесь вектор фильтра забывания f_t задается как функция весовых матриц фильтра забывания входных и рекуррентных соединений W_f и U_f и вектора смещения b_f следующим образом:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f). \quad (14)$$

В этом процессе мы обозначаем через x_t входной вектор в момент времени t , а h_t – вектор скрытого состояния в момент времени t . На вход LSTM подаются два вектора, как в «обычном» RNN; новый вектор из входных данных x_t и вектор скрытого

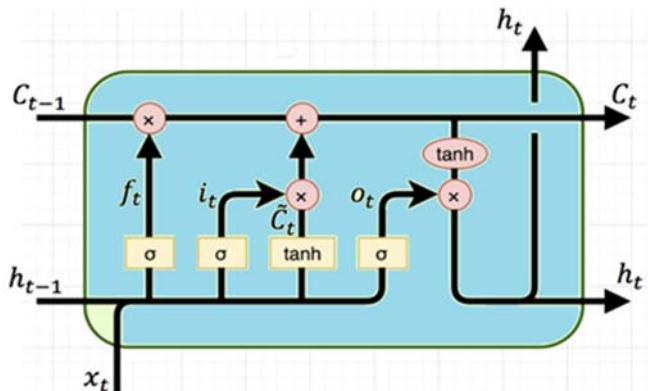


Рисунок 3 – Архитектура ячейки LSTM

состояния h_{t-1} , полученный из скрытого состояния этой ячейки на предыдущем шаге. Эти векторы также подвергаются линейному преобразованию.

Затем они вводятся в сигмоидную передаточную функцию для получения двоичных результатов от 0 до 1, чтобы решить, влияет ли информация с предыдущего шага на следующее состояние ячейки. Это основная структура фильтра забывания. После того, как фильтр забывания решил принять последний шаг времени C_{t-1} до состояния ячейки.

Следующим шагом является определение того, будут ли входные данные текущего времененного шага способствовать состоянию ячейки. Согласно основной идеи рекуррентных нейронных сетей, следует учитывать выход предыдущего времененного шага. Следовательно, текущий вход x_t и предыдущий выход h_{t-1} должны быть объединены. Используя те же обозначения, что и вектор фильтра забывания, входной вектор фильтра i_t , состояние ячейки-кандидата \tilde{C}_t определяются как функция весовых матриц W_i , U_i , W_c , U_c и векторов смещения b_i и b_c следующим образом:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \quad (15)$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c). \quad (16)$$

Предыдущее состояние ячейки C_{t-1} является мультиплексным посредством f_t и предыдущая забытая информация тогда добавляется $i_t \times \tilde{C}_t$; таким образом, можно вычислить вектор состояния c_t :

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t. \quad (17)$$

Наконец, на последнем этапе, мы получим результат вывода из ячейки выходного блока o_t и следующее состояние задается как h_t и определяется следующим образом:

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o), \quad (18)$$

$$h_t = o_t \odot \tanh(C_t), \quad (19)$$

где W_o и U_o – матрицы весов выходной ячейки, o_t – выходное значение и b_o – смещение на выходе, где исходные величины есть $C_0 = 0$ и $h_0 = 0$, а оператор \odot . Индекс t показывает временной шаг. Выход h_t наблюдается на через сигмоидный уровень, тангенс (C_t) принимает значения между -1 and 1.

Наконец, производительность зависит от состояния ячейки. Сигмоидная функция выбирает значения по $[0,1]$, а функция тангенса измеряет значения так, чтобы их значимость можно было определить между -1 и 1 и умножить на сигмоидный выход.

Процесс обучения глубокой нейронной сети состоит из нескольких итераций, называемых эпохами. Он начинается с назначения случайных значений инициализации для значений веса (w) и смещения b для первой эпохи. Объекты для наблюдений за данными с известными значениями меток отправляются на входной слой. Как правило, эти наблюдения группируются в пакеты (часто называемые мини-пакетами). Затем

нейроны применяют свою функцию и, если они активированы, передают результат на следующий слой, пока выходной слой не выдаст прогноз.

Прогноз сравнивается с фактически известным значением, и вычисляется величина отклонения между прогнозируемым и фактическим значениями (которую назовем потерями). На основе результатов оцениваются пересмотренные веса и значения смещения для уменьшения потерь, и эти корректировки распространяются обратно на нейроны в слоях сети. Следующая эпоха повторяет предварительный этап пакетного обучения с измененными значениями веса и смещения, что должно повысить точность модели (за счет уменьшения потерь).

Максимальное количество эпох для обучения составляет 1000 эпох. Начальная скорость обучения составляет 0,005. Коэффициент отбрасывания для скорости обучения равен 0,2, а период отбрасывания для скорости обучения равен 125. При определении отсева слоев мы указываем 0,2, что означает, что 20% слоев будут удалены. После этого мы добавляем слой Dense, который устанавливается на выходе 1 единицу. После этого компилируем модель с помощью известного оптимизатора Adam и определяем потери как среднеквадратичную ошибку. Это позволяет вычислить среднее значение квадратов ошибок. Затем настраиваем модель на 1000 эпох с размером пакета 32. В зависимости от технических характеристик компьютера выполнение расчета может занять несколько минут.

В четвертой главе выполнено прогнозирование трафика IoT с использованием глубокого обучения нейронных сетей (DNN) с сетью LSTM. Моделирование проводилось на процессоре Intel (R) Core(TM) I5-3210M с тактовой частотой 2,40 ГГц и 6 ГБ памяти. Моделирование проводилось в среде MATLAB R2020a для прогнозирования трафика IoT с использованием LSTM Deep Learning. Использован набор данных, сгенерированный моделью IoT из главы 3, для обучения алгоритма DNN. Пропускная способность исследована для трех случаев в зависимости от числа скрытых нейронов в сети LSTM: 500, 100 и 50 соответственно. Точность прогноза оценивается с использованием RMSE и MAPE. Таблица 3 показывает точность прогнозирования пропускной способности IoT с использованием RMSE и MAPE.

В таблице 3 показана точность прогнозирования пропускной способности сети IoT при использовании глубокого обучения LSTM. В трех случаях в зависимости от числа скрытых нейронов в слое LSTM (500, 200 и 50), получены

Таблица 3 – Оценка точности прогнозирования с использованием RMSE и MAPE

Скрытые нейроны LSTM	RMSE	MAPE
500	0.0298	2.12
200	0.1029	7.35
50	0.1694	13.86

оценки точности прогнозирования пропускной способности. Для оценки погрешности использовали RMSE и MAPE.

Из результатов, приведенных в таблице, видно, что при числе скрытых нейронов, равных 500, модель имеет наилучшую точность прогнозирования при значениях RMSE = 0,0298 и MAPE = 2,12% (по сравнению с другими моделями). Максимальное среднее увеличение точности прогноза в случае 500 скрытых нейронов составляет 11,74 %. Точность прогнозирования при 200 скрытых нейронах уменьшилась до RMSE = 0,1029 и MAPE = 7,35%. Максимальное среднее улучшение точности прогнозирования в этом случае составляет 5,23%. Модель с 50 скрытыми нейронами имеет наименьшую точность прогнозирования при RMSE = 0,1694 и MAPE = 13,86%.

На рисунках 4–6 представлены результаты, основанные на прогнозировании пропускной способности IoT с использованием сети глубокого обучения LSTM. В эксперименте выбраны модели с разным количеством скрытых нейронов в слое LSTM. Каждый рисунок содержит две кривые: первая показывает отношение пропускной способности (фактическая и прогнозируемая) ко времени, а вторая – изменение ошибки прогнозирования (RMSE) во времени.

Модель прогнозирования (рисунок 4) с числом скрытых нейронов 500 имеет наилучшую точность прогнозирования при RMSE = 0,0298, улучшение составляет 11,74% по сравнению с аналогичными моделями. Время в процессе прогнозирования равно 16 с. Из рисунка видно, что результаты моделирования с достаточной степенью точности соответствуют фактической модели.

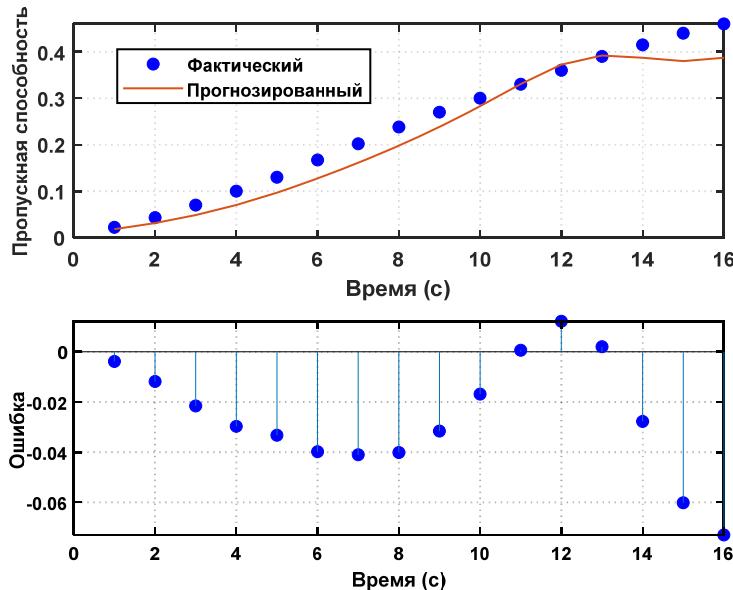


Рисунок 4 – Прогнозируемая и фактическая пропускная способность и RMSE при 500 скрытых нейронах в слое LSTM

На рисунке 5 изображено прогнозирование IoT трафика с числом скрытых нейронов 200. Модель прогнозирования имеет меньшую точность по сравнению с моделью с 500 скрытыми нейронами; значение RMSE упало до 0,1029 и улучшение составило 5,23% по сравнению с другими моделями. Кроме того, в данном случае

время в процессе прогнозирования равно 16 с. По первой кривой видно, что модель прогнозирования похожа на фактическую модель до времени 3с, а затем постепенно отклоняется от фактической до времени 16 с, где обеспечивается наилучшая точность прогнозирования.

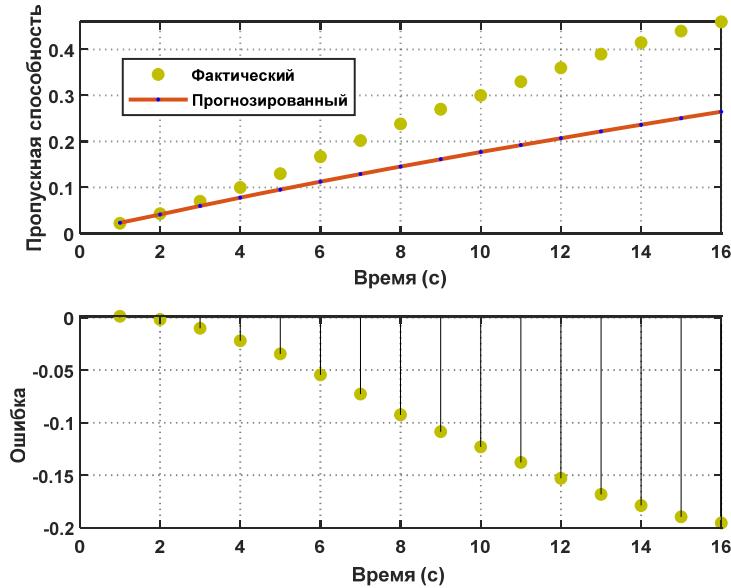


Рисунок 5 – Прогнозируемая и фактическая пропускная способность и RMSE при 200 скрытых нейронов в слое LSTM

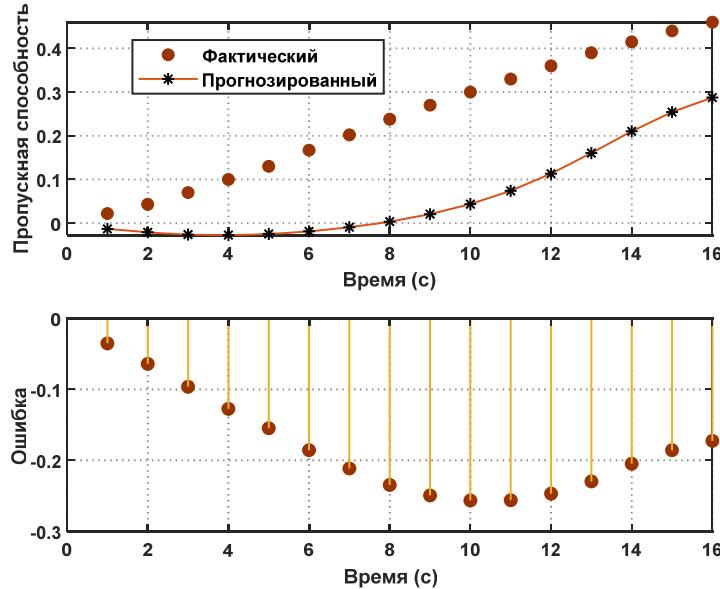


Рисунок 6 – Прогнозируемая и фактическая пропускная способность и RMSE при 50 скрытых нейронов в слое LSTM

На рисунке 6 показаны результаты прогнозирования IoT трафика с количеством скрытых нейронов 50. Такая модель имеет самую низкую точность прогнозирования: $RMSE = 0,16939$ по сравнению со своими аналогами. Как показано на первом из рисунков 6, модель прогнозирования отклоняется от фактической модели. Кроме того, она немного уменьшается до времени 2 с, потом становится постоянной до 5 с, а затем

постепенно увеличивается до времени 16 с, где получается наилучшая точность прогнозирования.

Кроме того, в главе были проведены подобные исследования и для прогнозирования временных рядов с использованием LSTM с глубоким обучением для трафика VANET.

В заключении представлены следующие основные результаты:

1. Анализ развития сетей мобильной связи и особенностей создания сетей связи пятого и последующих поколений показывает, что с переходом к сверхплотным сетям и сетям с ультра малыми задержками не только существенно возрастает сложность задач распределения ресурсов в сети, но и изменяются объемы данных, которые следует собирать и обрабатывать для прогнозирования трафика, что лежит в основе эффективного распределения ресурсов в сетях. При этом использование технологий искусственного интеллекта для прогнозирования характеристик трафика является не только рациональным, но и необходимым.

2. Проанализированы возможности машинного обучения и глубокого обучения для решения задач прогнозирования трафика, методы обучения с учителем, без учителя, с подкреплением, нейронные сети прямого распространения, рекуррентные нейронные сети обратного распространения и определен круг задач прогнозирования характеристик трафика, в которых возможно эффективное применение машинного и глубокого обучения в сетях связи пятого и последующих поколений. К этим задачам отнесены прогнозирование потерь пакетов в сети VANET, потерь пакетов в сетях связи 5G для Интернета Вещей и Тактильного Интернета, задержки в сетях связи 5G для Интернета Вещей и Тактильного Интернета и пропускной способности в сетях связи 5G для Интернета Вещей.

3. В таких сетях связи как автомобильные сети вследствие высоких скоростей перемещения узлов сети в сложных условиях городской застройки, а также в сетях Интернета Вещей вследствие возможности высокоплотного и сверх плотного размещения узлов собранные для прогноза данные могут содержать как данные гауссовского шума, так и случайные выбросы. В связи с этим необходимо в задачах прогнозирования характеристик трафика исследовать возможность и эффективность использования робастных оценок максимального правдоподобия – М-оценок.

4. Предложено использовать набор робастных статистических оценок, называемых М-оценками, в качестве робастной функции потерь для замены традиционной функции потерь с целью улучшения процесса обучения и создания робастной модели машинного обучения, когда обучающие данные являются как чистыми, так и содержат гауссовский шум и выбросы.

5. Предложена многослойная нейронная сеть прямого распространения (MFNN) с М-оценками в качестве функции потерь для замены традиционной функции потерь MSE в случае чистых данных. Используется архитектура MFNN, состоящая из

трехуровневой топологии прямого распространения со скрытым слоем, содержащим 20 скрытых нейронов. Предложенный метод использован в двух приложениях сети VANET:

- Оценка энергии для VANET на основе робастного обучения нейронной сети.
- Оценка потерь пакетов для VANET на основе робастного обучения нейронной сети.

6. Разработан метод прогнозирования потерь пакетов в сетях VANET на основе глубокого обучения и многослойной нейронной сети в условиях, когда данные искажены гауссовским шумом и случайными выбросами при использовании робастной справедливой оценки и робастной оценки Коши, который позволяет уменьшить среднеквадратичную ошибку более, чем в пять раз, а абсолютную ошибку примерно в 2 раза по сравнению с использованием метода наименьших квадратов.

7. Разработан метод прогнозирования потерь пакетов с использованием подхода многошагового прогнозирования (MSP) на основе временных рядов с использованием рекуррентной нелинейной авторегрессионной нейронной сети с внешними входами NARX-RNN.

8. Разработан метод прогнозирования задержки в сетях Интернета вещей и Тактильного Интернета с использованием прогнозирования на один и несколько шагов вперед на основе использования NARX-RNN. Точность прогноза оценивалась с использованием трех алгоритмов обучения нейронной сети: Trainlm, Traincgf, Trainrp и значений среднеквадратичной ошибки (RMSE) и абсолютной ошибки (MAPE).

9. Разработанный метод прогнозирования задержки и потерь в сетях Интернета вещей и Тактильного Интернета на основе нелинейной рекуррентной авторегрессионной нейронной сети NARX дает наилучшие результаты при его обучении алгоритмом Левенберга-Марквардта, превосходя при этом алгоритм обучения Флетчера-Ривса и устойчивый алгоритм обучения по значениям среднеквадратичной ошибки и абсолютной ошибки на порядок и более как при прогнозировании на один шаг, так и при прогнозировании на несколько шагов.

10. Разработан метод прогнозирования пропускной способности сетей 5G/6G для трафика Интернета Вещей на основе алгоритма долговременной краткосрочной памяти (LSTM), который обеспечивает результаты прогноза с приемлемой для практики точностью при 500 скрытых нейронах.

11. Разработан метод прогнозирования пропускной способности для сети VANET на основе глубокого обучения с применением долговременной краткосрочной памяти LSTM. Характеристик прогнозирования были исследованы в зависимости от числа отправленных пакетов: 4 пакета/с, 6 пакетов/с, 8 пакетов/с, 10 пакетов/с, 12 пакетов/с и 14 пакетов/с. Было установлено, что при использовании 4 пакетов/с точность прогнозирования наилучшая среди всех рассмотренных вариантов, а модель, прогнозируемая с использованием 14 пакетов/с, имеет самую низкую точность

прогнозирования. Точность прогнозирования оценивалась по значениям RMSE и MAPE.

СПИСОК ОПУБЛИКОВАННЫХ РАБОТ ПО ТЕМЕ ДИССЕРТАЦИИ

Научные статьи, опубликованные в рецензируемых научных изданиях, рекомендованных ВАК Минобрнауки России

1. Абделлах А.Р. Применение робастных т-оценок для машинного обучения в сетях VANET / А.Р. Абделлах, А. Мутханна, А.Е. Кучерявый // Электросвязь. 2020. № 5. С. 41-46.
2. Абделлах А.Р., Прогнозирование задержки в сетях интернета вещей и тактильного интернета с использованием машинного обучения / А.Р. Абделлах, О.А. Махмуд, А.И. Парамонов, А.Е. Кучерявый // Электросвязь. 2021. № 1. С. 23-27.
3. Абделлах А.Р. Глубокое обучение с долговременной краткосрочной памятью для прогнозирования трафика интернета вещей / А.С. Бородин, А.Р. Абделлах, А.Е. Кучерявый // Электросвязь. 2021. № 2. С. 26-30.

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

4. Abdellah A.R. Robust Estimation of VANET Performance-Based Robust Neural Networks Learning / Abdellah A.R., Muthanna A., Koucheryavy A. // In: Galinina O., Andreev S., Balandin S., Koucheryavy Y. (eds) Internet of Things, Smart Spaces, and Next Generation Networks and Systems. NEW2AN 2019, ruSMART 2019. Lecture Notes in Computer Science, Springer, Cham. vol 11660, pp. 402–414, 2019.
5. Abdellah A.R. Energy Estimation for VANET Performance Based Robust Neural Networks Learning / Abdellah A.R., Muthanna A., Koucheryavy A. // In: Vishnevskiy V., Samouylov K., Kozyrev D. (eds) Distributed Computer and Communication Networks. DCCN 2019. Communications in Computer and Information Science, Springer, Cham. Vol. 1141, pp. 127–138, 2019.
6. Ali R. Abdellah, Deep Learning with Long Short-Term Memory for IoT Traffic Prediction / Ali R. Abdellah, Andrey Koucheryavy // 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.
7. Ali R. Abdellah, VANET Traffic Prediction Using LSTM with Deep Neural Network Learning / Ali R. Abdellah, Andrey Koucheryavy // 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.
8. Abdellah A.R. Deep Learning for IoT Traffic Prediction Based on Edge Computing / Abdellah A.R., Artem V., Muthanna A., Gallyamov D., Koucheryavy A. // In: Vishnevskiy V.M., Samouylov K.E., Kozyrev D.V. (eds) Distributed Computer and Communication Networks: Control, Computation, Communications. DCCN 2020. Communications in Computer and Information Science, Springer, Cham. Vol. 1337. pp. 18-29, 2020.

9. Abdellah A.R. IoT Traffic Prediction with Neural Networks Learning Based on SDN Infrastructure / Volkov A., Abdellah A.R., Muthanna A., Makolkina M., Paramonov A., Koucheryavy A. // In: Vishnevskiy V.M., Samouylov K.E., Kozyrev D.V. (eds) Distributed Computer and Communication Networks. DCCN 2020. Lecture Notes in Computer Science, Springer, Cham. Vol. 12563. pp. 64-76, 2020.
10. Ali R. Abdellah, IoT traffic prediction using multi-step ahead prediction with neural network / Ali R. Abdellah, O.A.K. Mahmood, A. Paramonov, A. Koucheryavy // 2019 11th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT), Dublin, Ireland, 2019, pp. 1-4.
11. Ali R. Abdellah, Delay prediction in IoT using Machine Learning Approach / Ali R. Abdellah, O.A. Mahmood, A. Koucheryavy // 2020 12th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT), Brno, Czech Republic, 2020, pp. 275-279.
12. Abdellah, A.R. Performance Estimation in V2X Networks Using Deep Learning-Based M-Estimator Loss Functions in the Presence of Outliers / Alshahrani, A.; Muthanna, A.; Koucheryavy, A // Symmetry 2021, Vol. 13, Issue. 11, pp. 1-18.
13. Abdellah, A.R. Machine Learning Algorithm for Delay Prediction in IoT and Tactile Internet / Abdellah, A.R.; Mahmood, O.A.; Kirichek, R.; Paramonov, A.; Koucheryavy, A. // Future Internet 2021, Vol. 13, Issue. 12, 304, pp. 1-19.
14. Ali R. Abdellah, Deep learning approach for predicting energy consumption of drones based on MEC / Ali R. Abdellah, A. Alzaghir, A. Koucheryavy // NEW2AN 2021/ruSMART 2021, Springer Cham. LNCS, Vol. 13158, pp 284–296, 2022.
15. Abbas Alzaghir, Predicting energy consumption for UAV-enabled MEC using Machine Learning Algorithm / A. Alzaghir, Ali R. Abdellah, A. Koucheryavy // NEW2AN 2021/ruSMART 2021, Springer cham. LNCS, Vol. 13158, pp 297–309, 2022.

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

16. Абделлах А.Р. Искусственный Интеллект в сетях связи / А.Е. Кучерявый, А.С. Бородин, А.С.А. Мутханна, А.Р. Абделлах, А.Н. Волков / Актуальные проблемы инфотелекоммуникаций в науке и образовании (АПИНО 2021). X Юбилейная международная научно-техническая и научно-методическая конференция: сб. науч. ст. в 4-х т. СПб.: СПбГУТ, 2021. Т. 1. С. 8-18.
17. Абделлах, А.Р. Исследование методов прогнозирования трафика в сетях 5G на основе глубокого обучения / А.Р. Абделлах, А.Е. Кучерявый // Труды ежегодной НТК СПбНТОРЭС. – 2020. № 1 (75). – С.155-156.
18. Abdellah A., Identification of Multimedia Content Based on Digital Object Architecture / A. Abdellah, A. Koucheryavy // Telecom IT. 2020. Vol. 8. Iss. 1. pp. 1-10 (in Russian).

Подписано в печать 13.04.2022. Формат 60×84 1/16.
1,0 п.л. Тираж 100 экз.