

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

Гребенщикова Александра Андреевна

**МОДЕЛИ И МЕТОДЫ ПРОГНОЗИРОВАНИЯ СЕТЕВОГО ТРАФИКА В  
ГЕТЕРОГЕННЫХ СЕТЯХ СВЯЗИ С УЧЁТОМ ЕГО СТАТИСТИЧЕСКИХ  
ХАРАКТЕРИСТИК**

Специальность 2.2.15. Системы, сети и устройства телекоммуникаций

Диссертация на соискание ученой степени  
кандидата технических наук

Научный руководитель  
кандидат технических наук , доцент  
Елагин Василий Сергеевич

Санкт-Петербург – 2024

## ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ .....	4
ГЛАВА 1 АНАЛИЗ МОДЕЛЕЙ И МЕТОДОВ ПРОГНОЗИРОВАНИЯ СЕТЕВОГО ТРАФИКА ДЛЯ КРАТКОСРОЧНЫХ И ДОЛГОСРОЧНЫХ ПРОГНОЗОВ .....	11
1.1 Актуальность прогнозирования сетевого трафика .....	11
1.2 Модели и методы прогнозирования.....	17
1.3 Самоподобность трафика .....	25
1.4 Итеративный подход .....	27
1.5 Искусственные нейронные сети .....	29
1.6 Выводы по главе .....	38
ГЛАВА 2 ПРОГНОЗИРОВАНИЕ ТРАФИКА ИНТЕРНЕТА ВЕЩЕЙ С ПОМОЩЬЮ АВТРЕГРЕССИОННОЙ МОДЕЛИ ARIMA НА КРАТКОСРОЧНОМ ПЕРИОДЕ.....	40
2.1 Структура модели авторегрессии и проинтегрированного скользящего среднего ARIMA .....	40
2.2 Исследование трафика интернета вещей и свойство самоподобия.....	41
2.3 Применение итеративного подхода при разработке алгоритма по подбору оптимальной модели прогнозирования ARIMA .....	47
2.4 Выводы по главе .....	53
ГЛАВА 3 ПРОГНОЗИРОВАНИЕ ТРАФИКА РЕАЛЬНОГО ВРЕМЕНИ С ПОМОЩЬЮ ГИБРИДНОЙ МОДЕЛИ АВТРЕГРЕССИИ ARIMA С ПРИМЕНЕНИЕМ УСЛОВНОЙ ГЕТЕРОСКЕДАСТИЧНОСТИ GARCH НА КРАТКОСРОЧНОМ ПЕРИОДЕ .....	54
3.1 Модель GARCH.....	54
3.2 Модель ARIMA/GARCH.....	55
3.3 Алгоритм подбора и оценки гибридной модели ARIMA/GARCH.....	59
3.4 Прогнозирование трафика реального времени с помощью модели ARIMA/GARCH .....	61
3.5 Выводы по главе .....	72
ГЛАВА 4 ПРОГНОЗИРОВАНИЕ ТРАФИКА ТРЕХМЕРНОЙ СЕТИ ИНТЕРНЕТА ВЕЩЕЙ ВЫСОКОЙ ПЛОТНОСТИ КАК МНОГОМЕРНОГО СЛУЧАЙНОГО ПРОЦЕССА .....	75

4.1 Модель трафика .....	75
4.2 Масштаб времени .....	81
4.3 Метод использования искусственных нейронных сетей .....	84
4.4 Эффективность метода .....	88
4.5 Выводы по главе .....	91
ЗАКЛЮЧЕНИЕ.....	93
СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ.....	97
СПИСОК ИСПОЛЬЗУЕМЫХ ПЕРЕМЕННЫХ .....	99
СПИСОК ЛИТЕРАТУРЫ.....	102
ПРИЛОЖЕНИЕ А. ДОКУМЕНТЫ, ПОДТВЕРЖДАЮЩИЕ ВНЕДРЕНИЕ ОСНОВНЫХ РЕЗУЛЬТАТОВ ДИССЕРТАЦИОННОЙ РАБОТЫ .....	111

## ВВЕДЕНИЕ

**Актуальность темы диссертации.** Современная гетерогенная сеть порождает сетевой трафик со сложной (неоднородной) структурой. Рост объемов разнородного трафика в инфокоммуникационных сетях актуализирует вопросы обеспечения качества предоставляемых услуг связи, что в свою очередь требует обращения к моделям прогнозирования. Модель прогнозирования должна иметь возможность фиксировать значимые характеристики: например, зависимости в краткосрочной и долгой перспективе, самоподобие на больших временных масштабах и высокий уровень мультифрактальности на малых масштабах времени.

Результаты прогнозирования можно оценить по уменьшению ошибки получаемого прогноза. Уменьшение ошибки прогноза отражается на эффективности функционирования сети, а именно эффективности распределения трафика и ресурсов. Таким образом, модель прогнозирования с наименьшей ошибкой прогноза может иметь ценность для компаний, занимающихся проектированием сетей связи.

Среди методов прогнозирования современного сетевого трафика наибольшее количество исследований приходится на алгоритмы с применением искусственных нейронных сетей. Особенно актуально применение методов прогнозирования на основе ИНС для высокомоощных систем.

Однако для некоторых концепций сетей пятого и последующих поколений может быть актуально за короткий промежуток времени спрогнозировать возможные перегрузки на сети, не затрачивая при этом большое количество вычислительных ресурсов. Например, для технологии MEC (Mobile Edge Computing), с особенностью наличия маломощных устройств на границе сети, вопрос прогнозирования с применением аналитических моделей может быть критически важным по сравнению с применением методов на основе искусственных нейронных сетей.

В диссертационной работе исследуются модели и методы прогнозирования гетерогенного трафика в сетях пятого и последующих поколений. Поэтому требуется решить **научную задачу**, которая заключается в повышении точности прогнозирования сетевого трафика гетерогенной сети за счет аналитических методов и методов на основе искусственных нейронных сетей.

**Степень разработанности темы.** В области исследований сетевого трафика гетерогенной сети и моделей прогнозирования трафика сетей связи пятого и последующих поколений существует ряд работ отечественных и зарубежных ученых Б.С. Гольдштейна, В.Г. Карташевского, Р.В. Киричка, А.Е. Кучерявого, А.И. Парамонова, К.Е. Самуйлова, И.А. Соколова, С.Н. Степанова, Р.В. Разумчика, А.В. Абилова, Е.А. Кучерявого, Ю.В. Гайдамака, М.А. Маколкиной, А.Н. Волкова, А.С.А. Мутханна, А.А.А. Ateya, Г.Е.Р. Vox, G. Rutka, J.M. Jenkins и других.

Работы отмеченных выше авторов внесли весомый вклад в исследования характеристик сетевого трафика и методов прогнозирования.

**Объект и предмет диссертации.** *Объектом* исследования являются сетевой трафик в гетерогенных сетях, а *предметом* – модели и методы прогнозирования сетевого трафика.

**Цель и задачи диссертации.** *Цель* диссертационной работы состоит в разработке моделей и методов прогнозирования сетевого трафика с учетом его неоднородной структуры для повышения точности прогнозирования разного типа трафика в гетерогенной сети.

Указанная цель достигается путем решения в диссертационной работе следующих *задач*:

- анализ моделей и методов прогнозирования сетевого трафика для краткосрочных и долгосрочных прогнозов;
- анализ авторегрессионных моделей прогнозирования сетевого трафика таких как ARIMA и гибридных моделей ARIMA с обобщенной условной гетероскедастичностью GARCH;

- разработка метода прогнозирования трафика в гетерогенных сетях пятого и последующих поколений на основе модели авторегрессии и проинтегрированного скользящего среднего (ARIMA) для краткосрочного прогноза на языке программирования python;
- разработка алгоритма и метода прогнозирования трафика реального времени в гетерогенных сетях пятого и последующих поколений на основе гибридной модели авторегрессии и проинтегрированного скользящего среднего (ARIMA) и обобщенной условной гетероскедастичностью GARCH с преобразованием Бокса-Кокса для краткосрочного прогноза;
- исследование методов прогнозирования сетевого трафика на основе применения искусственных нейронных сетей (ИНС);
- исследование модели трафика трехмерной сети высокой плотности как многомерного случайного процесса;
- разработка метода использования ИНС типа *LSTM* для прогнозирования трафика в гетерогенных сетях пятого и последующих поколений в трехмерной сети высокой плотности как многомерного случайного процесса для долгосрочного прогноза.

**Научная новизна** полученных результатов состоит в следующем:

- Благодаря предложенному методу прогнозирования трафика Интернета вещей на краткосрочном периоде получена модель ARIMA(1,5,4), что обеспечило уменьшение средней абсолютной ошибки прогноза более чем в 4 раза по сравнению с использованием исходной модели ARIMA(1,1,2).
- В рамках прогнозирования трафика реального времени, предложенное применение преобразования Бокса-Кокса к сетевому трафику реального времени не повлияло на качество прогноза при сравнении моделей ARIMA, но позволило оптимизировать параметры. Однако, преобразование Бокса-Кокса совместно с гибридной моделью ARIMA–GARCH позволило улучшить прогноз на 8,5% при прогнозе на один шаг вперед и на 7,6% при прогнозе на два шага вперед.
- Применение для прогнозирования трафика трехмерной сети высокой плотности модели многомерного случайного процесса, при получении прогноза

при помощи ИНС типа LSTM, позволяет повысить эффективность прогнозирования до 35 % (при размерности  $k = 10$ ). Таким образом, такой трафик в задачах прогнозирования следует рассматривать как многомерный случайный процесс, размерность которого равна количеству узлов сети, производящих трафик.

### **Теоретическая и практическая значимость диссертации:**

*Теоретическая значимость* диссертационной работы состоит в исследовании моделей и методов прогнозирования сетевого трафика в гетерогенных сетях для краткосрочных и долгосрочных прогнозов. Применение гибридных моделей прогнозирования ARIMA-GARCH подтверждает наличие во временных рядах сетевого трафика реального времени эффектов авторегрессионной условной гетероскедастичности и расширяет существующие знания в области прогнозирования сетевого трафика в гетерогенной сети пятого и последующих поколений на краткосрочном периоде. Полученные результаты прогнозирования (обеспечение уменьшения средней абсолютной ошибки прогноза и повышение эффективности прогнозирования) для различного трафика гетерогенных сетей пятого и последующего поколений расширяют существующие знания в области прогнозирования сетевого трафика. Прогнозирование сетевого трафика как многомерного процесса с помощью ИНС демонстрирует хорошую точность долгосрочного прогноза, в отличие от параметрических моделей типа ARIMA, которые применяются для краткосрочного прогнозирования одномерных процессов. Эффективность прогнозирования предложенным методом зависит от размерности случайного процесса, возрастая с увеличением размерности.

*Практическая значимость* диссертационной работы состоит в возможности использования результатов работы для оптимизации функционирования системы управления трафиком. Так же полученные результаты могут быть применены в рамках технологий пятого и последующих поколений, для которых актуально не затрачивать большие вычислительные ресурсы. Таким образом, оптимальным способом прогнозирования избыточной нагрузки могут выступать именно аналитические модели. Соответственно для высокомоощных систем оптимально

подойдут решения на основе искусственных нейронных сетей и предложенный в работе метод прогнозирования.

Полученные в диссертационной работе результаты внедрены в ООО «НТЦ СевенТест» в решения серии «Профит», в АО «НПП «Эргоцентр» в ходе выполнения опытно-конструкторской работы, направленной на расширение функциональности комплексного имитационно-моделирующего стенда системы специального назначения в интересах решения задач обоснования системотехнических решений по построению функциональных подсистем и всей системы специального назначения в целом (шифр - «Орфей-Эрго-2014»), в ФГБОУ ВО «Санкт-Петербургском государственном университете телекоммуникаций им. проф. М.А. Бонч-Бруевича» (СПбГУТ) при чтении лекций и проведении практических занятий по курсам «Математическое и программное обеспечение киберфизических систем», а также при выполнении Соглашения о предоставлении из федерального бюджета гранта в форме субсидий, выделяемого для государственной поддержки научных исследований, проводимых под руководством ведущих ученых в российских образовательных организациях высшего образования, научных учреждениях и государственных научных центрах Российской Федерации от «06» июля 2022 г. № 075-15-2022-1137 по приоритетному направлению научно-технологического развития Российской Федерации 20а - Переход к передовым цифровым, интеллектуальным производственным технологиям, роботизированным системам, новым материалам и способам конструирования, создание систем обработки больших объемов данных, машинного обучения и искусственного интеллекта.

**Методология и методы исследования.** Для решения поставленных в диссертации задач использовались методы теории телетрафика и теории массового обслуживания, теории вероятностей, математической статистики.

**Основные положения, выносимые на защиту:**

1. Метод прогнозирования объёма трафика гетерогенной сети пятого и последующих поколений на краткосрочном периоде на основе модели

ARIMA(1,5,4) обеспечивает уменьшение ошибки точности прогнозирования до 19%, что на 60% меньше чем с использованием исходной модели ARIMA(1,1,2).

2. Метод прогнозирования объема трафика реального времени в гетерогенной сети пятого и последующих поколений на краткосрочном периоде на основе гибридной модели прогнозирования ARIMA(1,2,2)GARCH(2,0) обеспечивает уменьшение ошибки точности прогнозирования на 8,5% при прогнозе на один шаг вперед и на 7,6% при прогнозе на два шага вперед.

3. Модель трафика трехмерной сети связи высокой плотности как многомерного случайного процесса и метод прогнозирования с использованием искусственной нейронной сети позволяют повысить эффективность прогнозирования до 35 %.

**Степень достоверности** основных результатов диссертации подтверждается корректным применением математического аппарата, 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 10-ой международной научно-технической и научно-методической конференции «Актуальные проблемы инфотелекоммуникаций в науке и образовании» (Санкт-Петербург, 24–25 февраля 2021), 11-ой международной научно-технической и научно-методической конференции «Актуальные проблемы инфотелекоммуникаций в науке и образовании» (Санкт-Петербург, 15–16 февраля 2022), 27-ой международной конференции «International conference on Distributed Computer and Communication Networks: Control, Computation, Communications DCCN» (Москва, 23-27 сентября 2024), на семинарах кафедры инфокоммуникационных систем СПбГУТ.

**Публикации по теме диссертации.** Всего по теме диссертации опубликовано 5 работ, из них 3 статьи в рецензируемых научных журналах, входящих в перечень изданий, рекомендуемых ВАК Министерства высшего образования и науки Российской Федерации, 2 статьи в других изданиях.

**Соответствие паспорту специальности.** Содержание диссертации соответствует следующим пунктам паспорта специальности 2.2.15. Системы, сети и устройства телекоммуникаций: п.1, п.8 и п.18.

**Личный вклад автора.** Основные результаты диссертации получены автором самостоятельно.

# ГЛАВА 1 АНАЛИЗ МОДЕЛЕЙ И МЕТОДОВ ПРОГНОЗИРОВАНИЯ СЕТЕВОГО ТРАФИКА ДЛЯ КРАТКОСРОЧНЫХ И ДОЛГОСРОЧНЫХ ПРОГНОЗОВ

## 1.1 Актуальность прогнозирования сетевого трафика

При рассмотрении области прогнозирования сетевого трафика выделяют различные аспекты, где актуально применять различные модели и методы. Например, с помощью моделей и методов прогнозирования операторы связи могут эффективно управлять ресурсами, предотвращать перегрузки и обеспечивать высокое качество обслуживания. Таким образом, модели прогнозирования используются для оптимизации маршрутизации, планирования пропускной способности и управления нагрузкой благодаря возможности заранее выявить пиковые нагрузки и принять меры по распределению ресурсов для минимизации задержек и сбоев. Прогнозирование также помогает в определении времени обновления и модернизации сетевого оборудования, чтобы соответствовать росту трафика. Также важно отдельно отметить использование моделей прогнозирования для управления трафиком в дата-центрах и облачных платформах. Например, провайдеры облачных услуг используют прогнозные модели для распределения вычислительных ресурсов и обеспечения высокой доступности и производительности сервисов, что обеспечивает поддержку в планировании расширения инфраструктуры дата-центров и внедрения новых технологий для повышения эффективности работы.

В рамках рассмотрения гетерогенной сети стоит отметить работы

Среди методов прогнозирования современного сетевого трафика наибольшее количество исследований приходится на алгоритмы с применением искусственных нейронных сетей. Особенно актуально применение методов прогнозирования на основе ИНС для высокомоощных систем. Однако для некоторых концепций сетей пятого и последующих поколений может быть

актуально за короткий промежуток времени спрогнозировать возможные перегрузки на сети, не затрачивая при этом большое количество вычислительных ресурсов. Например, для технологии MEC (Mobile Edge Computing), с особенностью наличия маломощных устройств на границе сети, вопрос прогнозирования с применением аналитических моделей может быть критически важным по сравнению с применением методов на основе искусственных нейронных сетей. Технология MEC используется операторами сотовой сети для повышения эффективности всей сети путем разгрузки ее операций на близлежащие облака. Европейский институт стандартов электросвязи (ETSI) является одной из основных организаций, занимающихся MEC [1]. Технология MEC включает в структуру такие компоненты как мобильные устройства (конечные пользователи) и соответствующие сервера. Серверы MEC, как правило, представляют собой небольшие центры обработки данных, развертываемые облачными и телекоммуникационными операторами в непосредственной близости от конечных пользователей, и могут быть расположены совместно с беспроводными точками доступа. Серверы подключаются к центрам обработки данных через Интернет через шлюз. Мобильные устройства и серверы разделены интерфейсом, по которому можно устанавливать надежные беспроводные соединения с использованием передовых технологий беспроводной связи и сетевых технологий. В исследованиях [2,3] отмечается эффективность использования такой технологии в преодолении проблемы высокой задержки и решению проблемы сверхнизкой задержки.

Важно отметить, что модели прогнозирования трафика находят широкое применение и в других различных областях. Рассмотрим ключевые сферы, где эти модели играют важную роль. В транспортной системе прогнозирование трафика позволяет улучшить управление дорожным движением, сократить пробки и повысить безопасность на дорогах. Модели прогнозирования трафика используются для оптимизации работы светофоров, планирования дорожных работ и обеспечения бесперебойного движения. Например, системы интеллектуального управления трафиком используют прогнозные данные для адаптивного управления

светофорами и уменьшения времени ожидания на перекрестках. Прогнозирование также помогает в планировании расширения дорожной сети и строительства новых дорог на основе прогнозируемых изменений в трафике.

Прогнозирование трафика в логистике помогает компаниям оптимизировать маршруты доставки, снижать затраты на транспортировку и повышать эффективность работы складов. Модели прогнозирования позволяют планировать графики поставок и предотвращать задержки. Например, логистические компании используют прогнозные модели для определения наиболее эффективных маршрутов доставки и оптимального времени отправки грузов, что помогает минимизировать время в пути и затраты на топливо. Прогнозирование также помогает в управлении запасами и планировании производства, чтобы избежать излишков или дефицита продукции.

В сфере энергетики прогнозирование трафика используется для управления энергопотреблением и оптимизации работы электрических сетей. Модели прогнозирования помогают планировать нагрузки и избегать перегрузок в пиковые часы потребления. Например, энергокомпании используют прогнозные данные для управления распределением электричества и предотвращения перегрузок на сетях, что позволяет повысить надежность и стабильность энергоснабжения. Прогнозирование также помогает в планировании модернизации энергетической инфраструктуры и интеграции возобновляемых источников энергии.

Прогнозирование трафика в здравоохранении помогает оптимизировать работу медицинских учреждений, управлять потоками пациентов и обеспечивать своевременное оказание медицинской помощи. Модели прогнозирования используются для планирования работы клиник и больниц. Например, прогнозирование посещаемости больниц позволяет оптимально распределять медицинский персонал и ресурсы, снижая время ожидания пациентов и улучшая качество обслуживания. Прогнозирование также помогает в управлении запасами медикаментов и медицинского оборудования, чтобы избежать их дефицита.

В торговле прогнозирование трафика помогает управлять потоками покупателей и оптимизировать работу магазинов. Модели прогнозирования

используются для планирования запасов, организации распродаж и управления очередями. Например, ритейлеры используют прогнозные данные для определения наилучшего времени проведения акций и скидок, что позволяет увеличить объем продаж и улучшить обслуживание клиентов. Прогнозирование также помогает в планировании логистики и распределения товаров между различными магазинами.

В сфере общественного транспорта прогнозирование трафика позволяет улучшить планирование маршрутов, сократить время ожидания и повысить удовлетворенность пассажиров. Модели прогнозирования используются для оптимизации расписания поездок и управления транспортными средствами. Например, транспортные компании используют прогнозные модели для определения оптимальных интервалов движения автобусов и поездов в зависимости от ожидаемого пассажиропотока. Прогнозирование также помогает в планировании расширения транспортной сети и внедрения новых видов общественного транспорта.

В рамках концепции умных городов прогнозирование трафика играет ключевую роль в управлении городской инфраструктурой и улучшении качества жизни горожан. Модели прогнозирования используются для управления дорожным движением, общественным транспортом, энергоснабжением и коммунальными услугами. Например, прогнозирование трафика помогает городским властям оптимизировать работу светофоров, планировать дорожные работы и улучшать транспортную доступность. Прогнозирование также помогает в управлении ресурсами города, такими как водоснабжение и утилизация отходов, чтобы обеспечить устойчивое развитие городской среды.

В туристической отрасли прогнозирование трафика помогает управлять потоками туристов и оптимизировать работу гостиниц и других туристических объектов. Модели прогнозирования используются для планирования загрузки гостиниц, организации туристических мероприятий и управления очередями. Например, прогнозирование позволяет гостиницам оптимально распределять номера и персонал в зависимости от ожидаемого числа гостей, что помогает улучшить обслуживание и увеличить доходы.

Эти примеры показывают, насколько важны модели прогнозирования трафика в различных сферах. Современные технологии и методы позволяют создавать более точные и эффективные модели, которые помогают улучшать управление и оптимизацию в различных системах.

Первоначальные модели прогнозирования трафика основывались на статистических подходах, и одним из первых значимых вкладов в эту область стала разработка американским инженером и математиком Ричардом Мэтьюсоном модели, использующей вероятностные методы для прогнозирования объемов движения на основе информации о дорожных происшествиях в 1930-х годах.

В 1950-х годах американские инженеры Джордж Барроуз и Джон Тьюки создали одну из первых компьютерных моделей для прогнозирования трафика, используя методы временных рядов на основе исторических данных. Это позволило исследователям более точно и эффективно предсказывать трафик. В свою очередь, в 1960-х годах развитие статистических методов прогнозирования трафика получило новый толчок с развитием методов авторегрессии и скользящего среднего (ARMA). В 1970-х и 1980-х годах статистические модели прогнозирования трафика продолжали развиваться и улучшаться. На передовом плане оказалось использование новаторских методов, которые учитывали как случайные факторы, так и тренды и сезонные колебания в данных. Важным вкладом в эту область стала диссертация американского математика Джорджа Бокса "Time Series Analysis: Forecasting and Control", опубликованная в 1970 году. В своей работе он предложил революционный подход к прогнозированию временных рядов, основанный на моделях авторегрессионных интегрированных скользящих средних (ARIMA) [4].

В 1990-х годах начали появляться новые методы прогнозирования трафика, основанные на машинном обучении и искусственном интеллекте, благодаря развитию компьютерных технологий и доступности больших данных. Эти методы позволяют автоматически обрабатывать и анализировать объемные данные, выявляя скрытые закономерности. Один из самых популярных методов - нейронные сети, которые способны моделировать сложные нелинейные

зависимости в информации. В то же время, существующие методы, такие как экспоненциальное сглаживание и структурная временная декомпозиция, имели свои ограничения и не всегда обеспечивали точность результатов.

Прогнозирование трафика в современных статистических моделях основано на комбинации разнообразных подходов и методов, включая ARIMA, экспоненциальное сглаживание, а также методы машинного обучения и нейронные сети. Эти модели учитывают как структурные, так и случайные факторы, и способны предсказывать трафик на различные временные горизонты. Тем не менее, несмотря на значительные достижения в области математического прогнозирования трафика, эти модели все еще имеют свои ограничения и недостатки. Например, для эффективного функционирования статистических моделей требуется большой объем исторических данных для обучения, и они могут оказаться неэффективными при изменении условий и внешних факторов.

Современные технологии, такие как машинное обучение и искусственный интеллект, позволяют создавать более точные и эффективные статистические модели. Несмотря на успехи, дальнейшее развитие в этой области требует учета сложных взаимодействий и изменчивости условий. В заключение, можно сказать, что история развития прогнозирования трафика демонстрирует постоянный прогресс и активное развитие методов прогнозирования в последнее время. За последние годы стало возможным достичь значительного прогресса в разработке и применении статистических моделей прогнозирования трафика, благодаря использованию больших данных (Big Data) и технологий искусственного интеллекта (AI). Это обусловлено применением гибридных моделей, которые объединяют традиционные статистические методы с методами машинного обучения. Такой подход позволяет улучшить точность прогнозов и учитывать более сложные зависимости. Один из этих подходов - использование гибридных моделей ARIMA и нейронных сетей. В процессе анализа временных рядов в современных моделях происходит сначала передача данных в нейронные сети для более точного прогнозирования с учетом нелинейных зависимостей, после чего применяется метод ARIMA для выявления трендов и сезонных колебаний. Это инновационный

подход, который дает возможность улучшить точность прогнозов по сравнению с использованием отдельных моделей.

Разработка рекуррентных нейронных сетей (RNN) и их более сложных вариантов, таких как длинно-краткосрочная память (LSTM) и гейтовые рекуррентные блоки (GRU), также активно продвигается. Эти инновационные модели проявляют высокую эффективность при работе с временными рядами и прогнозировании трафика, поскольку учитывают временные зависимости в данных и могут предсказывать будущие значения, опираясь на предыдущие наблюдения.

Так же для прогнозирования трафика широко применяются современные модели, такие как случайные леса (Random Forest) и градиентный бустинг (Gradient Boosting). Они позволяют выделить сложные закономерности и значительно повысить точность прогнозов. Глубинное обучение, основанное на глубинных нейронных сетях (DNN), также является перспективным направлением. Эти модели требуют больших вычислительных ресурсов, но способны обрабатывать огромные объемы данных и прогнозировать трафик на долгосрочной основе.

С использованием современных технологий и методов анализа данных активно продолжается развитие прогнозирования трафика через улучшение управления транспортной инфраструктурой и обслуживания пользователей. Новые возможности для более точного и эффективного прогнозирования трафика открывают гибридные модели, методы глубинного обучения и использование больших данных.

## **1.2 Модели и методы прогнозирования**

Прогнозирование временных рядов является важной частью в области управления сетями. Например, именно от точности прогнозов, на основе которых принимаются упреждающие решения будет зависеть эффективность использования сетевых ресурсов и качество обслуживания для конечного пользователя.

На данный момент существует огромное количество научных работ и исследований, направленных на изучение прогнозирования сетевого трафика на основе статистических подходов и ИНС (искусственные нейронные сети). Основываясь на результатах анализа в [5], можно сделать вывод о наличии достаточно большого количества исследований прогнозирования сетевого трафика на основе ИНС (например, с несколькими слоями между входным и выходным слоями – глубоких нейронных сетей DNN (Deep neural network) и такого типа нейронных сетей, который напрямую работает со структурой графа – графовых нейронных сетей GNN (Graph Neural Network)). На следующем по количеству публикаций месте располагаются авторегрессионные модели типа ARIMA, которые характеризуются относительно простым решениями в области прогнозирования с высокой интерпретируемостью данных. Не смотря на этот факт, прогнозная способность моделей на основе нейронных сетей имеет наиболее эффективные результаты по сравнению с другими подходами. На рисунке 1 приведена упрощенная классификация моделей для прогнозирования.

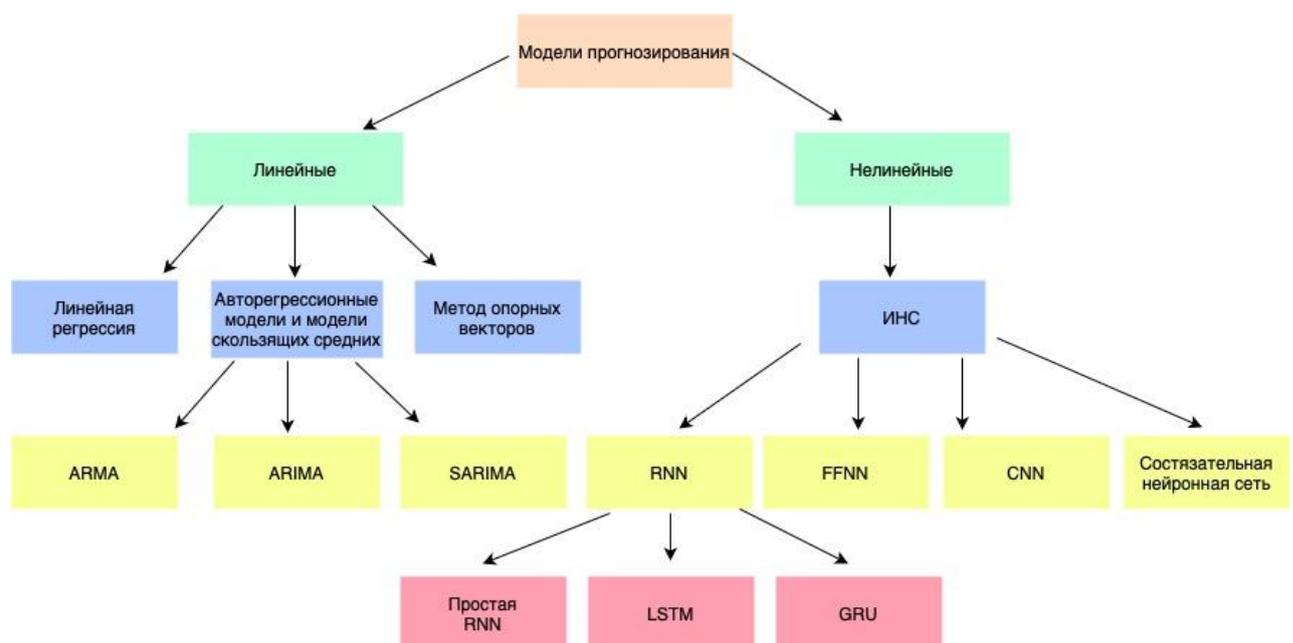


Рисунок 1 – Классификация моделей прогнозирования

Линейная регрессия — это метод машинного обучения, который является одним из самых простых методов в этой области. С помощью такого метода

прогнозируются непрерывные значения. Может применяться для прогнозирования вероятности блокировки полосы пропускания сети [6].

Метод опорных векторов SVM (Support Vector Machine) — это метод машинного обучения, широко используемый в задачах классификации и регрессии. Особенностью метода является построение гиперплоскости, разделяющей объекты выборки оптимальным способом. Так же может применяться для прогнозирования сетевого трафика [7].

Метод случайного леса RF (Random Forest) относится к структурным моделям, имеет достаточно высокий уровень интерпретируемости и применяется для задач классификации, регрессии и кластеризации. Благодаря большому ансамблю решающих деревьев возможно достижение оптимального результата.

Вейвлет-преобразование WT (Wavelet Transform) чаще всего применяется как метод разложения исходного временного ряда в совокупность последовательностей вейвлет-коэффициентов, построения прогнозов для каждой такой последовательности и последующего восстановления значений исходного временного ряда и спрогнозированных значений по имеющимся и спрогнозированным значениям коэффициентов [8].

Скрытая марковская модель НММ (Hidden Markov Model) — это вероятностная модель, в которой состояния системы скрыты. Этот метод основан на хорошо известной теории марковских цепей, при этом возможно только наблюдать выходные значения при условии отсутствия знаний о состоянии системы [9].

Авторегрессионные модели можно представить в виде линейной комбинации прошлых наблюдений. Обычно модель оценивается таким образом, чтобы ее параметры максимизировали вероятность создания правильных прогнозов. Аналогично, модели скользящего среднего также линейны, однако прогноз рассчитывается на основе предыдущих ошибок. Когда эти две модели используются одновременно, то получаются так называемые авторегрессионные модели скользящего среднего, которые можно расширить до ARIMA и SARIMA.

Очень большой класс функций может быть аппроксимирован с помощью нейронных сетей. Многие методы прогнозирования основаны на нейронных сетях, где различные шаблоны (например, пространственно-временные) могут быть изучены во время фазы обучения и впоследствии использованы для прогнозирования.

Согласно [10] опираясь на период прогнозирования и количество прогнозируемых интервалов, методы прогнозирования можно классифицировать на долгосрочные и краткосрочные. Для долгосрочных методов характерны наиболее сложные модели нежели для краткосрочных и в рамках исследования различий данных алгоритмов важно оценивать цели прогнозирования с учетом затрат различных моделей на анализ данных. Из краткосрочных алгоритмов авторы выделяют модели скользящих средних и моделей экспоненциального сглаживания.

Модели и методы прогнозирования, согласно [11], можно классифицировать на два вида:

1. Статистические модели, состоящие из регрессионных, авторегрессионных и экспоненциального сглаживания;
2. Структурные модели, которые в свою очередь включают в себя нейросетевые модели, модели на базе цепей Маркова и дерева принятия решений.

Так же важно отметить, что в исследовании [11] при необходимости выделить достаточный ресурс для хранения трафика в узловом оборудовании на краткосрочном периоде времени, авторегрессионные модели отличает ряд преимуществ в отличие от обучаемых за счет требования связанного с ограниченностью времени. Таким образом, для краткосрочного прогноза при работе с агрегированными данными с целью прогноза объема трафика в режиме реального времени предпочтительнее использовать именно статистические модели, а в остальных случаях структурные [12].

Среди статистических подходов наиболее популярным методом прогнозирования являются модели авторегрессии и проинтегрированного скользящего среднего (ARIMA, autoregressive integrated moving average). Модель

ARIMA является важным классом параметрических моделей, которые позволяют описывать нестационарные ряды. Что касается нейронных искусственных сетей, то в научной литературе описывается огромное количество исследований и успешных экспериментов по применению ИНС для решения задач классификации, прогнозирования и управления.

Согласно [13], важно обратить внимание на методы прогнозирования, основанные на традиционной методике Бокса-Дженкинса. Основная идея такого подхода заключается в представлении обширного класса моделей с достаточным и одновременно оптимальным количеством параметров, удовлетворяющим различным наборам данных [14]. При рассмотрении классических линейных моделей прогнозирования выделяют такие, как:

- Авторегрессионная модель  $AR(p)$  – выражает текущее значение процесса как конечную линейную совокупность предыдущих значений процесса и импульса белого шума, применяемых для прогнозирования сетевого трафика;

- Модель скользящего среднего  $MA(q)$  – даёт прогноз значений на основе линейной комбинации ограниченного числа  $q$  остатков, в то время как авторегрессионные модели  $AR(p)$  дают прогноз на основании линейной функции аппроксимации ограниченного числа  $p$  прошлых значений;

- Модель авторегрессии и скользящего среднего  $ARMA(p,q)$  – метод регрессионного анализа, целью которого является определение степени связи между прошлыми и будущими значениями [8]. Краткая запись модели описывается, как

$$\varphi(B)\beta_t = \theta(B)\alpha_t, \quad (1)$$

где  $\beta_t$  – временной ряд для анализа;  $\alpha_t$  – белый шум;  $B$  – оператор сдвига назад ( $B\beta_t = \beta_{t-1}$ );  $\varphi(\cdot)$  и  $\theta(\cdot)$  – полиномы степени  $p$  и  $q$ ;

- Модели авторегрессии и проинтегрированного скользящего среднего  $ARIMA(p,q)$  – это важный класс параметрических моделей, который позволяет описывать нестационарные ряды и классифицируется, как короткий прогноз (т.е.

качественно осуществляет предсказание трафика только на несколько шагов вперёд). В качестве частных случаев этот класс моделей включает в себя модели авторегрессии, скользящего среднего, смешанные модели авторегрессии и скользящего среднего и интеграцию всех трёх моделей соответственно. Кратко эту модель можно записать как

$$\varphi(B)(1-B)^d\beta_t=\theta(B)\alpha_t, \quad (2)$$

где  $d$  – порядок взятия последовательной разности ( $\Delta\beta_t=\beta_{t-1}-\beta_t=(1-B)^d\beta_t$ ).

Все эти модели линейны и актуальны для краткосрочного прогноза.

Что касается следующей группы моделей, то их характерным представителем может выступать дробно-интегрированная модель авторегрессии скользящего среднего FARIMA( $p,d,q$ ) (Fractional autoregressive integrated moving average model). Такая модель прогнозирования учитывает долгосрочную зависимость трафика [15].

Модели такого рода нелинейны, актуальны для долгосрочных прогнозов и способны адекватно отразить такие характеристики трафика, как самоподобие.

Следующие модели прогнозирования сетевого трафика можно объединить в ещё один кластер, так как они ориентированы на повышение точности прогнозов и могут быть представлены в виде:

- Гибридных моделей, таких как ARIMA/GARCH;
- Модели ONN/OFF, которые применяются для моделирования сетей передачи голосовых данных [16].

В таблице 1 представлено сравнение двух приоритетных направления в области прогнозирования сетевого трафика на основе приведенной выше информации.

Таблица 1 - Сравнение параметрических моделей прогнозирования трафика и моделей на основе ИНС

Модель	Преимущества	Недостатки	Область применения
ARIMA/ARIMA-GARCH	Учет сезонности и трендов	Необходимость стационарности данных в процессе обработки трафика	Краткосрочные прогнозы
Нейронные сети	Обработка сложных нелинейных зависимостей	Требование в виде большого объема данных и вычислительных ресурсов	Долгосрочные и краткосрочные прогнозы

Таким образом, использование статистических методов для прогнозирования будущих значений трафика позволяет учесть тренды и сезонность в данных, т.к. основаны на предположении о стационарности временного ряда.

Другим распространенным подходом к прогнозированию трафика является использование методов машинного обучения. В этом случае данные о трафике рассматриваются как набор признаков, которые могут быть использованы для обучения модели. Согласно исследованию [17], при сравнении вероятностно-ориентированного подхода с такими методами, как случайные леса, LSTM и т.д. именно методы на основе машинного обучения имеют ряд наилучших результатов для мобильного трафика.

В области машинного обучения регрессионный анализ является одним из основных инструментов, благодаря которому можно успешно проводить

исследования как в области статистики, так и в области прогнозирования [18]. В данной работе кроме базовых методов линейной регрессии, рассматриваются и более сложные модели (обобщенные линейные, нелинейные и модели смешанных эффектов). Таким образом, методы машинного обучения, такие как регрессия или нейронные сети, могут быть использованы для создания моделей, которые могут предсказывать будущие значения трафика на основе имеющихся данных. Эти методы позволяют учесть более сложные зависимости в данных и могут быть более гибкими. Однако, выбор оптимального метода прогнозирования трафика зависит от множества факторов, включая характеристики данных, доступность и объем данных, а также требования к точности прогноза.

В ходе экспериментов можно использовать различные метрики для оценки качества прогноза. Одной из наиболее распространенных метрик является среднеквадратическая ошибка (MSE), которая измеряет среднее отклонение прогнозных значений от фактических значений трафика. Другими метриками могут быть средняя абсолютная ошибка (MAE) или коэффициент детерминации ( $R^2$ ), которые также позволяют оценить точность прогноза.

При сравнении различных методов прогнозирования трафика также необходимо учитывать их вычислительную сложность и требования к объему данных. Некоторые методы могут быть более эффективными с точки зрения времени выполнения, но требовать большего объема данных для обучения модели. В то же время, другие методы могут быть менее вычислительно сложными, но требовать более длительного времени для обучения модели. Так же необходимо учитывать их способность обрабатывать различные типы данных. Некоторые методы могут быть более эффективными для прогнозирования трафика в определенных ситуациях, например, когда данные имеют явно выраженную сезонность или тренд. В то же время, другие методы могут быть более универсальными и способными обрабатывать данные с различными характеристиками.

Таким образом, оценка и сравнение эффективности математических моделей прогнозирования трафика является сложной задачей, которая требует проведения

экспериментов и использования различных метрик для оценки качества прогноза. Выбор оптимального метода зависит от характеристик данных, требований к точности прогноза и вычислительной сложности. Поэтому, для достижения наилучших результатов, рекомендуется использовать комбинацию различных методов и тщательно анализировать их результаты.

### 1.3 Самоподобность трафика

Вследствие наличия во временном ряде сильной зависимости значений от предыдущих возникает такое понятие как самоподобие. Таким образом, Интернет-трафик при сглаживании имеет определенную структуру с трендом, на которую стохастически влияют редкие «всплески» пакетов. Такие особенности трафика имеют особое значение и влияние на математические моменты временной последовательности как в локальных масштабах времени, так и на больших размахах [7].

В традиционных моделях сетевого трафика практически отсутствует свойство долговременной зависимости. Согласно [19], причиной такого явления выступает ярко выраженное сглаживание пульсаций. Именно с приходом концепции единой мультисервисной сети процесс генерации трафика стоит рассматривать с точки зрения степени самоподобия трафика и его долговременной зависимости [8]. Таким образом, теория пуассоновских процессов уходит на второй план, уступая самоподобному процессу, для которого характерно сохранение некоторых статистических особенностей при масштабировании времени.

Согласно [8], рассматривая трафик с точки зрения самоподобного процесса, помимо долговременной зависимости можно выделить такие дополнительные свойства, как медленно затухающая дисперсия и наличие распределения с тяжелыми «хвостами». Более того, при анализе моделирования самоподобного трафика выделяют такие модели, как нейросетевые [20], авторегрессионные [21] и модели ON/OFF [22]. Согласно [14], самой популярной моделью для

прогнозирования также является модель авторегрессии проинтегрированного скользящего среднего ARIMA, но эта модель часто не может выполнить точный прогноз. Недостоверность прогнозирования в рамках моделей ARIMA обусловлена невозможностью качественно улавливать характеристику всплесков трафика данных из-за константности дисперсии.

Моделям с авторегрессионной условной гетероскедастичностью GARCH (generalized autoregressive conditional heteroscedasticity) отводится особая роль в связи с наличием динамической, т.е. изменяющейся с течением времени, дисперсии. Модель авторегрессии проинтегрированного скользящего среднего ARIMA и модель с авторегрессионной условной гетероскедастичностью GARCH являются нелинейными моделями временных рядов, которые совмещают линейную модель ARIMA с условной дисперсией модели GARCH. Таким образом, в рамках самоподобного процесса приемлемо использовать не только модели ARIMA, но и существующие алгоритмы моделей GARCH ввиду того, что при усреднении по шкале времени у самоподобного процесса сохраняется склонность к всплескам. Данный факт подтверждается специализированными исследованиями финансовых рядов, для которых характерно наличие тяжёлого «хвоста» [9]. Несмотря на то, что такое поведение присуще экономическим временным рядам, модели GARCH могут поспособствовать адекватному отражению реального неоднородного сетевого трафика [23]. Более того, многие исследования подтверждают успешность применения моделей ARIMA/GARCH при прогнозировании беспроводного трафика [24], интернет-трафика [25] и мобильного трафика [26].

Кроме того, для прогнозирования трафика могут быть использованы и другие модели временных рядов, такие как модель SARIMA (Seasonal ARIMA), модель VAR (Vector Autoregression), модель ARCH (Autoregressive Conditional Heteroskedasticity) и другие. Модель SARIMA позволяет учесть сезонные колебания в данных и может быть полезна для прогнозирования трафика, который имеет ярко выраженные сезонные паттерны. Модель VAR позволяет учесть взаимосвязь между несколькими временными рядами, что может быть полезно для

прогнозирования, где трафик зависит от нескольких факторов. Модель ARCH позволяет учесть изменчивость дисперсии в данных и может быть полезна для прогнозирования трафика с высокой степенью изменчивости данных.

#### 1.4 Итеративный подход

Модели ARIMA ( $p, q$ ) представляют особый класс нестационарных моделей, которые считаются однородными и находятся в статистическом равновесии. Модель ARIMA определяется уравнением (2) и, согласно [9], такая модель является обобщённой, т.к. включает в себя в качестве частных случаев следующие модели: авторегрессионные, скользящего среднего, смешанные модели авторегрессии-скользящего среднего и интеграция всех трёх соответственно.

Эффективная итеративная процедура построения моделей для описания зависимости наблюдаемых временных рядов состоит из трёх этапов:

1. Идентификация. Подразумевает использование уже имеющихся данных о временном ряде, чтобы подобрать соответствующий и оптимальный класс моделей для последующей оценки.

2. Оценка. Подразумевает выявление сопутствующих параметров для построения модели.

3. Диагностика. Подразумевает проверку модели на соответствие имеющимся данным, чтобы выявить несоответствия и определить оптимальные пути улучшения модели.

Пошаговая оценка параметров модели ARIMA ( $p, d, q$ ) / GARCH ( $s, r$ ) продемонстрирована на рисунке 2.

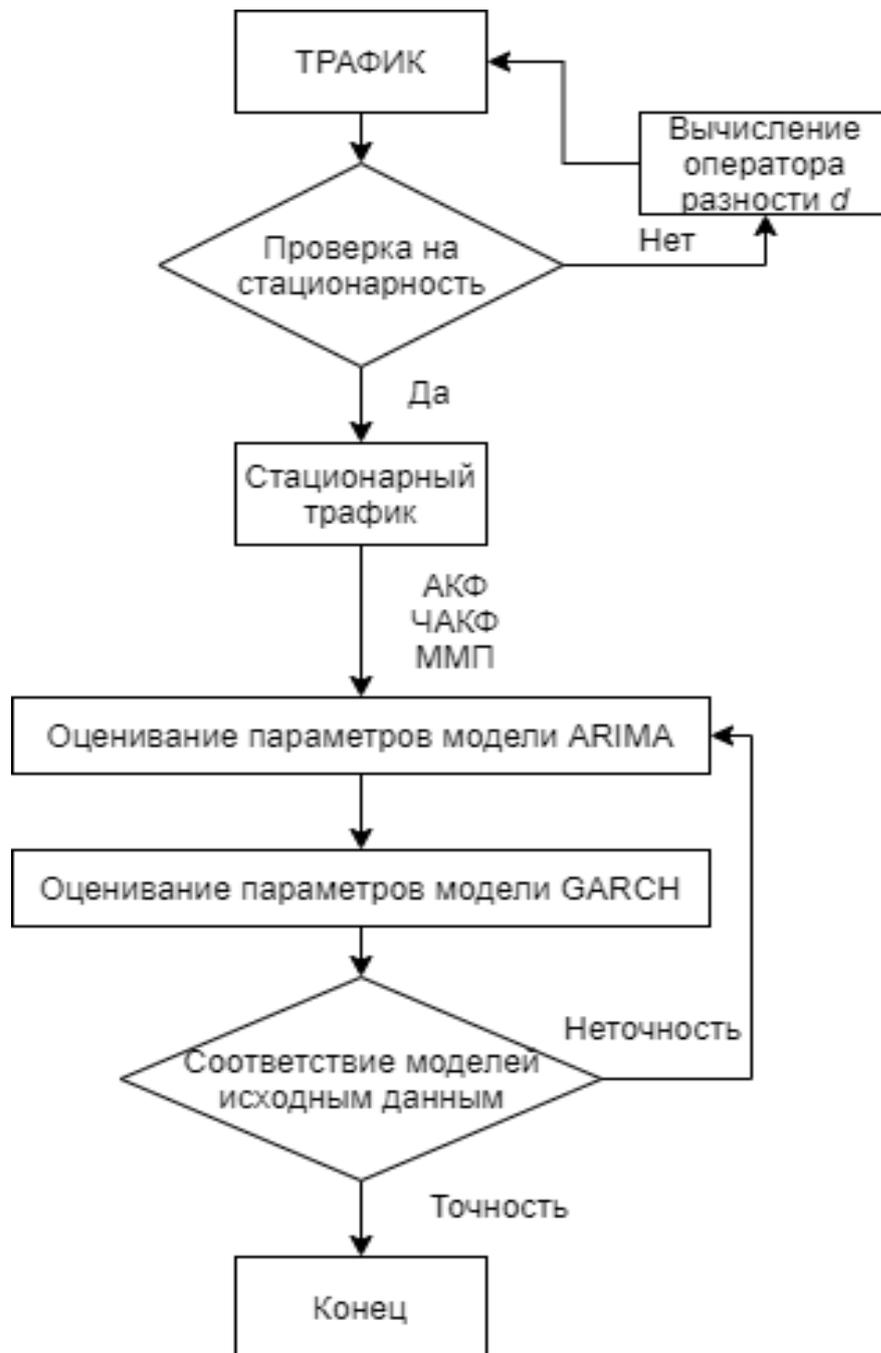


Рисунок 2 – Пример алгоритма оценки параметров модели ARIMA/GARCH.

Некоторые из этих этапов описываются в научной литературе, как [16]:

1. Необходимо установить параметр  $d$ , обозначающий порядок разности, как это делается при интеративном подходе (с помощью АКФ).
2. Для получения стационарного ряда исследуется характер поведения выборочных АКФ и частных АКФ (ЧАКФ), т.е. выдвигаются гипотезы о значениях параметров  $p$  (порядок авторегрессии) и  $q$  (порядок скользящего среднего). Таким образом, определяется

параметр скользящей средней порядка  $q$  и порядок  $p$  параметра авторегрессии.

3. Необходимо определить параметры второй части модели:  $s$  и  $r$ . Для этого полученные параметры  $p$  и  $q$  приравняются к нулю, чтобы оперировать с моделью ARIMA  $(0, d, 0)$  / GARCH  $(s, r)$  было удобнее.

Параметры нелинейной модели ARIMA/GARCH фиксируют статистические характеристики трафика и способны подробно описать данные в выбранном временном промежутке. Изучение их влияния на производительность сети может быть полезно для оценки трафика и последующего управления сетью. Таким образом, оценка параметров нелинейной модели ARIMA/GARCH отличается от классических моделей прогнозирования повышенной точностью в изучении поведения трафика и способностью фиксировать условную дисперсию.

Стоит отметить, что определение порядка параметров модели GARCH  $(s, r)$  можно инициализировать с помощью АКФ и ЧАКФ, как это описывалось при установлении порядка разности  $d$ . А когда необходимо оценить параметры модели, для этих целей используется метод максимального правдоподобия (ММП).

## 1.5 Искусственные нейронные сети

В последние несколько лет многие научные исследования в области прогнозирования связаны с другим мощным подходом: искусственными нейронными сетями (ИНС). Наличие нелинейного подхода подразумевает использование не только прошлых значения (например, как SARIMA) временного ряда, но и другие типы информации. Таким образом, такого рода стратегия может привести к более точным результатам. Основываясь на некоторых исследованиях [27], можно сделать вывод, что подходы, основанные на нейронных сетях, превосходят линейные.

На рисунке 3 показан процесс обучения нейронной сети. Процесс обучения нейронной сети включает несколько ключевых этапов, таких как выбор примера, настройка сети, расчет ошибки и обучение сети.

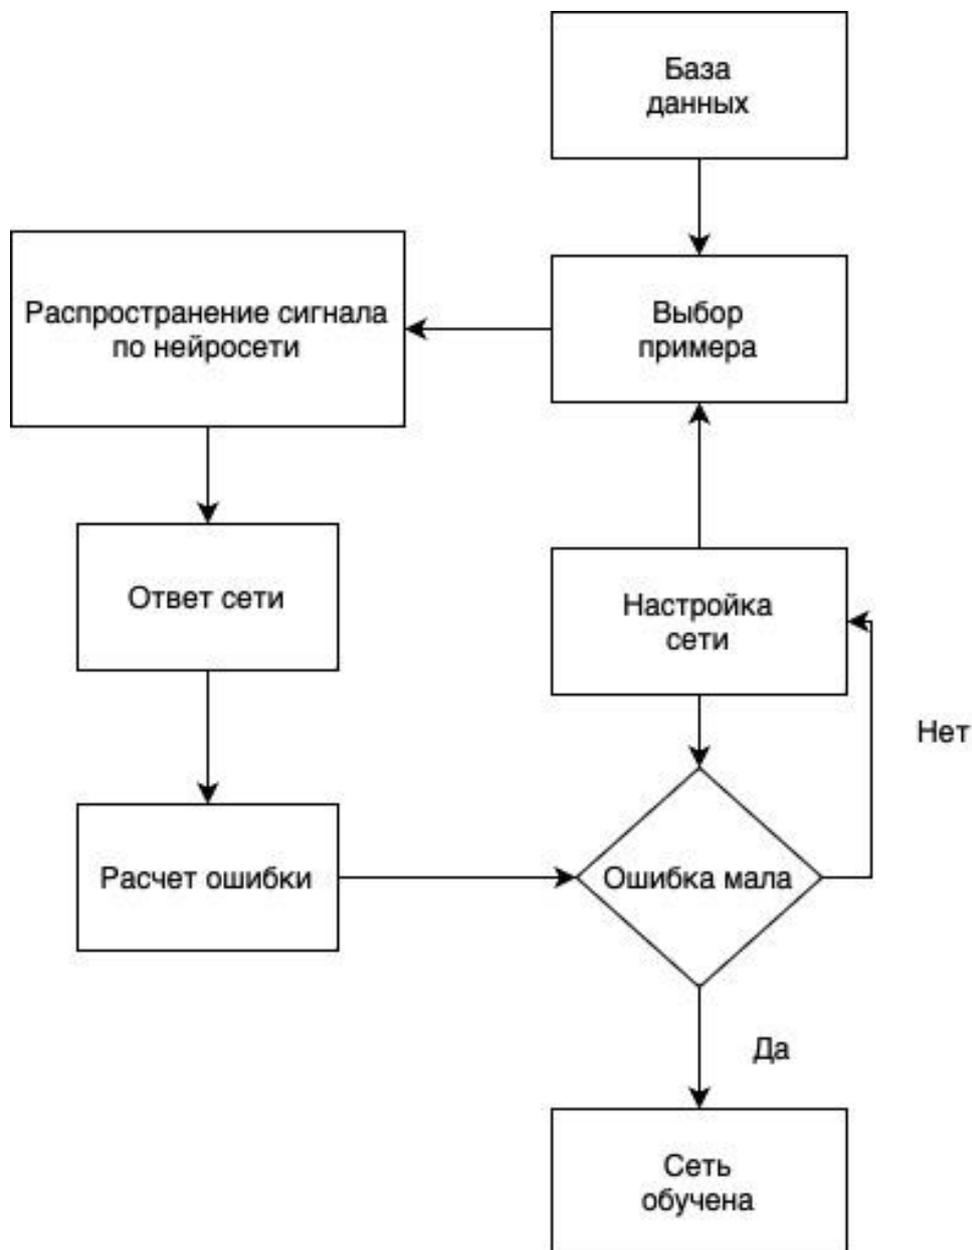


Рисунок 3 – Процесс обучения нейронной сети.

Использование технологий на основе искусственного интеллекта (ИИ) для оптимизации качества обслуживания QoS (Quality of Service) в современных сетях имеет несколько преимуществ. Во-первых, возможность анализировать большие объемы данных и выявлять скрытые закономерности и паттерны, которые могут

быть использованы для оптимизации сети. Например, анализировать данные о трафике и предсказывать будущие потребности пользователей, что позволяет сети адаптироваться и предоставлять высокий уровень качества обслуживания в соответствии с условиями.

Во-вторых, ИИ может использоваться для автоматической оптимизации параметров сети. Оптимизация распределения ресурсов между различными пользователями и приложениями обеспечивает максимальную производительность и предоставляет возможность минимизировать задержку. Использование таких технологий позволяет сети адаптироваться к изменяющимся условиям и динамически оптимизировать свою работу, что приводит к улучшению QoS. Таким образом, ИИ может использоваться для анализа и прогнозирования трафика, определения оптимального распределения ресурсов и принятия решений о перераспределении ресурсов в реальном времени. Данный фактор позволяет сети эффективно использовать доступные ресурсы и обеспечивать QoS в соответствии с требованиями пользователей. Например, в сетях пятого и последующих поколений, которые включают в себе большое количество устройств и приложений с различными требованиями, оптимальная маршрутизация и управление трафиком становятся сложными задачами. Использование ИИ позволяет сети анализировать и предсказывать трафик, определять оптимальные маршруты и принимать решения о перераспределении трафика в реальном времени для обеспечения оптимальной производительности для различных пользователей и приложений. Исследование [28] описывает возможности ИИ в анализе цифровых изображений на основе сверточных нейронных сетей глубокого обучения, что демонстрирует успехи ИИ в области медицины и диагностики определенных заболеваний.

Нейронная сеть состоит из взаимосвязанных узлов, называемых нейронами. Нейроны организованы в слои: входной слой, один или несколько скрытых слоев и выходной слой. Наиболее популярной архитектурой является нейронная сеть прямого распространения FFNN (Feed Forward Neural Network), в которой

информация проходит через сеть только в прямом направлении, т. е. от входного слоя к выходному слою, как показано на рисунке 4.

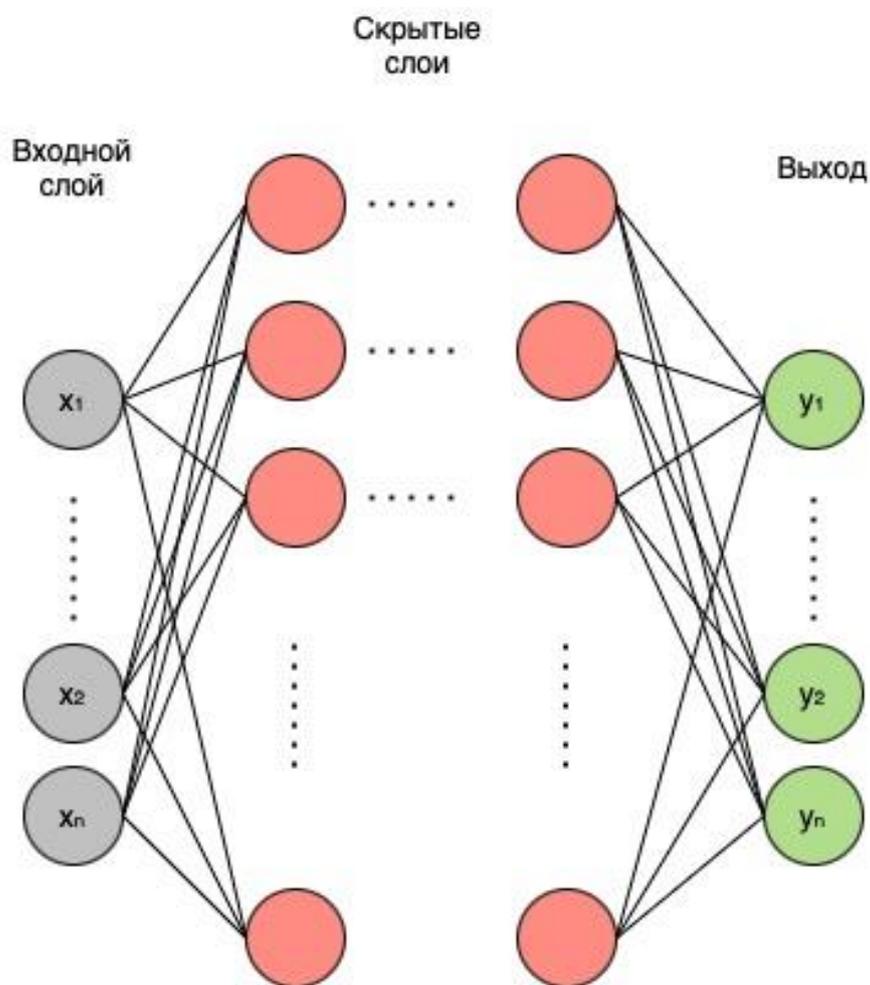


Рисунок 4 – Нейронная сеть прямого распространения FFNN.

Одним из недостатков нейронных сетей прямого распространения FFNN является тот факт, что предыдущие значения последовательных данных не рассматриваются для прогнозирования следующих. Таким образом, для решения такой проблемы в области прогнозирования временных рядов стоит рассмотреть другие архитектуры, такие как RNN и LSTM [5].

Прогнозирование с использованием нейронных сетей включает две фазы: фазу обучения и тестирования (прогнозирования). Фаза обучения заключается в представлении обучающих данных на входном слое и динамической корректировки параметров для достижения оптимального выходного значения для входного

набора. Наиболее часто используемый алгоритм обучения для обучения называется алгоритмом обратного распространения. Алгоритм обратного распространения ошибки это один из методов обучения многослойных нейронных сетей прямого распространения. Существует два подхода для обучения по такому алгоритму: прямой и обратный. При прямом проходе входной вектор подается на входной слой нейронной сети и в процессе разделяется от слоя к слою. Таким образом, на выходе получается набор выходных сигналов. При обратном же подходе синаптические веса настраиваются в соответствии с правилом коррекции ошибок и сформированный сигнал ошибки распространяется по сети в направлении, обратном направлению синаптических связей [29]. Соответственно, при распространении ошибки в противоположном направлении веса постоянно изменяются до тех пор, пока выходная ошибка не упадет ниже заданного значения, что демонстрирует особенность нейронных сетей изучать коррелированные закономерности между входными наборами и соответствующими целевыми значениями.

Рекуррентные нейронные сети или глубокие рекуррентные нейронные сети представлены на рисунке 5.

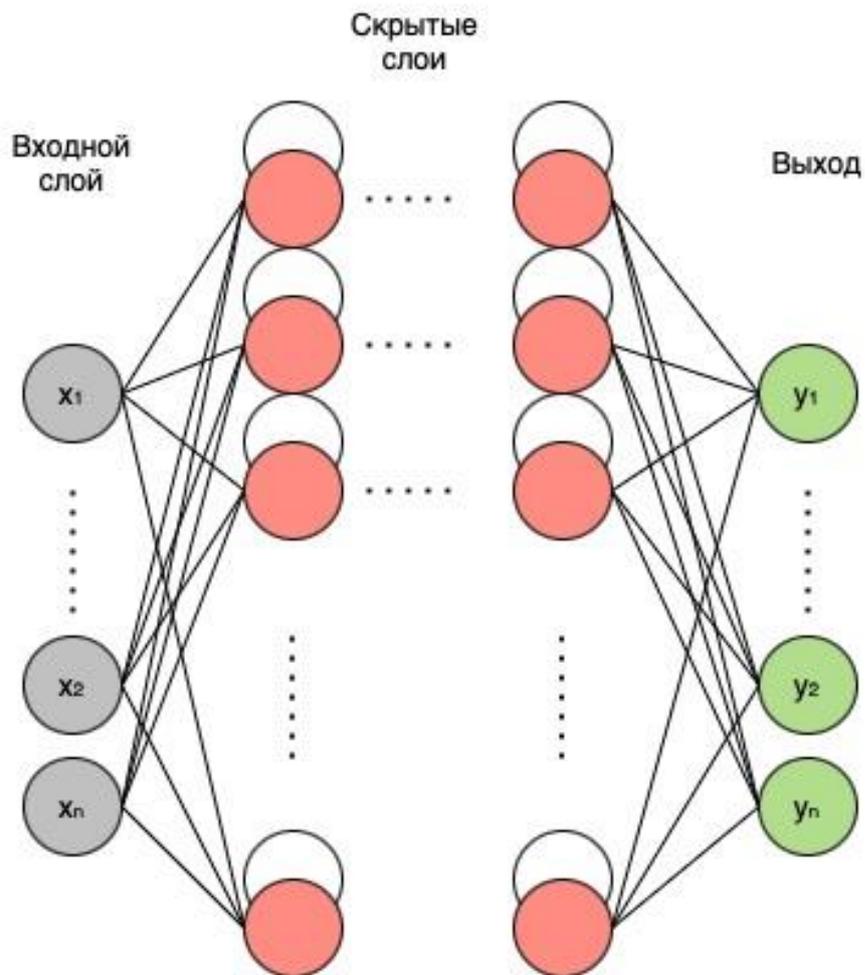


Рисунок 5 – Рекуррентная нейронная сеть RNN.

Рекуррентные нейронные сети RNN (Recurrent neural network), в отличие от сетей прямого распространения, обладают свойством циклического возврата выходных данных из слоев обратно в сеть. Таким образом, можно оценить влияние начальных значений на более поздние. Такие сети подходят для прогнозирования параметров сетевого трафика: объема, классификации протоколов и распределения протоколов [30].

RNN обеспечивают лучшие результаты в прогнозировании последовательных данных по сравнению с FFNN, но при этом сохраняется проблема затухающего градиента для очень длинных последовательностей.

Согласно [14, 15] ИНС типа LSTM используются для прогнозирования трафика в сотовых сетях и в транспортных системах. Также, в исследовании [16] отмечается специализация LSTM в прогнозировании временных рядов благодаря ячеистой архитектуре. Исследования демонстрируют, что модели LSTM оказались

более точными в прогнозировании месячного потока трафика по сравнению с моделями ARIMA. В этом исследовании использовались метрики средней абсолютной ошибки (MAE), средней абсолютной процентной ошибки (MAPE) и корня среднеквадратичной ошибки (RMSE) для оценки адекватности моделей. Результаты показали, что модели LSTM лучше подходят для прогнозирования трафика, так как они лучше справляются с нелинейными зависимостями в данных и обеспечивают более точные краткосрочные прогнозы [31].

В другом исследовании, проведенном для прогнозирования временных рядов, модели LSTM показали превосходство над моделями ARIMA в задачах прогнозирования цен акций. В этом исследовании использовались метрики RMSE, которые показали, что модели LSTM имеют меньшую ошибку прогноза по сравнению с моделями ARIMA. Это подтверждает, что модели LSTM лучше справляются с задачами, где необходимо учитывать сложные временные зависимости и нелинейности данных [32].

LSTM специализируются на прогнозировании временных последовательностей благодаря своей архитектуре: три фильтра, представленные ниже, которые обновляют состояние ячейки и представлены на рисунке 6.

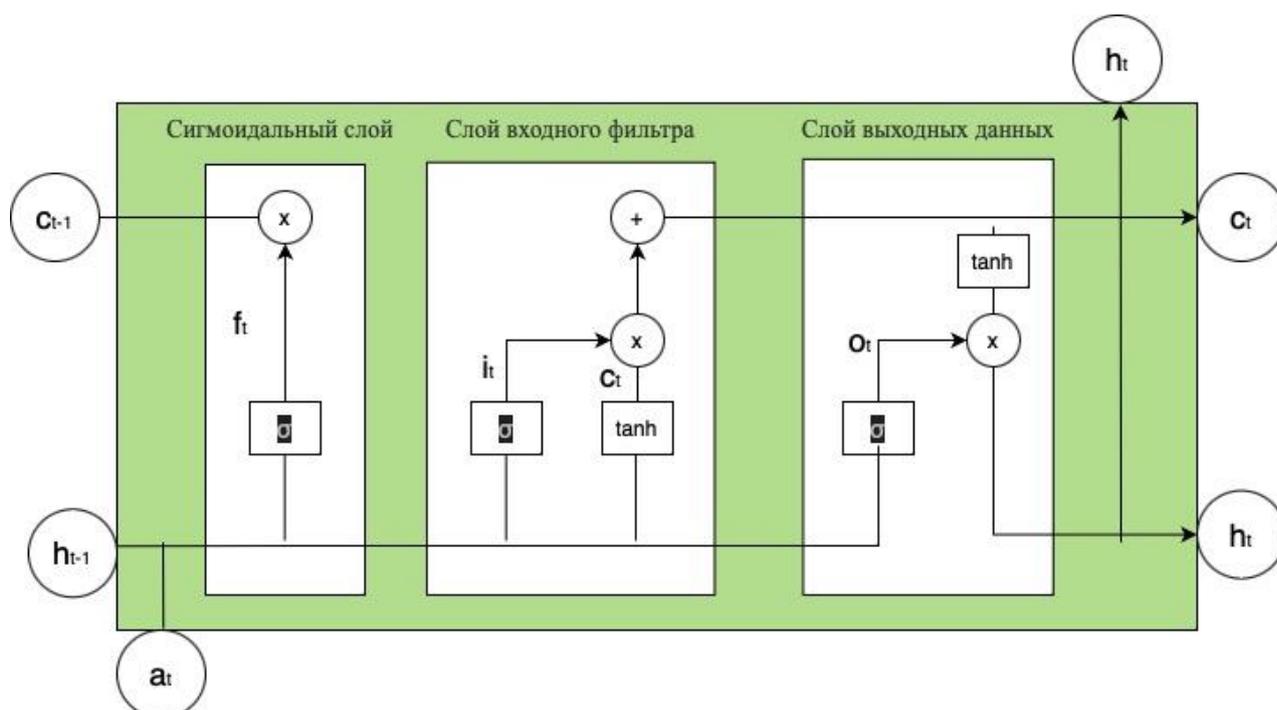


Рисунок 6 – Операции внутри ячейки LSTM.

- Сигмоидальный слой, благодаря которому принимается решение является ли информация релевантной или должна быть «забыта».

Входы такого фильтра являются значениями текущего входного значения  $a_t$  и предыдущего скрытого состояния  $h_{t-1}$ , которые проходят через сигмоидальную функцию и возвращают значение в  $f_t$  от 0 до 1. Таким образом, для каждого числа из состояния ячейки  $c_{t-1}$  получается итог в виде двух вариантов действий: полностью сохранить или “забыть” благодаря операции перемножения  $c_{t-1}$  и  $f_t$ ;

- Слой входного фильтра, который определяет, какие значения следует обновить и затем с помощью функции гиперболического тангенса (*tanh*-слой) строит вектор новых значений-кандидатов  $\tilde{C}_t$ , которые можно добавить в состояние ячейки.

Основная операция на данном шаге — произведение между  $i_t$  и  $\tilde{C}_t$  (значения-кандидаты, которые можно считать релевантными и добавлять к состоянию ячейки).  $\tilde{C}_t$  — это функция гиперболического тангенса (*tanh*)  $a_t$  и  $h_{t-1}$  (с соответствующими весовыми матрицами) для возвращения значений от -1 до 1. Такая функция используется для регулирования значений внутри ячейки, избегая того, чтобы они стали очень большими. На последнем этапе вычисляется сумма между выходом сигмоидального слоя и произведением между  $i_t$  и  $\tilde{C}_t$ .

- Обновленное состояние ячейки  $c_t$  является итогом предыдущего шага и сохраняет соответствующую информацию даже с самых ранних шагов.
- Слой выходных данных определяет следующее скрытое состояние, которое содержит соответствующую информацию о предыдущих шагах.

Первым шагом  $a_t$  и  $h_{t-1}$  (с соответствующими весовыми матрицами) проходят через сигмоидальный слой, который решает, какую информацию из состояния ячейки мы будем выводить. Затем значения состояния ячейки проходят через *tanh*-слой, чтобы получить на выходе значения из диапазона от -1 до 1, и перемножаются с выходными значениями сигмоидального слоя, что позволяет выводить только требуемую информацию т.е. умножаются на гиперболический тангенс  $c_t$  и результатом является новое скрытое состояние  $h_t$ .

В таблице 2 представлены преимущества и недостатки моделей прогнозирования для временных рядов.

Таблица 2 – Недостатки и преимущества моделей прогнозирования

Модель прогнозирования	Недостатки	Преимущества
SARIMA ARIMA ARMA	Прогнозирование данных основано исключительно на прошлых значениях	Высокая интерпретируемость параметров
NN RNN LSTM GRU CNN GNN	– низкая интерпретируемость параметров; – требуется большое количество гиперпараметров; – высокие вычислительные затраты на этапе обучения	Согласно научной литературе, демонстрирует лучшие результаты по сравнению со статистическими подходами

Таким образом, модели прогнозирования на основе ИНС, несомненно имеют ряд преимуществ по сравнению с традиционными подходами. Само понятие ИИ представляет собой область компьютерной науки, которая занимается разработкой и применением алгоритмов и моделей, способных имитировать человеческое мышление и поведение. В контексте сетей пятого и последующих поколений ИИ может использоваться для оптимизации качества обслуживания QoS, улучшения производительности и обеспечения более эффективного использования ресурсов.

## 1.6 Выводы по главе

По содержанию главы можно сделать следующие выводы:

1. Исследована научная литература в области изучения современного трафика. Современная гетерогенная сеть порождает сетевой трафик со сложной (неоднородной) структурой. Рост объемов разнородного трафика в инфокоммуникационных сетях актуализирует вопросы обеспечения качества предоставляемых услуг связи, что в свою очередь требует обращения к моделям прогнозирования.

2. Модели, построенные на основе данных, характеризующего один объект за ряд последовательных моментов времени (временные ряды) обладают свойством нестационарности, что означает, что их структура многокомпонентная. Поэтому задачи управления сетью основываются, в том числе и на предсказанных будущих данных для принятия правильного решения. Выявить и количественно выразить компоненты сложной структуры, определить наличие или отсутствие тенденции, периодичности, случайной компоненты является основной задачей анализа временного ряда.

3. Произведен анализ моделей и методов прогнозирования сетевого трафика для краткосрочных и долгосрочных прогнозов. Определено, что для краткосрочного прогноза при работе с агрегированными данными с целью прогноза объема трафика в режиме реального времени предпочтительнее использовать статистические модели, а в остальных случаях структурные. Среди статистических подходов наиболее популярным методом прогнозирования являются модели авторегрессии и проинтегрированного скользящего среднего (ARIMA, autoregressive integrated moving average). Модель ARIMA является важным классом параметрических моделей, которые позволяют описывать нестационарные ряды. Модели авторегрессионного класса вполне подходят для интеграции в сетевые устройства как аналитическая программа, работающая на

агрегационных данных, что позволит в реальном времени предсказывать поведение объема трафика на коротком промежутке времени.

4. Рассмотрено свойство современного сетевого трафика — самоподобие. Для самоподобного процесса характерно сохранение некоторых статистических особенностей при масштабировании времени. Точная модель предсказания трафика должна иметь возможность фиксировать значимые характеристики: например, зависимости в краткосрочной и долгосрочной перспективе, самоподобие на больших временных масштабах и высокий уровень мультифрактальности на малых масштабах времени. По этим причинам вводятся модели временных рядов для моделирования и предсказания сетевого трафика.

5. Рассмотрена итеративная процедура построения моделей для описания зависимости наблюдаемых временных рядов.

6. Произведен анализ моделей и методов прогнозирования сетевого трафика на основе ИНС. RNN обеспечивают лучшие результаты в прогнозировании последовательных данных по сравнению с FFNN, но при этом сохраняется проблема затухающего градиента для очень длинных последовательностей. Алгоритмы нейронной сети с глубоким обучением могут идентифицировать нелинейную функцию и осуществить прогнозирование. ИНС типа LSTM используются для прогнозирования трафика в сотовых сетях и в транспортных системах. LSTM специализируются на прогнозировании временных последовательностей благодаря своей архитектуре, которая представлена в виде трех фильтров.

7. В результате проведенного анализа представлены преимущества и недостатки моделей прогнозирования для временных рядов.

## ГЛАВА 2 ПРОГНОЗИРОВАНИЕ ТРАФИКА ИНТЕРНЕТА ВЕЩЕЙ С ПОМОЩЬЮ АВТРЕГРЕССИОННОЙ МОДЕЛИ ARIMA НА КРАТКОСРОЧНОМ ПЕРИОДЕ

### 2.1 Структура модели авторегрессии и проинтегрированного скользящего среднего ARIMA

При попытке разобраться в структуре ARIMA, важно сразу уточнить, что основной составляющей модели является недетерминированный ряд, рассматриваемый при анализе реализацией стохастического процесса [14].

Стохастический процесс — модель, описывающая вероятностную структуру последовательности наблюдений. Важным классом такого наблюдения является стационарный процесс, для описания которого успешно используются автокорреляционные функции. Также, стоит отметить частные случаи стохастических стационарных процессов при моделировании временных рядов: авторегрессия, скользящие средние и смешанные процессы между этими двумя составляющими. При рассмотрении сетевого трафика, подразумевается наличие нестационарных характеристик, поэтому из стационарных процессов выводится новый класс нестационарных — модели авторегрессии и проинтегрированного скользящего среднего.

Авторегрессионная модель AR (p) — выражает текущее значение процесса как конечную линейную совокупность предыдущих значений процесса и импульса белого шума:

$$\varphi(B)\tilde{\beta}_t = a_t, \quad (3)$$

где  $\tilde{\beta}_t = \beta_t - \mu$  — уровень временного ряда в момент времени  $t$  (зависимая переменная) с учётом разности значения процесса относительно параметра уровня  $\mu$ ;  $\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$  — оператор авторегрессии порядка  $p$ .

Модель скользящего среднего MA ( $q$ ) даёт прогноз значений функции  $\beta_t$  на основе линейной комбинации ограниченного числа  $q$  остатков, в то время как авторегрессионные модели AR ( $p$ ) дают прогноз значения  $\beta_t$  на основании линейной функции аппроксимации ограниченного числа  $p$  прошлых значений  $\beta_t$ :

$$\tilde{\beta}_t = \theta(B)a_t, \quad (4)$$

где  $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_p B^p$  — оператор скользящего среднего порядка  $q$ .

Авторегрессионную модель и модель со скользящим средним можно объединить. Модель авторегрессии и скользящего среднего ARMA ( $p, q$ ), где  $p$  — порядок авторегрессионной части модели,  $q$  — порядок части скользящего среднего, записывается как (1). Данная модель позволяет составлять прогноз, зависящий как от текущего и прошлого значений зависимой переменной, так и от текущих и прошлых значений величины случайного возмущения [33].

## 2.2 Исследование трафика интернета вещей и свойство самоподобия

Анализ трафика проводился на основе реальных дампов трафика, в котором присутствует нагрузка интернета вещей (Internet of Things, IoT) [34]. Данные интеллектуальной среды, состоящей из устройств интернета вещей, собирались в течение шести месяцев. В число устройств входили камеры, светильники, розетки, датчики движения, бытовая техника и мониторы состояния здоровья. Только часть данных доступна для использования исследовательским сообществом. Помимо устройств типа IoT в сформированных файлах присутствует также трафик устройств, не относящихся к данному типу. На веб-ресурсе

<https://iotanalytics.unsw.edu.au/iottraces.html> представлены дампы трафика за 20 дней, а сами данные имеют форматы **pcap** и **csv**.

Таким образом, перед анализом сетевого трафика было необходимо отфильтровать данные в формате **pcap** по принципу отбрасывания пакетов, физический адрес которых не относился к устройствам типа IoT. Фильтрация нужного набора пакетов проводилась в программе анализа сетевого трафика Wireshark. Для примера на рисунке 7 представлено распределение трафика в течение 10 дней для дальнейшего прогнозирования.

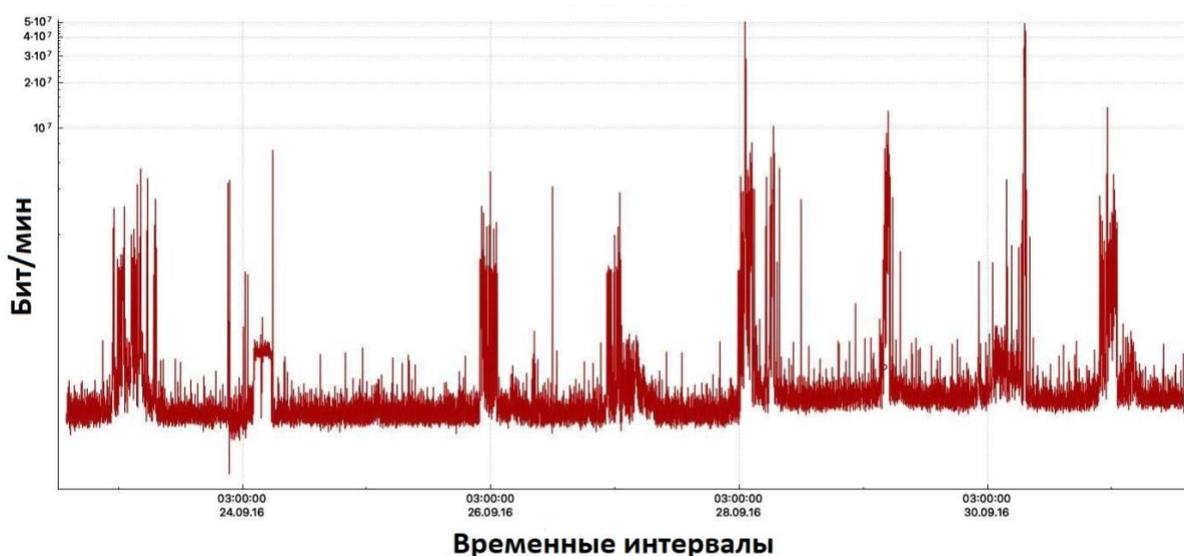


Рисунок 7 – Распределение трафика типа интернета вещей в течение 10 дней

Как показано на рисунке 7, наибольшая интенсивность трафика наблюдается в ночное время, что может быть связано с режимом работы устройств интернета вещей и/или со стремлением уменьшить нагрузку канала в период пиковой нагрузки днем.

При начальном анализе дампов трафика были получены графики плотностей распределения интервалов между пакетами (рисунок 8) и длин пакетов (рисунок 9) [26].

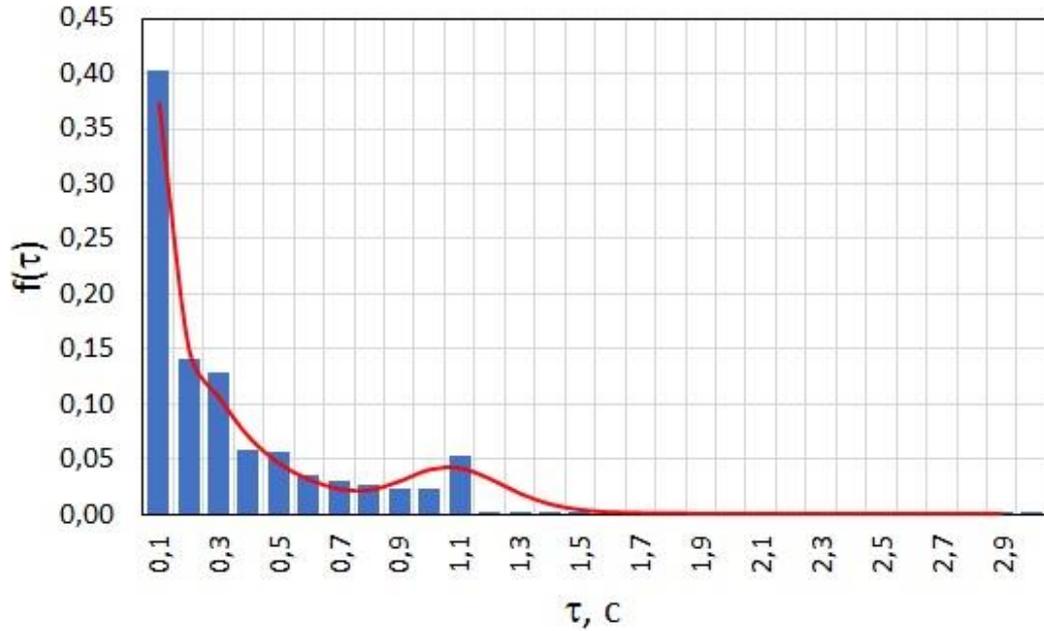


Рисунок 8 – Плотность распределения времени между пакетами трафика интернета вещей

Как видно на рисунке 8, полученное распределение было аппроксимировано и на основе этой аппроксимации была выведена математическая функция вида

$$f(t) = k_1 f_1(t) + k_2 f_2(t) + \dots + k_m f_m(t) = \sum_{i=1}^m k_i f_i(t), \quad (5)$$

где  $m > 0$ ;  $\sum_{i=1}^m k_i = 1$ .

Таким образом, для плотности распределения, подходящей под данный пример, было подобрано три коэффициента. Несмотря на то, что распределение времени между пакетами на промежутке между 0,5 и 1 с можно идентифицировать как экспоненциальную функцию с коэффициентом  $k_1=0,15$ , не рекомендуется игнорировать всплеск на графике при 1,1 с. На промежутках времени  $\tau < 0,3$  с и  $\tau > 0,8$  с распределение можно аппроксимировать гамма-функциями с коэффициентами  $k_2=0,1$  и  $k_3=0,15$  соответственно.

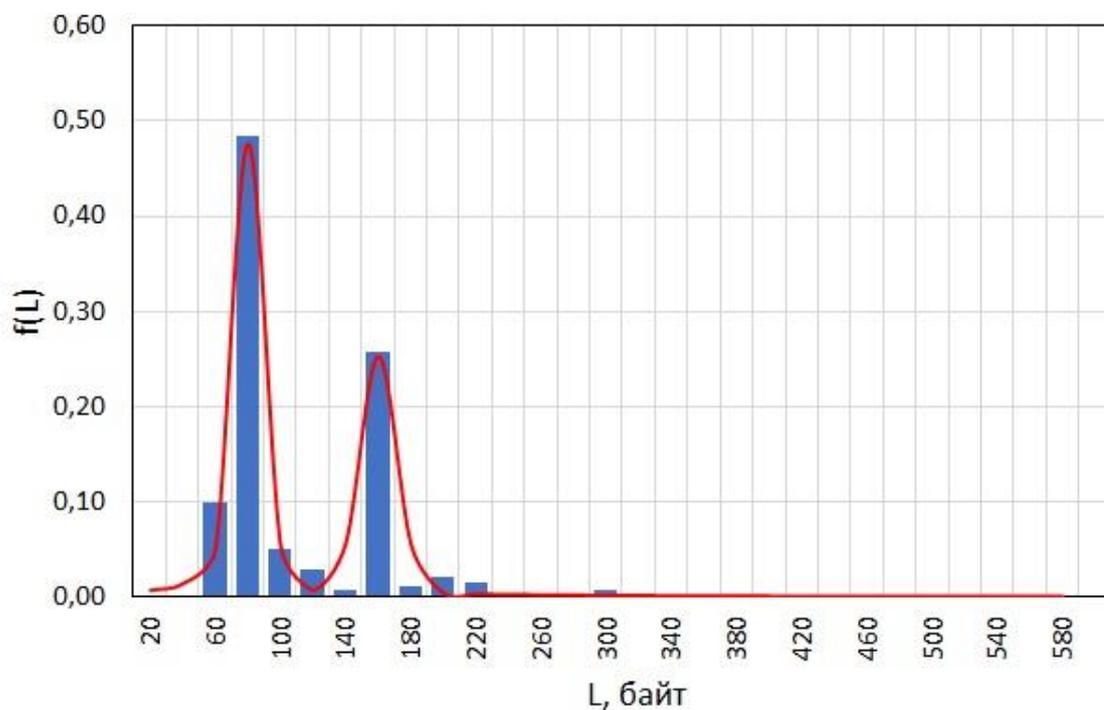


Рисунок 9 – Плотность распределения длин пакетов трафика интернета вещей

На рисунке 9 видно, что в трафике данных устройств интернета вещей преобладают пакеты длиной 60–80 байт (наибольшая вероятность составляет около 50%), второй максимум наблюдается для пакетов длиной 140–160 байт (с вероятностью 25%).

Для аппроксимирующей функции такого распределения также можно взять формулу (5). Два значимых всплеска на графике можно описать двумя гамма-распределениями с коэффициентами  $k_1=0,55$  и  $k_2=0,35$ , дополнительно добавив экспоненциальное распределение при  $k_3=0,1$ . Таким образом, с помощью полученных функций можно впоследствии смоделировать трафик для будущих исследований.

Для дальнейшего исследования трафика использовались файлы в формате `csv`, которые содержали такие характеристики, как идентификационный номер, дата, время, физические адреса устройств отправителя и получателя, тип протокола и длина пакетов. Обработка и визуализация такого массива данных осуществлялась с помощью программы, написанной на языке Python. Для оптимального анализа в

исследуемых файлах удалялись все характеристики, кроме времени поступления и длин пакетов.

В соответствии с методикой, описанной в [35], имеющиеся данные, соответствующие временному промежутку в 24 ч с 17:00 23.09 до 17:00 24.09 приводились в эквидистантный вид с различным временем агрегации. На рисунке 10 представлено распределение трафика в течение 24 ч на примере одного из дней наблюдения с периодом агрегации 10 мин.

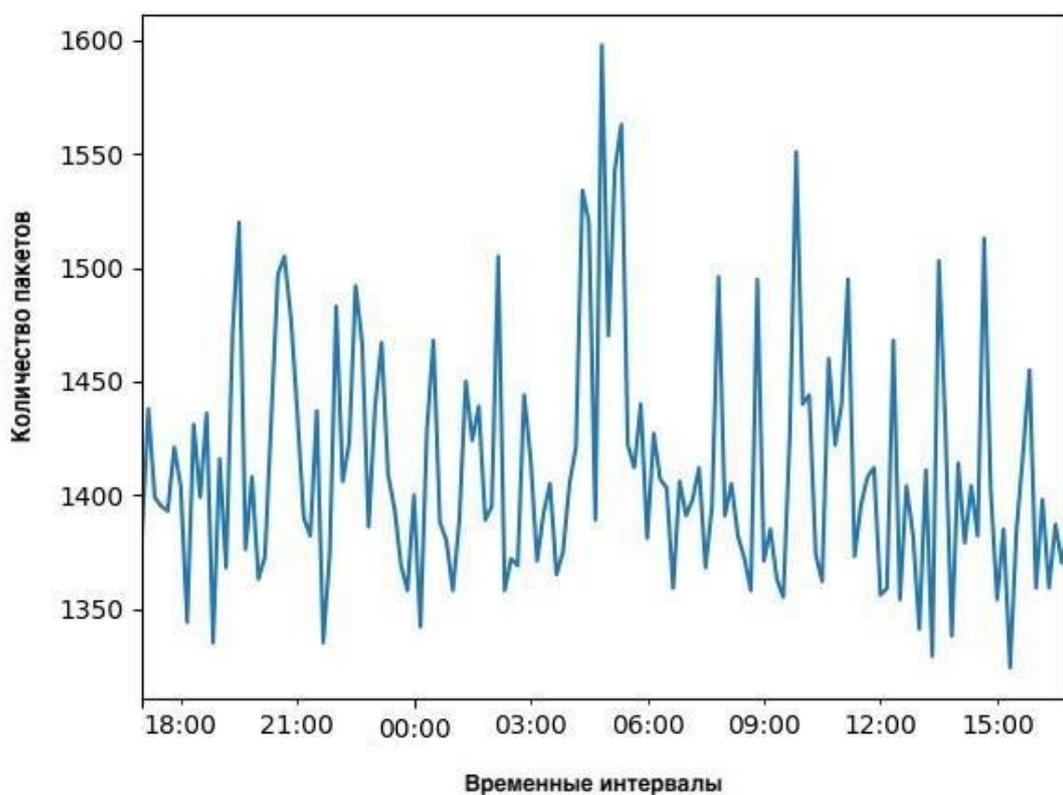


Рисунок 10 – Распределение трафика на временных интервалах с периодом агрегации 10 мин в первый день наблюдений

Таким же образом данные, соответствующие временному промежутку в 24 часа с 17:00 24.09 до 17:00 25.09 приводились в эквидистантный вид с различным временем агрегации. Пример представлен на рисунке 11.

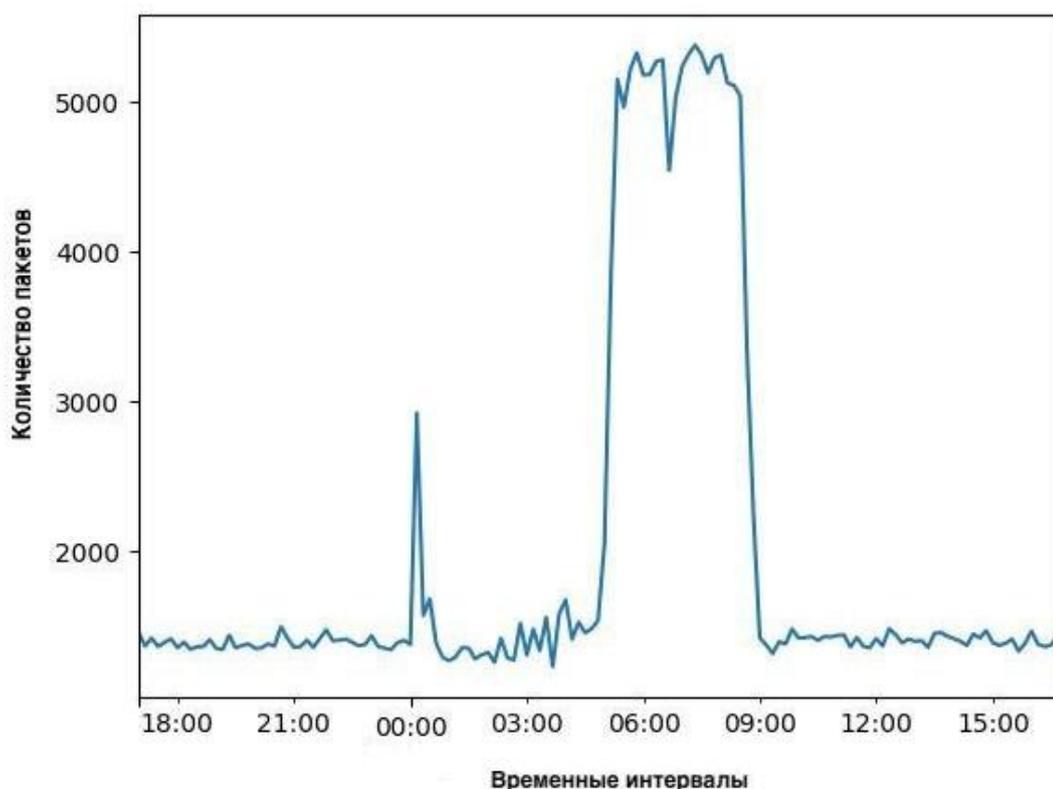


Рисунок 11 – Распределение количества пакетов на временных интервалах с периодом агрегации 10 мин во второй день наблюдений

Как видно на рисунках 10 и 11, трафик такого типа может характеризоваться различными распределениями данных в разные дни. Для изучения самоподобия трафика рассчитывался индекс Херста с применением RS-анализа, результаты которого приведены в таблице 3.

Таблица 3– Результаты расчета параметра Херста

Период агрегации	Параметр Херста, H	
	с 17:00 23.09 до 17:00 24.09	с 17:00 24.09 до 17:00 25.09
1 с	0,9264	0,9348
10 с	0,8155	0,9645
1 мин	0,6050	0,9914
10 мин	0,1181	0,9483

Полученные результаты свидетельствуют о наличии свойства самоподобия у разных дампов трафика при различных уровнях агрегации, что может быть использовано для дальнейшего изучения характеристик такого рода трафика.

### 2.3 Применение итеративного подхода при разработке алгоритма по подбору оптимальной модели прогнозирования ARIMA

Следующим этапом анализа имеющихся дампов рассматривался наиболее загруженный промежуток времени в период с 17:00 27.09 по 17:00 28.09. Полученный временной ряд содержал 2821835 отсчетов, из которых был выбран тренировочный участок, который был приведен в эквидистантный вид с временем агрегации 200 мс (рисунок 12).

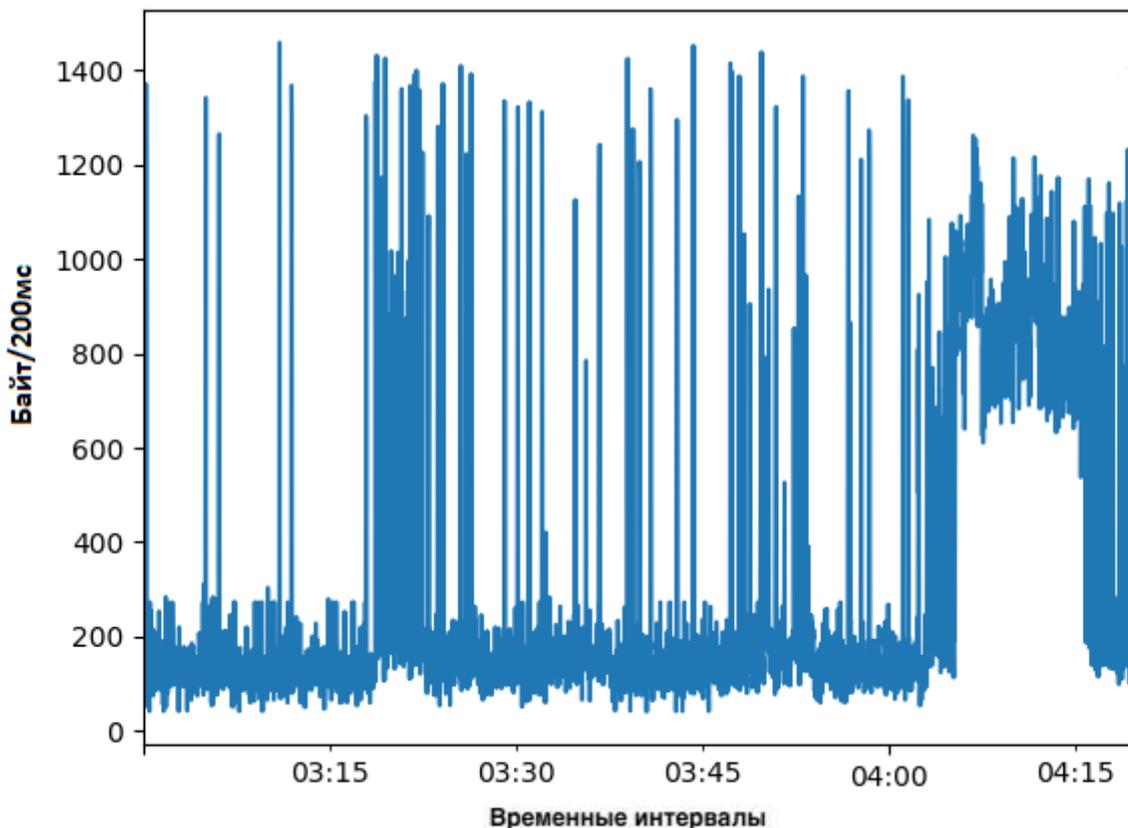


Рисунок 12 – Тренировочный участок трафика с 4000 отсчетов

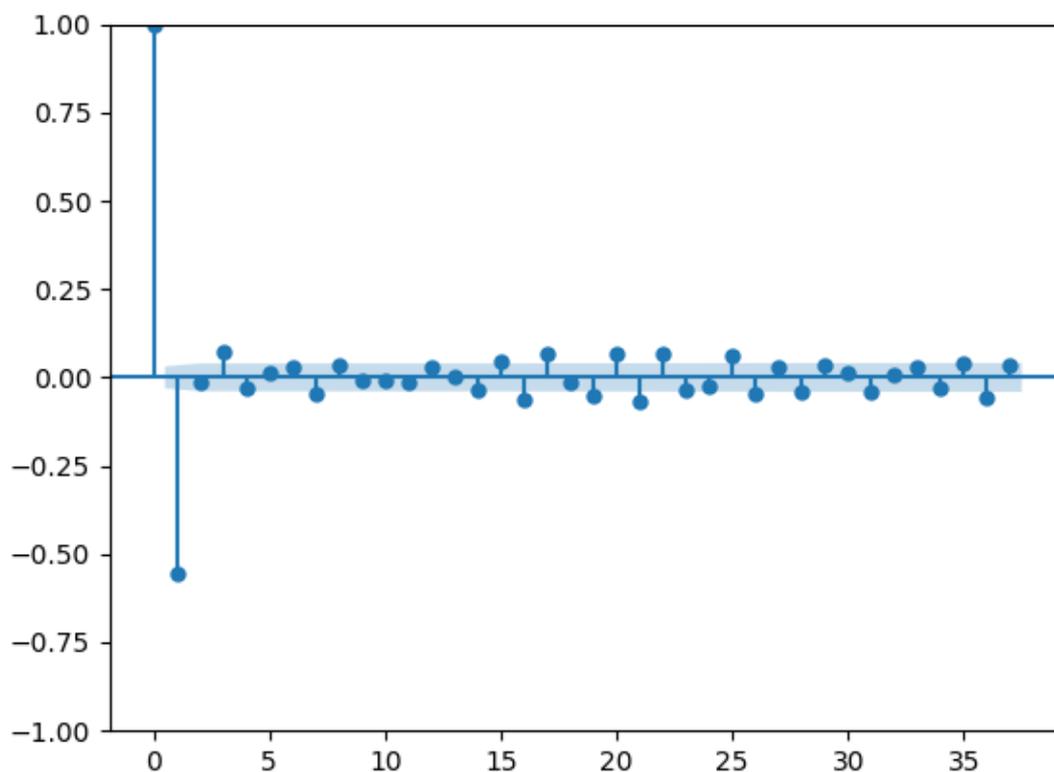
В соответствии с методикой Бокса-Дженкинса тренировочный участок проверялся на стационарность с помощью статистики Дики-Фуллера. Результаты представлены в таблице 4.

Таблица 4 – Результаты статистики Дики-Фуллера

Период агрегации	ADFT	p-величина	1%	5%	10%	Итог
Тренировочный участок	-2,40	0,141	-3,432	-2,862	-2,567	нестационарен
Последовательное взятие разности ( $d=1$ )	-17,61	$3,89e-30$	-3,432	-2,862	-2,567	стационарен
Последовательное взятие разности ( $d=2$ )	-24,63	0,0	-3,432	-2,862	-2,567	стационарен

Согласно значениям критерия расширенного теста Дики-Фуллера (ADF-тест) тренировочный временной ряд является нестационарным, поскольку нулевая гипотеза о наличии единичного корня подтверждается на 5%-ном уровне значимости [13]. Таким образом, ряд подвергается взятию последовательной разности, и тест повторяется. Для подтверждения тестов на стационарность на рисунке 13 представлен временной ряд при  $d=2$  и соответствующая ему автокорреляционная функция (АКФ).

## ACF (d=2)

Рисунок 13 – АКФ тренировочного участка при  $d=2$ 

После применения дифференцирования временной ряд не имеет уже ярко выраженного тренда, и среднее значение ряда эквивалентно нулю. После взятия последовательной разности второго порядка значение  $p$  падает до минимального значения. Таким образом, можно выдвинуть предположение о порядке разности, равным 2, что визуально согласуется с графиком автокорреляции. Однако значение  $p$  для первого порядка намного ближе к пороговому значению, поэтому была выдвинута гипотеза о первом порядке разности ( $d=1$ ). Соответственно была получена модель вида  $ARIMA(p,1,q)$ , так как ADF-тест пройден и операция последовательной разности была применена один раз.

Теперь необходимо произвести оценку порядка параметров  $p$  и  $q$  модели  $ARMA(p,q)$ , которая, в свою очередь, представляет собой модели  $AR(p)$  и  $MA(q)$ . Соответственно, необходимо проанализировать характер поведения выборочных автокорреляционной и частной автокорреляционной функций (ЧАКФ) (последняя

показана на рисунке 14) и выдвинуть гипотезы о значениях параметров  $p$  (порядок авторегрессии) и  $q$  (порядок скользящего среднего).

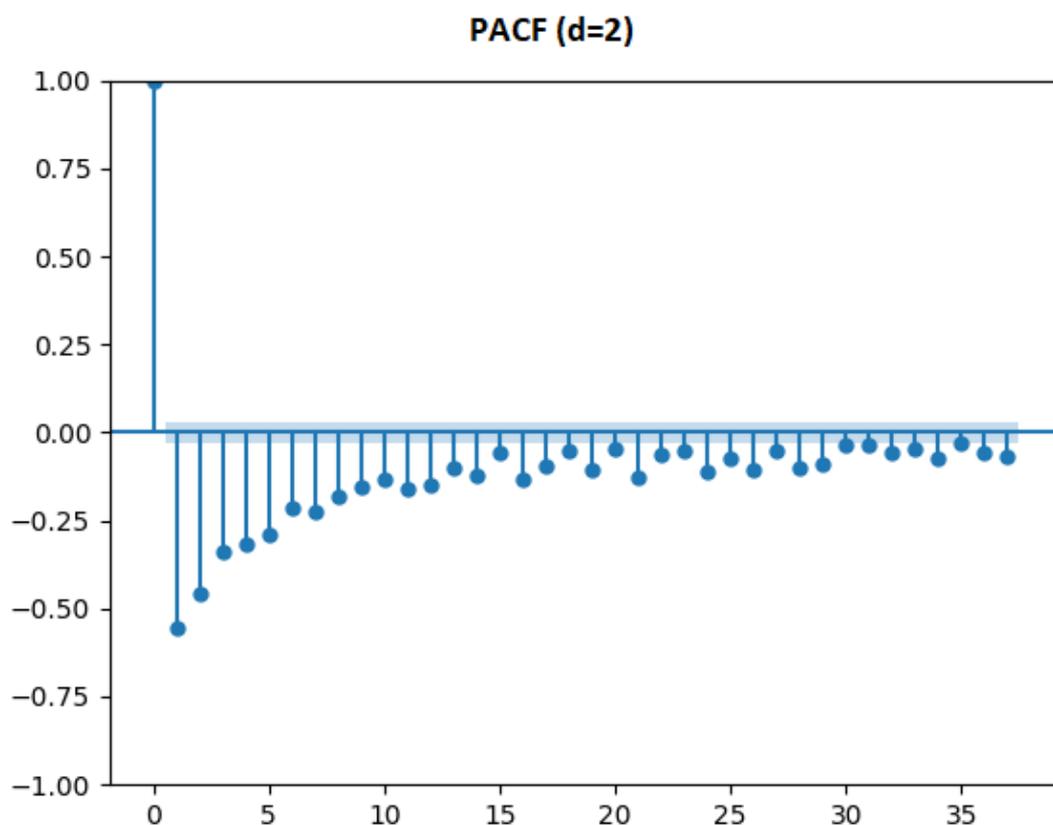


Рисунок 14 – ЧАКФ тренировочного участка трафика при дифференцировании

Первый лаг является наиболее значительным. Таким образом, была выдвинута гипотеза о порядке авторегрессии, равном  $p=1$ .

Порядок скользящего среднего оценивался аналогичным методом, основываясь на графиках АКФ. Таким образом, была выдвинута гипотеза о параметре скользящего среднего, равном  $q=2$ . Итоговая модель ARIMA была определена как ARIMA(1,1,2) (рисунок 15).

```

=====
Dep. Variable:                Length    No. Observations:           4888
Model:                        ARIMA(1, 1, 2)  Log Likelihood              -26472.186
Date:                          Sun, 21 Apr 2024          AIC                          52952.372
Time:                           16:08:44              BIC                          52977.547
Sample:                          09-28-2016            HQIC                         52961.296
                                - 09-28-2016
Covariance Type:                opg
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
ar.L1          0.1031      0.035         2.928      0.003      0.034      0.172
ma.L1         -0.7288      0.036        -20.264     0.000     -0.799     -0.658
ma.L2         -0.2048      0.032         -6.334     0.000     -0.268     -0.141
sigma2        3.29e+04     236.949     138.830     0.000     3.24e+04     3.34e+04
=====
Ljung-Box (L1) (Q):                0.00      Jarque-Bera (JB):           60047.78
Prob(Q):                            0.98      Prob(JB):                   0.00
Heteroskedasticity (H):             0.99      Skew:                       3.35
Prob(H) (two-sided):                0.85      Kurtosis:                   20.76
=====

```

Рисунок 15 – Предварительные результаты по модели ARIMA(1,1,2)

При оценке такой модели были выявлены достаточно большие значения байесовского информационного критерия (Bayesian information criterion, BIC) и информационного критерия Акаике (AIC).

Таким образом, дополнительно с помощью программной среды Python был сформирован код для расчета оптимальной модели ARIMA( $p,d,q$ ). Результаты представлены в таблице 5, где значения информационного критерия AIC, который оценивает, насколько хорошо модель подходит под данные, сравниваются в разных моделях ARIMA.

Таблица 5 - Результат подбора моделей ARIMA( $p,d,q$ )

Предлагаемая модель ARIMA( $p,d,q$ )	Результат оценки AIC
(0,1,0)	54467,19
(0,1,1)	53288,93
(0,1,2)	52953,54
(1,1,2)	52952,37
(1,5,3)	59433,43
(1,5,4)	1494,80

Основываясь на полученных данных, оптимально выбрать модель ARIMA(1,5,4). На рисунке 16 представлены результаты оценки такой модели с минимальным критерием AIC.

Dep. Variable:		Length	No. Observations:		4800	
Model:		ARIMA(1, 5, 4)	Log Likelihood		-741.401	
Date:		Mon, 22 Apr 2024	AIC		1494.802	
Time:		18:37:27	BIC		1532.559	
Sample:		09-28-2016	HQIC		1508.187	
		- 09-28-2016				
Covariance Type:		opg				
	coef	std err	z	P> z	[0.025	0.975]
ar.L1	0.9999	0.001	1112.255	0.000	0.998	1.002
ma.L1	-3.9999	0.009	-423.215	0.000	-4.018	-3.981
ma.L2	5.9997	1.3e-08	4.63e+08	0.000	6.000	6.000
ma.L3	-3.9998	0.010	-396.578	0.000	-4.020	-3.980
ma.L4	1.0000	0.001	1532.426	0.000	0.999	1.001
sigma2	2.4e+04	9.25e-09	2.59e+12	0.000	2.4e+04	2.4e+04

Рисунок 16 – Предварительные результаты по модели ARIMA(1,5,4)

Средняя абсолютная процентная ошибка (MAPE):

$$\text{MAPE} = \frac{100\%}{L} \sum_{t=1}^L \left| \frac{X_t - \hat{X}_t}{X_t} \right|, \quad (6)$$

где  $X_t$  – реальное значение;  $\hat{X}_t$  – прогнозное значение;  $L$  – интервал прогноза. Если  $\text{MAPE} < 10\%$ , то прогноз сделан с высокой точностью, если  $10\% < \text{MAPE} < 20\%$  – прогноз хороший,  $20\% < \text{MAPE} < 50\%$  – прогноз удовлетворительный,  $\text{MAPE} > 50\%$  – прогноз плохой.

Для рассматриваемой на первом этапе подбора модели ARIMA(1,1,2) средняя абсолютная ошибка составила около 90%, что говорит о плохом прогнозе. Для второй модели ARIMA(1,5,4) полученное значение  $\text{MAPE} = 19\%$  можно оценить как хороший прогноз, но он уже достаточно близок к удовлетворительному [36].

## 2.4 Выводы по главе

По содержанию главы можно сделать следующие выводы:

1. Частные случаи стохастических стационарных процессов при моделировании временных рядов: авторегрессия, скользящие средние и смешанные процессы между этими двумя составляющими. При рассмотрении сетевого трафика, подразумевается наличие нестационарных характеристик, поэтому из стационарных процессов выводится новый класс нестационарных — модели авторегрессии и проинтегрированного скользящего среднего.

2. Проведен анализ авторегрессионных моделей прогнозирования сетевого трафика таких как модель авторегрессии и проинтегрированного скользящего среднего ARIMA.

3. Для повышения точности прогнозирования трафика модели ARIMA можно объединять с другими методиками. Например, существует дополнение к моделям ARIMA в виде моделей, характеризующихся условной гетероскедастичностью, которые учитывают прошлые составляющие временных рядов и вводятся для объяснения характерных всплесков трафика.

### ГЛАВА 3 ПРОГНОЗИРОВАНИЕ ТРАФИКА РЕАЛЬНОГО ВРЕМЕНИ С ПОМОЩЬЮ ГИБРИДНОЙ МОДЕЛИ АВТРЕГРЕССИИ ARIMA С ПРИМЕНЕНИЕМ УСЛОВНОЙ ГЕТЕРОСКЕДАСТИЧНОСТИ GARCH НА КРАТКОСРОЧНОМ ПЕРИОДЕ

#### 3.1 Модель GARCH

Согласно [37], начальное понятие гетероскедастичности плавно вытекает из предпосылки, именуемой гомоскедастичностью и подразумевающей, что дисперсия случайных отклонений  $\varepsilon_i$  постоянна для любых наблюдений  $i, j$ :

$$D(\varepsilon_i) = D(\varepsilon_j) = \sigma^2, \quad (7)$$

где  $\sigma^2$  – дисперсия случайных отклонений;  $i = 1, 2, \dots, n; j = 1, 2, \dots, k$ .

Таким образом, при наличии непостоянства дисперсии отклонений можно говорить о гетероскедастичности.

Возглавляет семейство GARCH моделей, которые изначально предназначены для изучения рядов, характеризующихся разбросом временного ряда (волатильностью), модель авторегрессионной условной гетероскедастичности ARCH (autoregressive conditional heteroscedasticity). Условная гетероскедастичность подразумевает моделирование такого разброса во временных рамках как «условная дисперсия в момент  $t$  при известной информации только до момента  $(t-1)$  включительно» [16]. Соответственно, дисперсия текущих отклонений является функцией от значений отклонений в предыдущие моменты времени.

Ориентируясь на представленные в [16] данные, можно утверждать, что безусловное распределение остатков  $\varepsilon_i$  в ARCH модели обладает большим куртозисом (имеет более тяжелые «хвосты» по сравнению с нормальным распределением).

Модель GARCH ( $p, q$ ) именуется обобщённой и является одним из способов представления ARCH модели с большим числом лагов. Наиболее отличительной чертой GARCH является его условная дисперсия (меняется с течением времени) и обладание свойствами моделей авторегрессии - скользящего среднего ARMA (autoregressive moving-average model) [23, 38].

Общая модель GARCH для условной дисперсии  $\alpha_t$  предполагает, что [22]

$$\alpha_t = \sigma_t e_t, \quad (8)$$

где  $e_t$  – последовательность независимых и одинаково распределённых случайных величин со средней, равной нулю, и дисперсией, равной единице.

Модель GARCH( $s, r$ ) характеризует условную дисперсию ошибки прогнозирования  $\alpha_t$  и записывается в общем виде, как

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^s \alpha_i \alpha_{t-i}^2 + \sum_{j=1}^r \beta_j \sigma_{t-j}^2, \quad (9)$$

где  $\alpha_0 > 0$ ;  $\alpha_i \geq 0$ ;  $i = 1, \dots, (s-1)$ ;  $\alpha_s > 0$ ;  $\beta_j \geq 0$ ;  $j = 1, \dots, (r-1)$ ;  $\beta_r > 0$ ;  $\alpha_0, \alpha_i, \beta_j$  – коэффициенты модели;  $r$  – порядок GARCH-членов;  $s$  – порядок ARCH-членов.

Множество исследований показывают негативный вклад увеличения количества лагов в качество прогноза GARCH моделей. Поэтому обычно используются спецификации с  $s \leq 2$  и  $r \leq 2$ , и наиболее популярной и часто используемой является модель GARCH(1,1).

### 3.2 Модель ARIMA/GARCH

Для повышения точности прогнозирования трафика модели ARIMA можно объединять с другими методиками. Например, существует дополнение к моделям

ARIMA в виде моделей, характеризующихся условной гетероскедастичностью, которые учитывают прошлые составляющие временных рядов и вводятся для объяснения характерных всплесков трафика. Самоподобие на больших временных масштабах и долгосрочные зависимости являются следствием определённого поведения сетевого трафика – всплески или тяжелый «хвост». Для объяснения таких особенностей на малых масштабах времени существует понятие мультифрактальности [29].

Предположим, что необходимо изучить стационарный временной ряд  $\beta_t$ , который можно смоделировать как процесс ARMA (см. формулу (1)). В случае нестационарности такого ряда, возможно получить стационарный ряд в виде ARIMA (см. формулу (2)) методом дифференцирования. Таким образом, модель ARIMA является обобщением стандартной модели ARMA, в которой при нестационарности процесса используется метод дифференцирования.

Такие модели представляют собой линейные модели временных рядов с постоянной дисперсией параметра  $\alpha_t$ . Но, как было описано выше, эти модели не в состоянии адекватно и оптимально отразить такую характеристику, как условная дисперсия. Дополнительно этот факт подтверждается исследованием, согласно которому, экспоненциальный спад автокорреляционной функции моделей ARIMA дает им возможность фиксировать только характеристики зависимостей в краткосрочной перспективе [15]. Решение проблемы заключается в моделировании гетероскедастичности как нелинейной зависимости между последовательными ошибками. Именно поэтому модель GARCH, которая имеет изменяющуюся во времени дисперсию, может лучше охарактеризовать статистические характеристики рядов [39].

Модель ARIMA-GARCH объединяет модели ARIMA и GARCH для формирования нелинейной модели временных рядов. В общем виде такую модель можно записать, объединив выражения (2) и (8) в виде

$$\varphi(B)(1-B)^d\beta_t=\theta(B)\sigma_t e_t, \quad (10)$$

где  $\sigma_t^2$  описывается с помощью (9).

Характеристика дисперсии как «условная» подразумевает не только изменчивость с течением времени, но также и явную зависимость от прошедшей последовательности наблюдений. Соответственно, такое свойство моделей GARCH может фиксировать и объяснять характерные для сетевого трафика всплески, что подтверждает гибкость моделей ARIMA/GARCH при моделировании самоподобного трафика с зависимостями в долгосрочной перспективе.

Согласно исследованию проведенному в [5], с целью управления мгновенной пропускной способностью сегмента сети для операций реального времени, оптимально использовать краткосрочные методы, такие как модель экспоненциального сглаживания. Так же отмечаются модели на основе скользящих средних ARIMA, в частности ARIMA(1,1,0) для прогноза на 10 шагов вперед, однако результаты исследования демонстрируют более высокую среднюю абсолютную ошибку прогноза.

Согласно [40], так как ARIMA модели не в состоянии справиться с волатильностью и нелинейностью, которые присутствуют в данных, рекомендуется использовать преобразование Бокса-Кокса. Данный инструмент способен нормализовать данные и выровнять дисперсию. Таким образом, предлагается трансформировать данные по методу Бокса-Кокса, который применяется только для положительных рядов ( $y_t > 0$ ):

$$y_t^* = f(x) = \begin{cases} \frac{y_t^\lambda - 1}{\lambda}, \lambda \neq 0; \\ \ln(y_t), \lambda = 0, \end{cases} \quad (11)$$

где  $y_t^*$  – преобразованное значение в момент времени  $t$ ;  $\lambda$  – среднеквадратичное значение ошибки.

Важным условием эффективного прогнозирования с помощью модели ARIMA ( $p,d,q$ ) является преобразование ряда для достижения стационарности данных. Таким образом, при выявлении на начальном этапе у наблюдаемого

временного ряда определенных тенденций и несезонного поведения, необходимо применить дифференцирование с целью стабилизации дисперсии и устранения тренда. Данная процедура проводится с помощью расширенного теста Дики-Фуллера (augmented Dickey-Fuller test, ADF). Таким образом, две альтернативные гипотезы  $H_0$  и  $H_1$  предполагают, что ряд является стационарным ( $H_0$ ) и нестационарным ( $H_1$ ) соответственно. В случае опровержения гипотезы  $H_0$  временной ряд может быть приведен к стационарному путем взятия последовательной разности [41].

Для определения порядка параметров при построении модели используются автокорреляционная функция АКФ (autocorrelation function, ACF) и функция частичной автокорреляции ЧАКФ (partial autocorrelation function, PACF) выборочных данных. Впоследствии выбранная модель статистически проверяется на точность описания временного ряда. Предложенная модель является оптимальной если  $p$ -значения ее параметра статистически значимы, остатки распределены случайным образом и не содержат полезной информации.

Для подтверждения адекватности полученной модели необходимо убедиться, что ряд остатков представляет собой случайную компоненту [38]. Таким образом, чтобы оптимально провести анализ остатков сформированной модели используется  $Q$ -тест Льюнг–Бокса для проверки гипотезы на наличие автокорреляции в данных [42]:

$$Q = N(N+2) \sum_{j=1}^L \frac{\hat{p}_j^2}{(N-j)}, \quad (12)$$

где  $N$  – объем выборки;  $L$  – количество проверяемых лагов;  $\hat{p}_j^2$  – квадрат автокорреляции  $j$ -го порядка. При  $H_0$  (нулевая гипотеза об отсутствии корреляции) статистика  $Q$ -теста асимптотически имеет распределение  $\chi^2$ . Значения  $p$  выше 0,05 указывают на принятие нулевой гипотезы о точности модели при уровне значимости 95%. Рекомендуется применение  $Q$ -теста совместно с графиками АКФ и ЧАКФ [43].

Эффективного результата в построении моделей с ARCH-GARCH-процессами в остатках можно достичь путем проверки остатков на нормальное распределение [44]. Наиболее известный тест для проверки гипотезы о нормальном распределении остатков – статистический тест Харке-Бера (Jarque-Bera test). [45]. Однако, тест Харке-Бера ненадежен при  $y_t < 2000$ , поэтому рекомендуется применять тест Шапиро-Уилка.

Для определения порядка параметров при построении модели GARCH ( $s,r$ ) используются автокорреляционная функция и функция частичной автокорреляции остатков модели ARIMA [40]. Важно отметить, что перед построением модели необходимо убедиться в наличии условной гетероскедастичности с помощью теста множителей Лагранжа (ARCH LM-тест) [46]. Согласно [47] временные ряды, проявляющие условную гетероскедастичность (автокорреляцию в квадратном ряду), демонстрируют присутствие ARCH-эффектов (autoregressive conditional heteroscedastic).

Основываясь на исследованиях в [48] для уменьшения числа параметров в подобранной модели целесообразно использовать информационный критерий Шварца. Однако, критерий Акаике при правильной оценке АКФ и ЧАКФ способен повысить точность модели при оптимальном наборе параметров. В рассматриваемой гибридной модели ARIMA/GARCH используется комбинированная процедура подбора оптимальной модели ARIMA( $p,d,q$ ) GARCH( $s,r$ ).

### 3.3 Алгоритм подбора и оценки гибридной модели ARIMA/GARCH

На рисунке 17 представлен алгоритм подбора и оценки гибридной модели ARIMA/GARCH. Таким образом, остатки подобранных моделей ARIMA могут содержать нелинейные данные, а модель GARCH способна смоделировать

структуру таких остатков. Согласно [38], случайные ошибки  $e_t$  модели ARIMA соответствуют процессу GARCH порядков  $r$  и  $s$ .

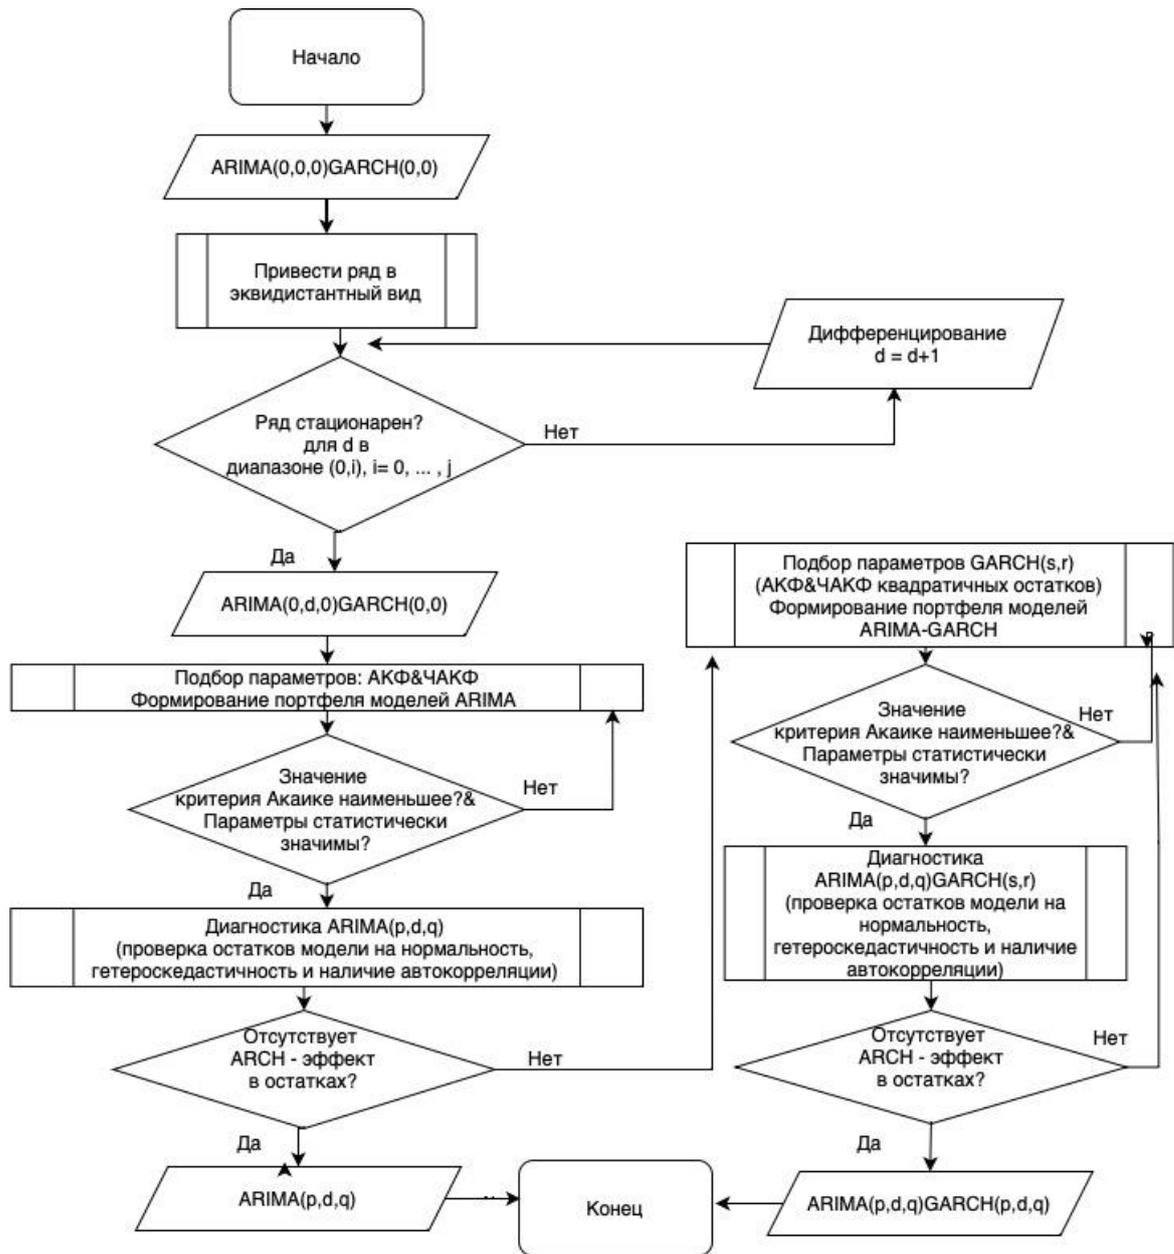


Рисунок 17– Алгоритм подбора гибридной модели ARIMA/GARCH

АКФ и ЧАКФ квадратов стандартизированных остатков для гибридных моделей должны демонстрировать приблизительно нулевое значение, что согласуется с незначительным статистическим значением, определяющим адекватность моделей.

### 3.4 Прогнозирование трафика реального времени с помощью модели ARIMA/GARCH

Для построения гибридной модели  $ARIMA(p,d,q)$   $GARCH(s,r)$  использовались дампы видеотрафика реального времени [49]. Используемые данные из [49] были представлены в формате `csv` и содержали такие характеристики, как идентификационный номер, дата, время, физические адреса устройств отправителя и получателя, тип протокола и длина пакетов. Обработка и визуализация такого массива данных осуществлялась с помощью Python 3.12.1. Для оптимального анализа в исследуемых файлах удалялись все характеристики, кроме времени поступления и длин пакетов. Затем в соответствии с методикой, описанной в [14], имеющиеся данные приводились в эквидистантный вид с различным временем агрегации.

Данные видеотрафика содержали информацию о длине пакетов (байт/с) за период с 11:32:35 до 18:22:52 06.01.2022 и впоследствии были отфильтрованы и приведены в эквидистантный вид с временем агрегации 100 мс.

Выборочная временная последовательность для видеотрафика изображена на рисунке 18, на ее примере далее будет представлена методика подбора параметров модели  $ARIMA(p,d,q)$  и  $GARCH(s,r)$  для остатков модели при наличии соответствующих эффектов условной гетероскедастичности в данных. На рисунке 19 представлен преобразованный ряд с помощью методик дифференцирования и Бокса-Кокса.

Первым шагом идентификации является проверка наличия тренда путем построения выборочного ряда, как показано на рисунке 18, где график демонстрирует наличие тренда во временном ряде. Таким образом, можно предположить о нестационарности ряда как в области средних значений, так и в области дисперсии [39]. Следующим шагом является нормализация наблюдаемого ряда с использованием округленного значения  $\lambda = 5,11$  из преобразования Бокса-Кокса.

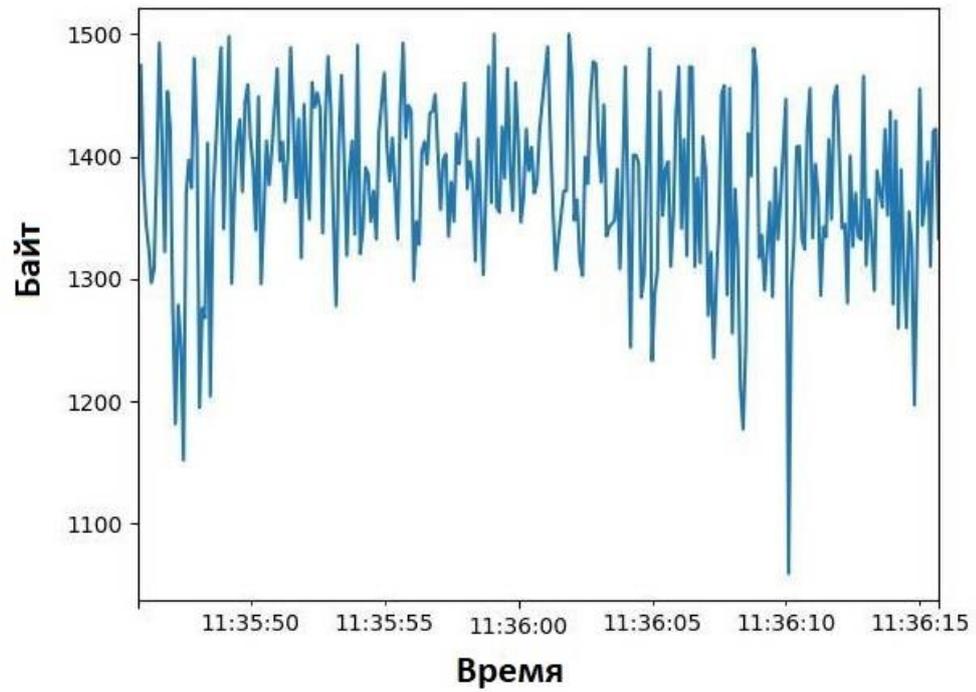


Рисунок 18 –Пример трафика реального времени

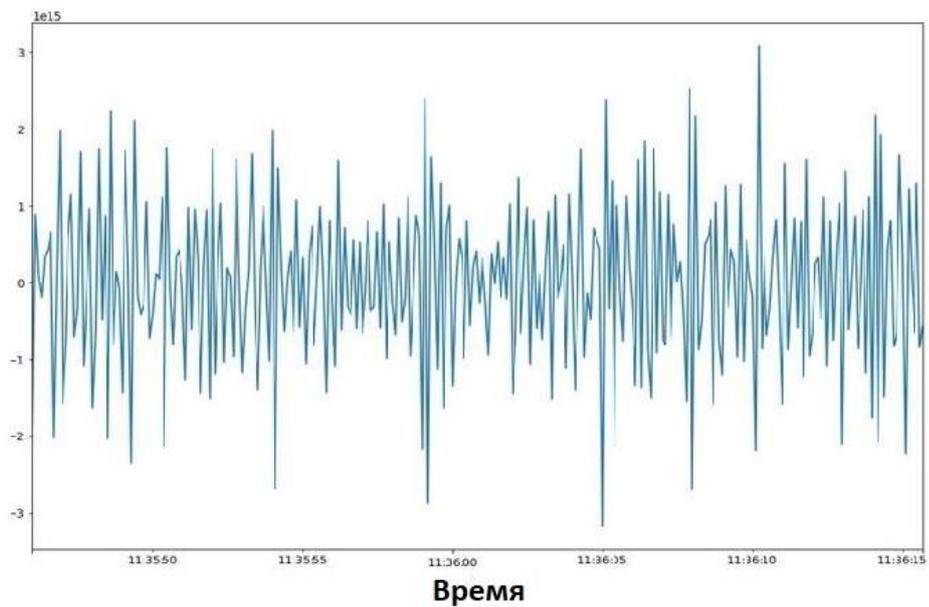


Рисунок 19 –Преобразованный ряд

Затем в соответствии с методикой Бокса-Дженкинса выбранный участок проверялся на стационарность с помощью статистики Дики-Фуллера. В таблице 6 приведены результаты.

Таблица 6 – Результаты расширенного теста Дикки-Фуллера (ADFT-тест)

	<b>ADFT</b>	<b>p-величина</b>
	<b>1%: -3,453261605529366,</b> <b>5%: -2,87162848654246,</b> <b>10%: -2,5721455328896603</b>	
Временной ряд с преобразованием ( $\lambda = 5,16$ )	-0,371	0,915
Временной ряд после последовательного взятия разности ( $d=1$ )	-10,686	3,842e-19

Согласно тесту на единичный корень, значение  $p$ , равное 0,91 в расширенном тесте Дики-Фуллера (ADFT) для ряда, преобразованного с помощью преобразования Бокса-Кокса, противоречит стационарности данных. Таким образом, трансформированный ряд необходимо дифференцировать, чтобы устранить тренд. Полученное значение  $p$ , равное  $6,42e-20$ , указывает на то, что  $t$ -статистика ADF является значимой и ряд является стационарным.

Таким образом, порядок разности  $d$  будет определяться как 1 либо 2, в зависимости от дальнейшей оценки параметров. На данном этапе учитываются значения информационного критерия Акаике (AIC) совместно с байесовским информационным критерием (BIC) при необходимости уменьшить порядок параметров в модели. Важным условием при подборе модели является наличие статистически значимых  $p$ -значений параметров.

Основываясь на корреляционных диаграммах АКФ и ЧАКФ, представленных на рисунках 20 и 21 для дифференцированного ряда, существует множество возможных комбинаций моделей ARIMA.

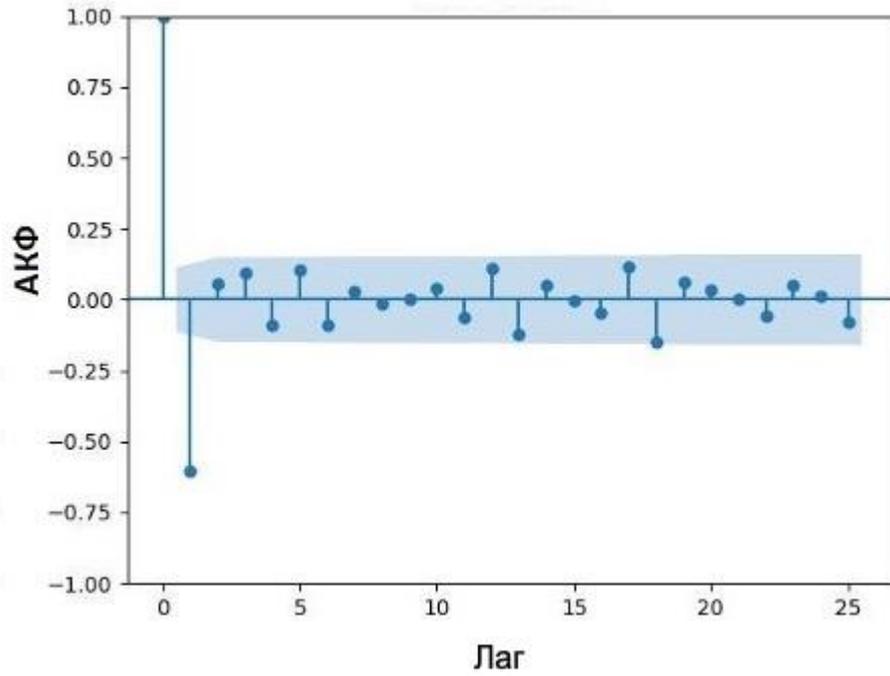


Рисунок 20 – АКФ дифференцированного ряда

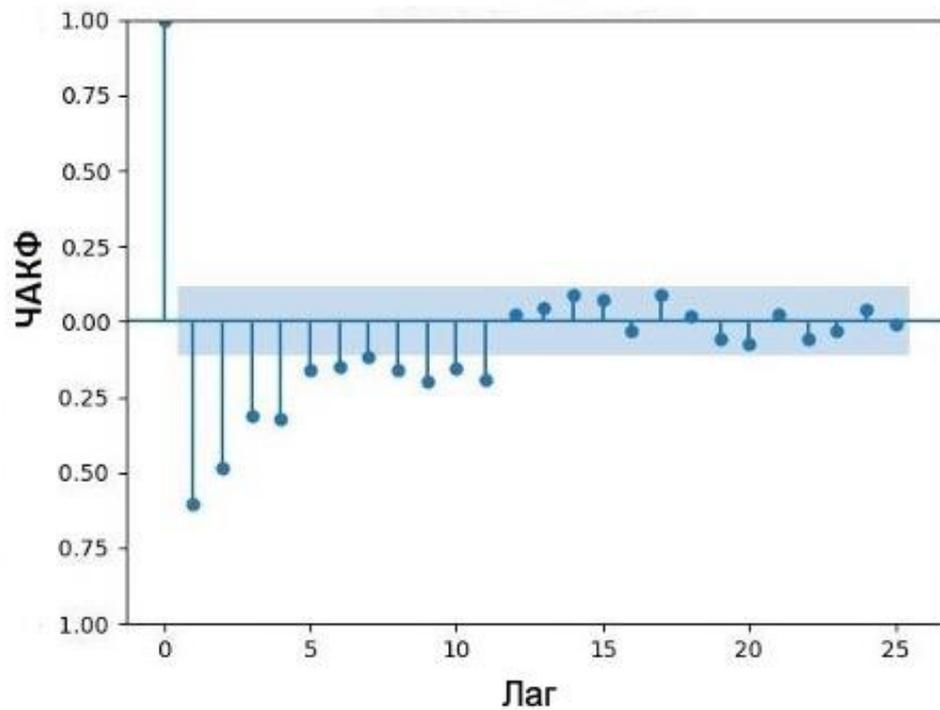


Рисунок 21 – ЧАКФ дифференцированного ряда

С помощью библиотеки Python `statsmodels.tsa.arima.model` и пользовательской функции для поиска моделей с наименьшими значениями AIC

генерируются все возможные варианты  $ARIMA(p,d,q)$  из диапазона заданных порядков параметров. Каждая полученная модель проходит проверку на адекватность посредством анализа ряда остатков этой модели. На рисунках 22 и 23 представлена проверка значимости каждого коэффициента автокорреляции отдельно.

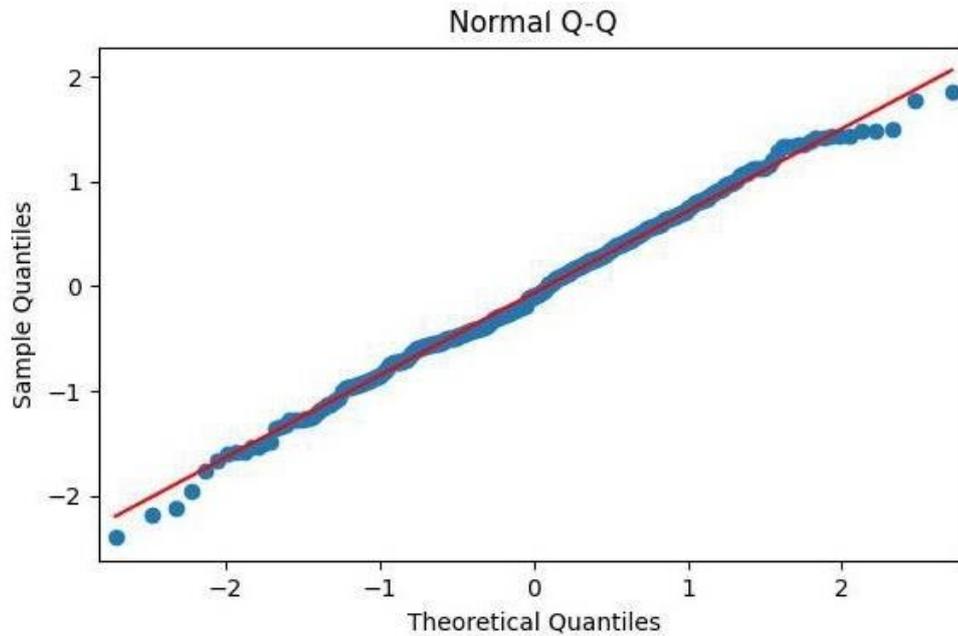


Рисунок 22 – Коэффициенты автокорреляции остатков модели  $ARIMA(1,2,2)$  на нормальной вероятностной бумаге

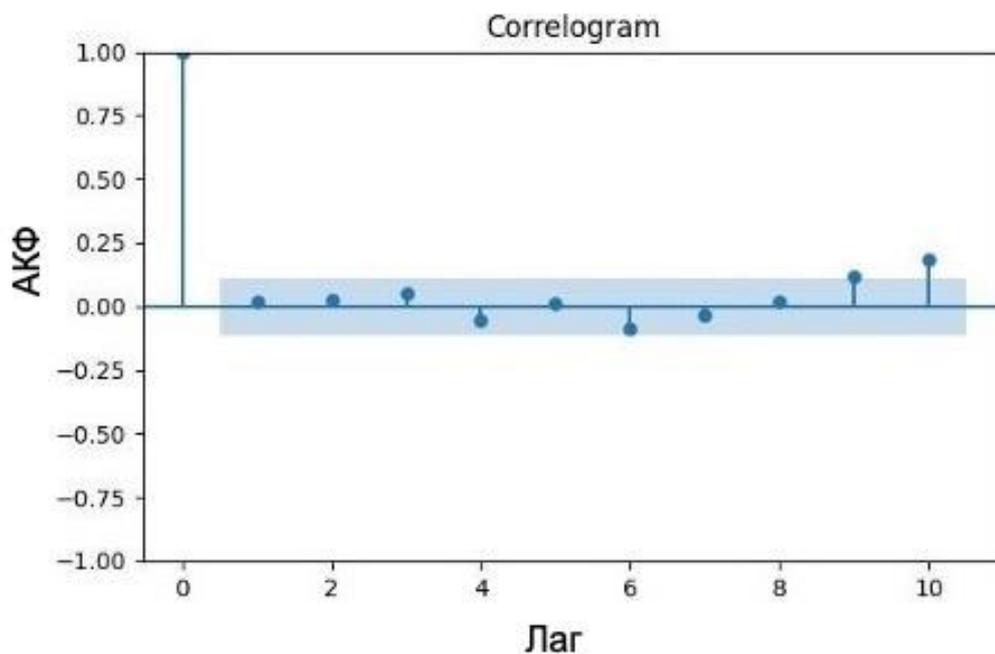


Рисунок 23 – Функция автокорреляции остатков модели  $ARIMA(1,2,2)$

Для модели  $ARIMA(1,2,2)$  распределение коэффициентов автокорреляции практически приближается к нормальному распределению с нулевым математическим ожиданием. Некоторые выборочные коэффициенты автокорреляции выходят за доверительный интервал после восьмого лага, таким образом, нулевая гипотеза о равенстве таких коэффициентов нулю отвергается.

В таблице 7 приведены результаты проверки значимости множества коэффициентов автокорреляции как группы на основе Q-статистики Льюнга-Бокса.

Основываясь на полученных результатах, Q-статистика Льюнга-Бокса для модели  $ARIMA(1,2,2)$  подтверждает нулевую гипотезу о независимости коэффициентов автокорреляции вплоть до 10-го лага, а модель  $ARIMA(0,1,2)$  вплоть до девятого лага. Нормальность распределения остатков двух моделей опровергается тестом Шапиро-Уилка.

Важно отметить, что ненормальность остатков предполагает оптимизацию модели  $ARIMA$  в области подбора параметров, но в рамках исследования GARCH моделей остатки первой модели могут иметь ненормальное распределение [40]. Тест ARCH-LM подтверждает слабую корреляцию квадратичных остатков модели  $ARIMA$  и вплоть до пятого лага отвергает гипотезу отсутствия ARCH-эффектов.

Таблица 7 – Диагностика остатков модели ARIMA

	ARIMA (0,1,2)		ARIMA (1,2,2)	
	Статистика	р-значение	Статистика	р-значение
Тест Льюнга-Бокса остатков до второго (2), пятого (5) и 10-го лага (10)	(2) 0,299 (5) 3,771 (10) 20,215	(2) 0,861 (5) 0,583 (10) 0,027	(2) 0,853 (5) 1,618 (10) 5,254	(2) 0,504 (5) 0,630 (10) 0,530
Тест Льюнга-Бокса квадратичных остатков для остатков до второго (2), пятого (5) и 10-го лага (10)	(2) 11,380 (5) 11,723 (10) 21,021	(2) 0,003 (5) 0,039 (10) 0,021	(2) 36,511 (5) 53,834 (10) 68,269	(2) 1,179e-08 (5) 2,267e-10 (10) 9,560e-11
Тест Шапиро-Уилка	0,989	0,020	0,989	0,028
ARCH-LM тест остатков (р-значение) для остатков второго (2), пятого (5) и 10-го лага (10)	(2) 1,0 (5) 1,0 (10) 1,0		(2) 1,0 (5) 1,0 (10) 1,0	
Тест Лангранжа для квадратичных остатков (р-значение) для остатков до второго (2), пятого (5) и 10-го лага (10)	(2) 1,0 (5) 1,0 (10) 1,0		(2) 1,354e-31 (5) 0,791 (10) 0,057	
AIC	21108,889		21090,086	

Для подбора параметров  $s$  и  $r$  для модели GARCH( $s,r$ ) была рассмотрена ЧАКФ квадратичных остатков (рисунок 24).

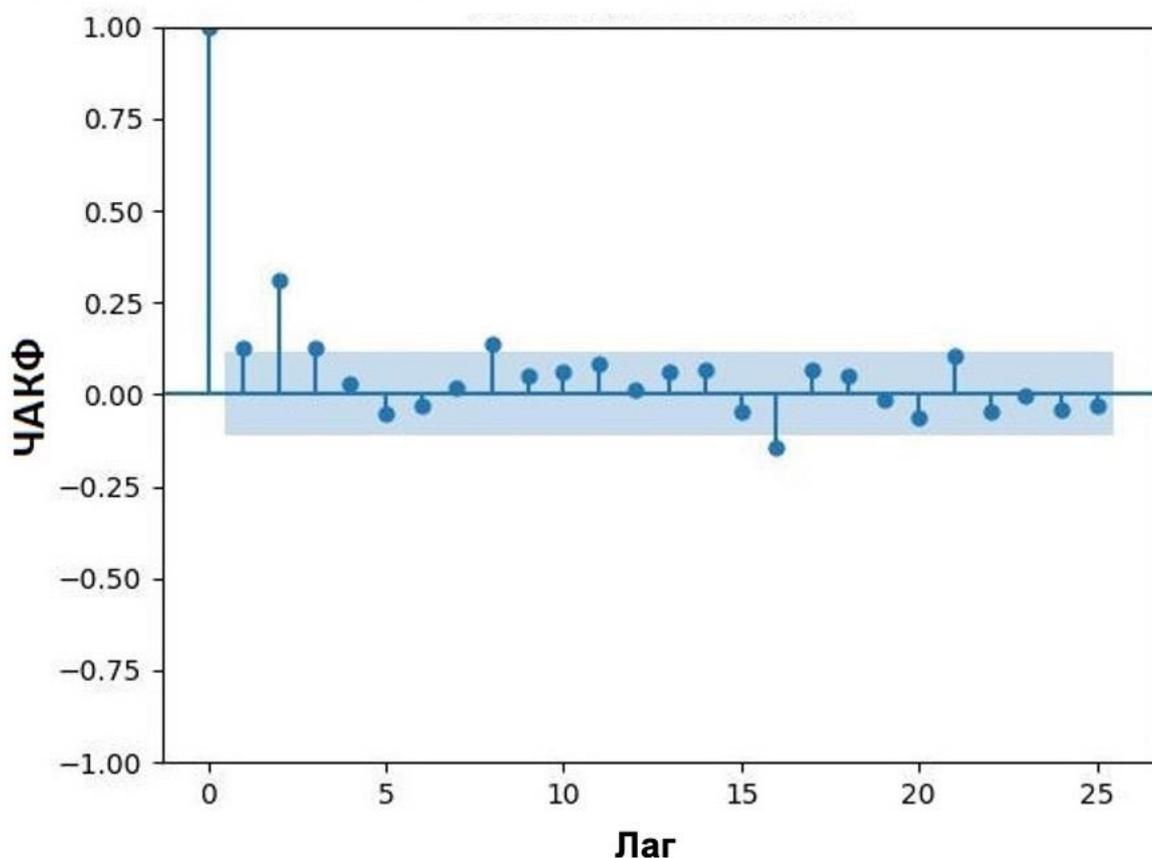


Рисунок 24 – ЧАКФ квадратичных остатков модели ARIMA(2,2,5)

На рисунке 24 заметны значительные выбросы на определенных лагах, что является подтверждением присутствия ARCH-эффектов и демонстрирует второй лаг наиболее весовым. Таким образом, на адекватность проверялись модели с параметрами  $s=0; 1; \text{ и } 2$  и  $r=0;1; \text{ и } 2$  и на основе информационного критерия AIC были предложены для следующей диагностической проверки модели ARIMA(1,2,2)– GARCH(1,0) и ARIMA(1,2,2)–GARCH(1,0).

В таблице 8 приведена диагностика остатков моделей с наименьшим AIC. Диагностическая проверка проводилась вновь для оценки адекватности рассматриваемых моделей. На остатках моделей оценивались результаты теста Q-статистики Льюнга-Бокса, теста на гетероскедастичность и на анализ нормальности. Тест на нормальность стандартизированных остатков модели с параметрами GARCH(1,0) отвергает гипотезу о нормальном распределении.

Таблица 8 – Диагностика остатков модели ARIMA–GARCH

	ARIMA(1,2,2)– GARCH(1,0)		ARIMA(1,2,2)– GARCH(2,0)	
	Статистика	p-значение	Статистика	p-значение
Тест Льюнга-Бокса остатков до второго (2), пятого (5) и 10-го лага (10)	(2) 0,421 (5) 1,526 (10) 5,434	(2) 0,743 (5) 0,710 (10) 0,535	(2) 0,175 (5) 1,099 (10) 5,030	(2) 0,896 (5) 0,837 (10) 0,632
Тест Льюнга-Бокса квадратичных остатков для остатков до второго (2), пятого (5) и 10-го лага (10)	(2) 9,175 (5) 12,299 (10) 14,493	(2) 0,021 (5) 0,012 (10) 0,023	(2) 2,910 (5) 4,876 (10) 7,911	(2) 0,160 (5) 0,179 (10) 0,193
Тест Шапиро-Уилка	0,985	0,005	0,995	0,5
ARCH-LM тест остатков (p-значение) для остатков второго (2), пятого (5) и 10-го лага (10)	(2) 0,002 (5) 0,076 (10) 0,101			(2) 0,115 (5) 0,119 (10) 0,129
Тест Лангранжа для квадратичных остатков (p-значение) для остатков до второго (2), пятого (5) и 10-го лага (10)	(2) 0,226 (5) 0,415 (10) 0,704			(2) 0,734 (5) 0,556 (10) 0,496

Также обращая внимание на Q-статистику Льюнга-Бокса важно отметить, что в данной модели нет квадратичных остатков, которые выглядят как белый шум. Таким образом, модель  $ARIMA(1,2,2)-GARCH(1,0)$  не сможет удовлетворительно смоделировать условную дисперсию.

АКФ и ЧАКФ квадратов стандартизированных остатков для гибридной модели  $ARIMA(1,2,2)-GARCH(2,0)$  демонстрируют близкие к нулю значения (рисунки 25 и 26), что согласуется с Q-статистикой Льюнга-Бокса. Предположение о нормальности стандартизированных остатков для модели удовлетворяется тестом Шапиро-Уилка. Между тем тест ARCH-LM остатков модели показывает, что условная гетероскедастичность больше не присутствует во временном ряде.

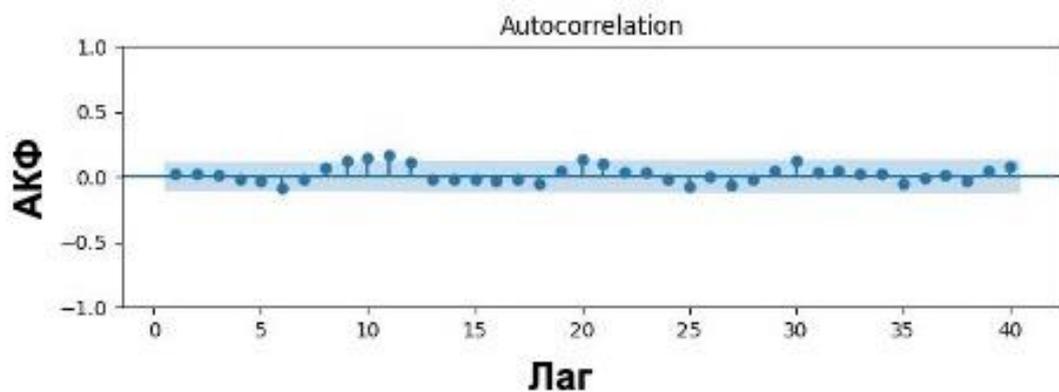


Рисунок 25 – Функция АКФ остатков модели  $ARIMA(1,2,2)-GARCH(2,0)$

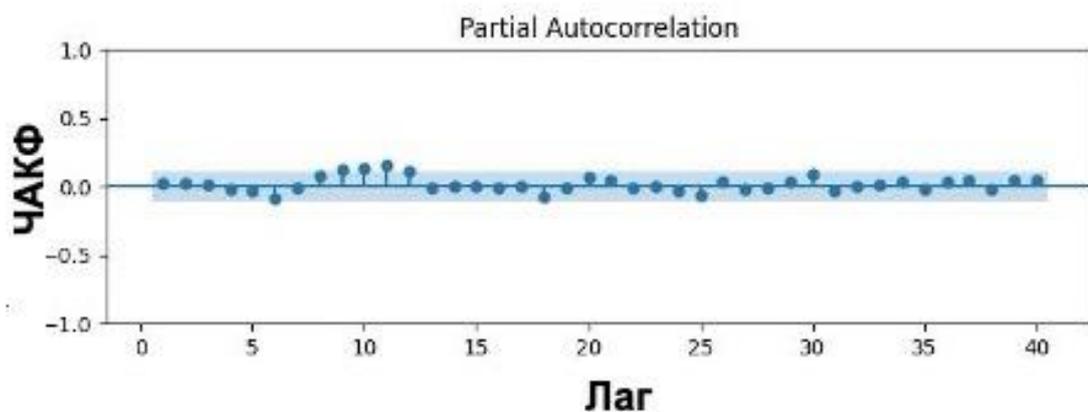


Рисунок 26 – Функция ЧАКФ остатков модели  $ARIMA(1,2,2)-GARCH(2,0)$

На рисунке 27 представлен прогноз будущих значений для всех исследуемых до этого моделей. Он демонстрирует, насколько схожи прогнозируемые значения трафика реального времени и предложенных моделей. Можно отметить, что модели ARIMA дают достаточно хороший прогноз, но ни одна из представленных моделей не способна уловить резкий подъем данных на шестом шаге. Однако именно модель ARIMA(2,2,5)–GARCH способна предсказать характерные всплески трафика, что продемонстрировано на графике. Причем визуально можно наблюдать прогноз модели для данного шага с небольшим отставанием от реальных значений.

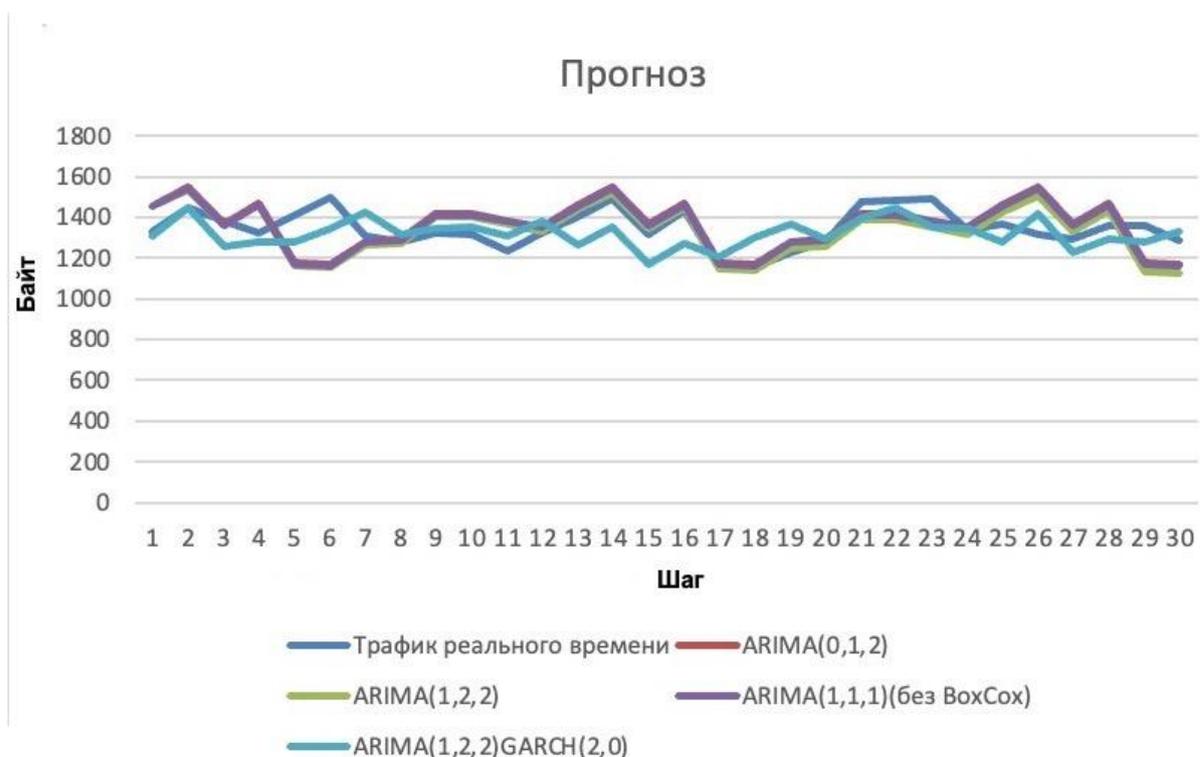


Рисунок 27 – Прогноз моделей ARIMA и гибридной модели ARIMA/GARCH

Для оценки точности прогноза используется средняя абсолютная процентная ошибка (mean absolute percentage error, MAPE) как в формуле (6). Далее на рисунке 28 приведены результаты усредненных оценок, характеризующие качество прогнозной оценки MAPE [50].

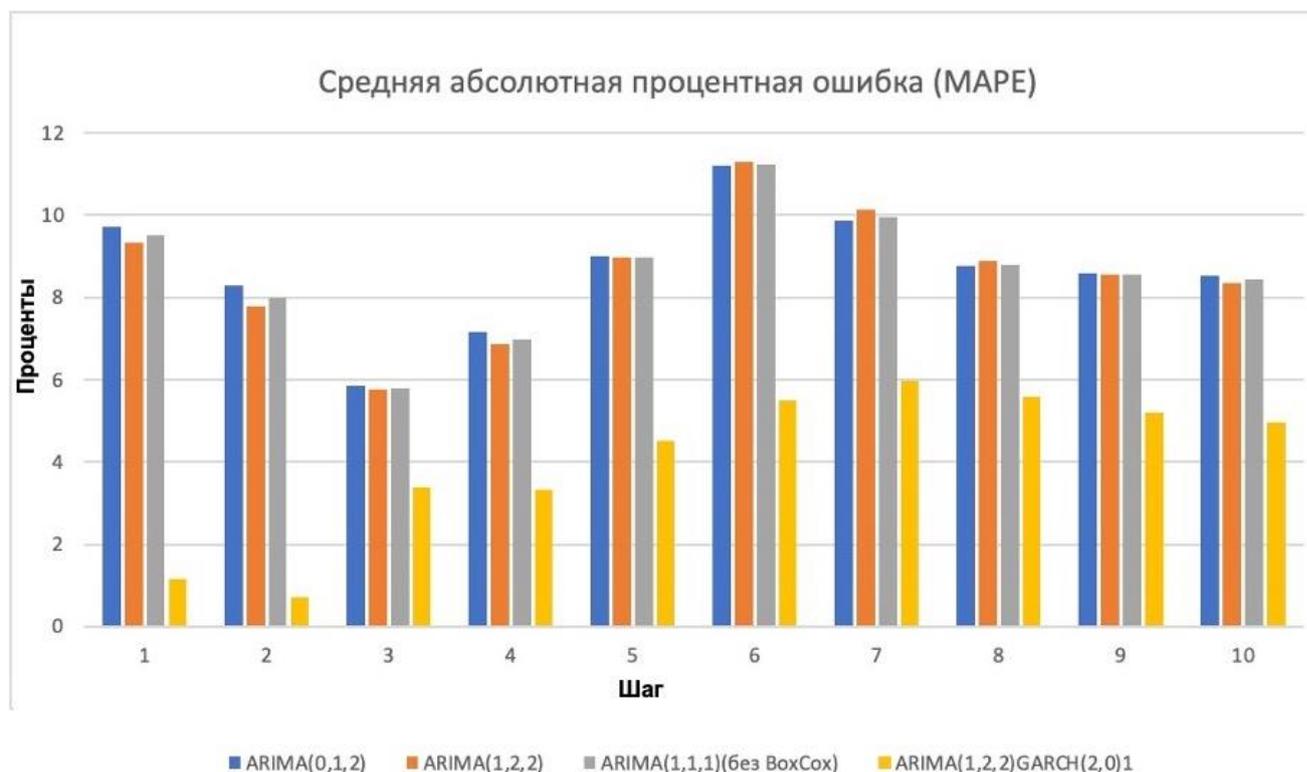


Рисунок 28 – Результаты прогнозной оценки MAPE

Из рисунка 28 видно, что оценка MAPE модели ARIMA(2,2,5)–GARCH(2,0) минимальна и находится между 0% и 10%, что соответствует качественному прогнозу. Поэтому данная модель лучше всего подходит для прогнозирования значений трафика реального времени на несколько шагов вперед.

### 3.5 Выводы по главе

По содержанию главы можно сделать следующие выводы:

1. Данное исследование подтверждает наличие во временных рядах сетевого трафика реального времени эффектов авторегрессионной условной гетероскедастичности.

2. Проведен анализ гибридных моделей авторегрессии и проинтегрированного скользящего среднего ARIMA с обобщенной условной гетероскедастичностью GARCH.

3. Основная цель внедрения и предложения модели ARIMA в специализированной литературе — возможность прогнозирования. Не смотря на достоинства такой модели, была выявлена невозможность ARIMA качественно уловить специфичные характеристики сетевого трафика, как “всплески”. Внедрение модели GARCH обусловлено наличием у последней изменяющейся во времени дисперсии, в отличие от ARIMA с достаточно постоянной дисперсионной составляющей.

4. Модель авторегрессии проинтегрированного скользящего среднего ARIMA и модель с авторегрессионной условной гетероскедастичностью GARCH являются нелинейными моделями временных рядов, которые совмещают линейную модель ARIMA с условной дисперсией модели GARCH. Таким образом, в рамках самоподобного процесса приемлемо использовать не только модели ARIMA, но и существующие алгоритмы моделей GARCH ввиду того, что при усреднении по шкале времени у самоподобного процесса сохраняется склонность к всплескам.

5. Разработан алгоритм для прогнозирования трафика реального времени в гетерогенных сетях пятого и последующих поколений на основе гибридной модели авторегрессии и проинтегрированного скользящего среднего (ARIMA) и обобщенной условной гетероскедастичностью GARCH с преобразованием Бокса-Кокса для краткосрочного прогноза на языке программирования python.

6. Эмпирические результаты серии данных показывают, что гибридная модель ARIMA(1,2,2)–GARCH(2,0) обеспечивает оптимальные результаты в рамках предсказания будущих значений и эффективно повышает точность оценки прогнозирования трафика реального времени по сравнению с другими моделями.

7. Преобразование Бокса-Кокса не повлияло на качество прогноза при сравнении моделей ARIMA, но позволило оптимизировать параметры. Однако, преобразование Бокса-Кокса совместно с гибридной моделью ARIMA–GARCH

позволило улучшить прогноз на 8,5% при прогнозе на один шаг вперед и на 7,6% при прогнозе на два шага вперед.

## **ГЛАВА 4 ПРОГНОЗИРОВАНИЕ ТРАФИКА ТРЕХМЕРНОЙ СЕТИ ИНТЕРНЕТА ВЕЩЕЙ ВЫСОКОЙ ПЛОТНОСТИ КАК МНОГОМЕРНОГО СЛУЧАЙНОГО ПРОЦЕССА**

### **4.1 Модель трафика**

Исследования [51] подтверждают необходимость разработки новых подходов и моделей не только в области прогнозирования, но и моделирования в рамках сетей связи пятого и последующих поколений.

Для сетей пятого поколения актуальна более высокая скорость передачи данных по сравнению с предыдущими поколениями мобильной связи, что позволяет подключать больше устройств к сети одновременно [52].

В работе [53] так же упоминается концепция эластичного управления ресурсами (технология беспроводных сетей шестого поколения), позволяющей быстро и гибко адаптироваться к изменяющимся условиям сети. Для обеспечения требуемого качества обслуживания пользователей применяется нарезка сети путем выделения ресурсов для различных видов трафика в зависимости от их требований к задержке передачи данных.

Развитие сетей беспроводной связи и беспроводного доступа приводит к высокой концентрации узлов сети в пространстве. Например, в многоквартирных зданиях в зоне связи каждого из узлов сети может оказаться до нескольких десятков аналогичных узлов [54]. Таким образом, в подобных сетях создаются условия взаимного влияния между элементами сети. Потоки трафика, производимого пользователями этих узлов, оказываются зависимыми. Степень этой зависимости определяется различными факторами, одним из которых является расстояние между узлами сети. В трехмерной сети наибольшее влияние оказывают ближайшие соседние узлы [55].

При построении сети с использованием принципов SDN [56], в целях управления потоками трафика и ресурсами сети необходимо получение прогнозируемых значений трафика. Для этого используются различные методы, основанные на анализе статистики [57]. В большинстве случаев, эти методы предполагают рассмотрение потоков, производимых отдельными узлами сети, как независимых случайных процессов [58]. Широко распространенными методами прогнозирования является использование инструментов статистического анализа, например, ARIMA [59], а также применение искусственных нейронных сетей (ИНС). Широкое распространение в задачах прогнозирования получили модели ИНС типа LSTM, которые показали хорошие результаты в решении подобных задач [5], благодаря их «способности запоминать» характерные особенности случайных процессов.

Применение ИНС типа LSTM для прогнозирования многомерного случайного процесса, описывающего трафик в трехмерной сети высокой плотности, может дать лучшие результаты, чем прогнозирование отдельных потоков трафика, как независимых случайных процессов, за счет учета взаимных влияний между различными потоками трафика. Эти результаты можно оценить по уменьшению ошибки получаемого прогноза. Уменьшение ошибки прогноза отражается на эффективности функционирования сети, а именно эффективности распределения трафика и ресурсов. Поэтому его можно рассматривать как способ повышения эффективности функционирования сети в целом.

Трафик в сетях, построенных с использованием беспроводной связи, создается пользователями, которые случайным образом распределены в зоне обслуживания. В зависимости от способа построения сети трафик данных передается между пользовательскими терминалами и базовой станцией или точкой доступа, или непосредственно между терминалами пользователей. При этом в каждой точке пространства имеют место сигналы всех узлов сети (базовых станций и терминалов), которые имеют различный уровень мощности. Одни из них могут быть приняты приемными устройствами, а другие имеют слишком малый уровень мощности и

воспринимаются как дополнительный источник помех (шума) или вообще могут быть проигнорированы, если их уровень мощности пренебрежимо мал.

Таким образом, если рассматривать некоторое пространство, обслуживаемое сетью связи, то в каждой точке пространства можно наблюдать потоки трафика между элементами сети. Выбор точки наблюдения определяется целью задачи. Если рассматриваемая сеть построена с использованием точек доступа (базовых станций), то особую роль играют именно точки их размещения, т. к. в такой сети имеют место только потоки трафика между пользователями и точками доступа.

В трехмерной сети точки доступа распределены в пространстве, например, как это показано на рисунке 29.

Трафик в такой сети — это трафик, производимый пользователями, подключенными к ее точкам доступа. В каждой из этих точек трафик представляет собой случайный поток пакетов (кадров, пакетов или сегментов, в зависимости от уровня рассмотрения, для общности будем называть пакетами). В общем случае эти потоки зависимы, так как передаваемые сигналы влияют на процесс передачи в соседних узлах, если используется один частотный канал.

Если две точки доступа оказываются в зоне связи друг друга, то они вынуждены распределять время своей активности, так чтобы интервалы их активности не совпадали и не перекрывались. Это приводит возникновению зависимостей между потоками трафика в таких точках доступа. Аналогичная задача решается и когда точек доступа больше, чем две. В рассматриваемой модели их может быть гораздо больше. Для примера, в сетях семейства стандартов IEEE 802.11 [60] в многоквартирном жилом здании, количество точек доступа, сигнал от которых принимается с достаточно высоким уровнем мощности, может исчисляться несколькими десятками.

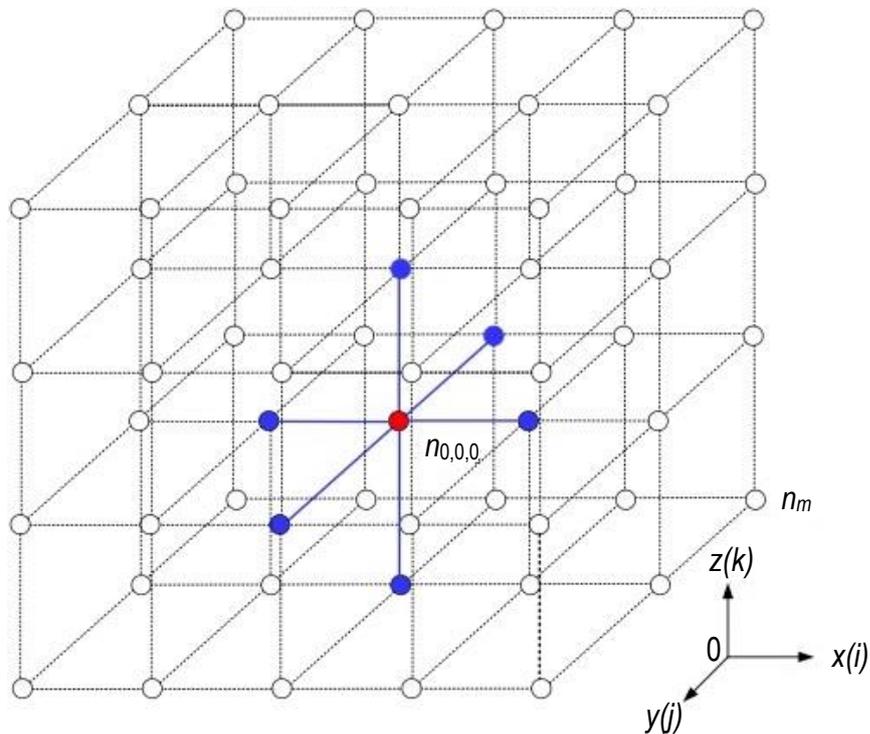


Рисунок 29 – Пример размещения точек доступа сети в пространстве

Поэтому трафик в трехмерной сети высокой плотности можно рассматривать как многомерный случайный процесс [61] в виде:

$$X^{(k)} = \{X_1(t), \dots, X_k(t)\}, \quad (13)$$

описываемый совместными функциями распределения:

$$F^{(k)} = \{F_1(x_1, x_2 \dots x_k, t), \dots, F_k(x_1, x_2 \dots x_k, t)\}, \quad (14)$$

где  $X_1(t), \dots, X_k(t)$  – случайные процессы в выбранных точках (точках доступа) сети, которые представляют собой количество данных (пакетов), переданных за заданный интервал времени (лаг, *от англ. Lag*, запаздывание).

В случае независимости  $X_1(t), \dots, X_k(t)$  каждый из процессов может быть описан своей функцией распределения, например, распределением Пуассона. Однако, в общем случае эти процессы зависимы. Практически, эта зависимость тем выше, чем ближе рассматриваемые точки. Иными словами, в конкретной точке сети трафик в наибольшей степени зависим от трафика ближайших соседей (точек

доступа) и в меньшей степени – от удаленных. Таким образом, общая картина трафика в сети может быть описана многомерным процессом (13) и его функциями распределения (14).

При построении SDN для управления потоками трафика требуется информация о трафике и его прогнозируемых значениях. Для решения данной задачи предлагается использование ИНС типа LSTM. Применение ИНС для прогнозирования множества зависимых случайных процессов позволяет учесть, как влияние времени, так и взаимные влияния этих процессов друг на друга. Таким образом, использование иных методов для решения задачи прогнозирования многомерного процесса либо не эффективно, либо слишком сложно [65]. Традиционные методы прогнозирования с использованием ARIMA, SARIMA и подобные, позволяют получать удовлетворительные прогнозы по отношению лишь к фактору времени, при наличии же взаимной зависимости процессов прогноз оказывается менее эффективным.

Процесс прогнозирования трафика в 3D сети высокой плотности можно описать последовательностью обработки трафика, как показано на рисунке 30.

Такая последовательность состоит из двух непрерывно повторяющихся фаз: фазы сбора статических данных (результатом которой является выборка значений  $D_T$ ) и фазы прогнозирования (результатом которого является выборка значений  $D_F$ ).

Качество функционирования такой системы определяется достоверностью получаемых прогнозов.

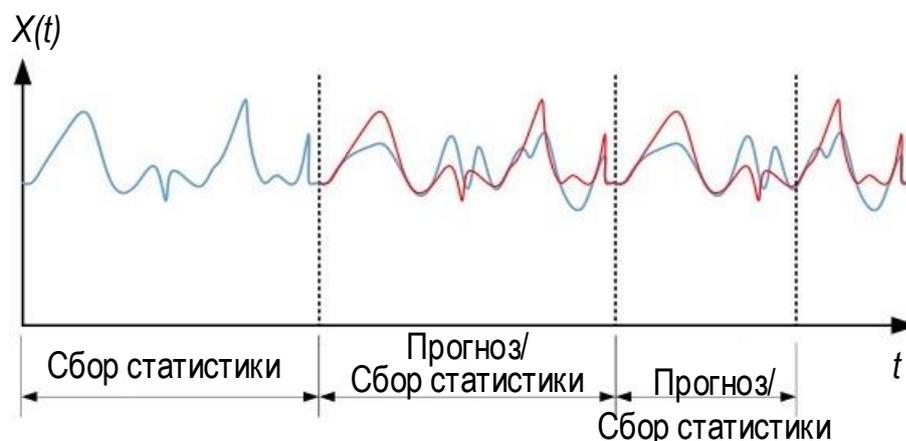


Рисунок 30 – Сбор статистики и прогнозирование

Для оценки эффективности полученного прогноза чаще всего применяется средняя разница между значениями, спрогнозированными моделью, и фактическими значениями трафика – корень средней квадратичной ошибки (*RMSE*) [66]:

$$RMSE_i = \sqrt{\frac{1}{n} \sum_{j=1}^n (x_j^{(i)} - \hat{x}_j^{(i)})^2}, \quad (15)$$

где  $x_i$  – значение процесса на  $i$ -м отсчете интервала прогнозирования из выборки статистики.  $D_T^{(i)} = \{x_1^{(i)} \dots x_n^{(i)}\}$ ,  $x_1^{(i)} \dots x_n^{(i)} \in X_i(t)$ ,  $i = 1 \dots k$ ,  $t \in T$ ,  $\hat{x}_j^{(i)}$  – прогнозируемое значение на  $i$ -м отсчете интервала прогнозирования из данных прогноза  $D_F^{(i)} = \{\hat{x}_1^{(i)} \dots \hat{x}_n^{(i)}\}$ ,  $n$  – количество отсчетов.  $D_T^{(i)}$  – выборка значений одного из случайных процессов  $X_1(t), \dots, X_k(t)$ , а  $D_F^{(i)}$  – его прогнозируемые значения.

Наряду с *RMSE* могут использоваться и другие оценки, такие как среднеквадратичная ошибка *MSE* (аббр. от англ. *Mean Square Error*), средняя абсолютная ошибка *MAE* (аббр. от англ. *Mean Absolute Error*), коэффициент детерминации *R-квадрат* (*squared Coefficient of determination*). Все эти оценки характеризуют разницу между прогнозируемыми значениями и фактической реализацией процесса, а также между данными обучения и выходными значениями ИНС. Использование различных оценок несколько отражается на получаемом результате и их выбор является отдельной задачей. В данной работе используется наиболее распространенная оценка *RMSE*. Хотя, следует отметить, что обсуждаемый подход к прогнозированию не зависит принципиально от выбранной оценки.

Оценка *RMSE* (или любая иная оценка из упомянутых выше) зависит от множества факторов, к которым можно отнести: свойства случайного (прогнозируемого) процесса, продолжительность интервала прогнозирования, количество отсчетов на интервале прогнозирования, продолжительность интервала (интервалов) сбора статистики и количество отсчетов на нем.

## 4.2 Масштаб времени

Выбор продолжительности интервала прогнозирования  $T_F$  и единичных интервалов (лагов) существенно влияет на результаты прогнозирования. Величина единичных интервалов времени влияет на оценку свойств потока (процесса).

В частности, влияние величины единичных интервалов на свойства случайного процесса характеризуется степенью самоподобия [67]. Чем выше степень самоподобия, тем меньше это влияние.

Рассмотрим выбор величины единичного интервала с различных позиций.

Во-первых, с точки зрения выбора величины минимального и максимального интервала. А во-вторых, с точки зрения требований со стороны системы управления трафиком.

*Минимальная величина.* Величина единичного интервала определяет детальность представления трафика. Чем меньше эта величина, тем детальнее будет представлен процесс поступления заявок (пакетов, кадров или сегментов). Если устремить эту величину к нулю, то количество пакетов, поступивших за интервал, не превысит единицы (если принимать во внимание момент начала приема/передачи пакета), так как в линии связи пакеты передаются последовательно, а время передачи самого короткого пакета превышает продолжительность этого интервала. В таком случае случайный процесс будет представлен последовательностью нулей и единиц. Причем в реальном трафике нулей будет гораздо больше, чем единиц. Таким образом, минимальная величина интервала – это величина, не превышающая время передачи самого короткого пакета:

$$u_{\min} \leq \min\left(\frac{L_{\min}}{b}\right), \quad (16)$$

где  $L_{\min}$  – минимальный размер пакета (бит),  $b$  – скорость передачи данных (бит/с).

*Максимальная величина.* Максимальная величина единичного интервала ограничена продолжительностью наблюдений и требованиями к объёму статистического материала. Поскольку для решения задачи прогнозирования требуется набор статистических данных (обучающая выборка), то это требование можно интерпретировать как требование к максимальной величине единичного интервала:

$$u_{\max} = \frac{T_t}{n_t}, \quad (17)$$

где  $n_t$  – количество значений в обучающей выборке,  $T_t$  – продолжительность наблюдений (продолжительность получения обучающей выборки, сбора статистики).

Интервал получения обучающей выборки  $T_t$  – должен быть репрезентативен с точки зрения решаемой задачи.

*Репрезентативность процесса* обеспечивается достаточной детализацией процесса изменения трафика.

Если дискретный процесс  $X(t)$  является представлением некоего непрерывного процесса, то для полного сохранения информации, согласно теореме В.А. Котельникова, величину, обратную единичному интервалу  $1/u$  необходимо интерпретировать как удвоенную верхнюю частоту спектра непрерывного процесса. В этом смысле, величина единичного интервала не должна ограничивать верхнюю частоту спектра непрерывного процесса, а, следовательно, и его информативность.

Количество данных  $x_u$ , переданных, за интервал  $u$  случайно и зависит от средней интенсивности трафика. Среднее количество данных будет определяться как:

$$\bar{x}_u = u\bar{a}_u. \quad (18)$$

Очевидно, что значения этой величины могут лежать в пределах от нуля до величины скорости передачи данных в линии связи  $b$ :

$$0 < x_u \leq b, \quad (19)$$

где  $b$  – скорость передачи данных.

Пусть  $f(x_u)$  – плотность вероятности случайной величины.

Рассматривая эту величину с позиции информативности представления данных, количество информации (бит) в случайном процессе можно определить, как:

$$h_x = \int_{-\infty}^{\infty} f(x) \log_2 f(x) dx. \quad (20)$$

Согласно [62], связь с единичным интервалом  $u$  можно установить через коэффициент Херста:

$$m^{1-H} F^{(m)}(x) \doteq F(x), \quad m \in \mathbb{N}, \quad (21)$$

где  $H$  – коэффициент Херста,  $H = 1 - \left(\frac{\beta}{2}\right)$ ; знак  $\doteq$  обозначает равенство распределений;  $F(x)$  – распределение исходного процесса (полученного на интервалах  $u$ );  $F^{(m)}(x)$  – распределение процесса, полученного на  $m$  интервалах  $u$ .

Из (10) видно, что с ростом коэффициента Херста ( $0 < H < 1$ ) распределения вероятностей исходного процесса и процесса, полученного при увеличении интервалов  $u$  в  $m$  раз сближаются.

Из определения самоподобности второго порядка и коэффициента корреляции  $r(k)$  следует, что для  $0 < H < 1$  при  $H \neq 0,5$ :

$$r(k) \sim H(2H - 1)k^{2H-2}, \quad (22)$$

где  $k \rightarrow \infty$ .

Согласно [63], если  $0,5 < H < 1$ ,  $r(k) \sim ck^{-\beta}$ ,  $c > 0$  – константа,  $\beta = 2 - 2H$  и  $0 < \beta < 1$ , тогда коэффициент корреляции медленно затухает, что является основной

причиной несуммируемости и исходный процесс является долговременно зависимым:

$$\sum_{k=-\infty}^{\infty} r(k) = \infty. \quad (23)$$

Для равенства (21) при  $0 < \beta < 1$  исходный процесс является строго самоподобным в широком смысле (ССШС) и имеет медленно убывающую зависимость [68].

*Требования со стороны системы управления трафиком* могут иметь первостепенное значение при выборе величины  $u$ . Функционирование системы управления предполагает сбор статистики (обучение), получение прогнозов, анализ состояния сети и принятие решения по управлению трафиком. Каждый из этих этапов имеет свои характеристики и требует определенных затрат времени. Это проявляется в определенных характеристиках управления. Тогда величина  $u$  должна соответствовать времени реакции системы управления (интервалу управления).

Таким образом, обобщая сказанное, можно сделать вывод, что выбор величины единичного интервала  $u$  (лага) зависит от таких факторов, как параметры канала связи, свойства трафика и характеристики системы управления.

### 4.3 Метод использования искусственных нейронных сетей

При использовании ИНС,  $RMSE$  зависит от объема обучающей выборки  $D_T$ . Отрицательное влияние на прогноз может оказать как недостаточное, так и избыточное обучение, поэтому необходимо определить некоторый размер этой выборки, при котором ошибка минимальна [70].

Выбор параметров прогнозирования можно определить, как задачу оптимизации, целевой функцией (%) в которой является:

$$O = \min_{T_t, m} RMSE(T_t, m), \quad (24)$$

где  $T$  – продолжительность обучающей выборки (размер выборки);  $m$  – количество эпох обучения.

Прогнозирование трафика – это непрерывный процесс, который выполняется в течение всего времени функционирования сети связи. Случайные процессы могут претерпевать как краткосрочные, так и медленные (долговременные) изменения. Для того чтобы учитывать актуальную ситуацию обучение ИНС должно производиться непрерывно с учетом требований к продолжительности периода прогнозирования. Соответствующий алгоритм приведен на рисунке 31.

На этапе инициализации может задаваться начальная обучающая выборка  $D_T$ , продолжительностью  $T_t$ . Если такой выборки нет, то для ее получения проводится сбор статистики и непосредственное формирование этой выборки. Далее начинается циклическое обучение ИНС на основе начальной выборки, которое проводится за несколько эпох (циклов обучения). Критерием завершения обучения является отсутствие уменьшения значения  $RMSE$ . Если после очередной эпохи ошибка не снизилась, то обучение считается оконченным при числе эпох равном  $m$ . Далее ИНС готова выполнить прогноз, что делается на следующем этапе – получение набора прогнозируемых значений  $D_F$ .

Полученный прогноз  $D_F$  может быть использован как результат в целях управления трафиком, а его качество оценивается сравнением с реальными данными, получаемыми в результате сбора статистики о трафике  $D_T$ . На основе которых вычисляется оценка  $RMSE$ . Если полученная оценка свидетельствует о низком качестве прогнозирования, то производится корректировка интервала обучения  $T_t$ .

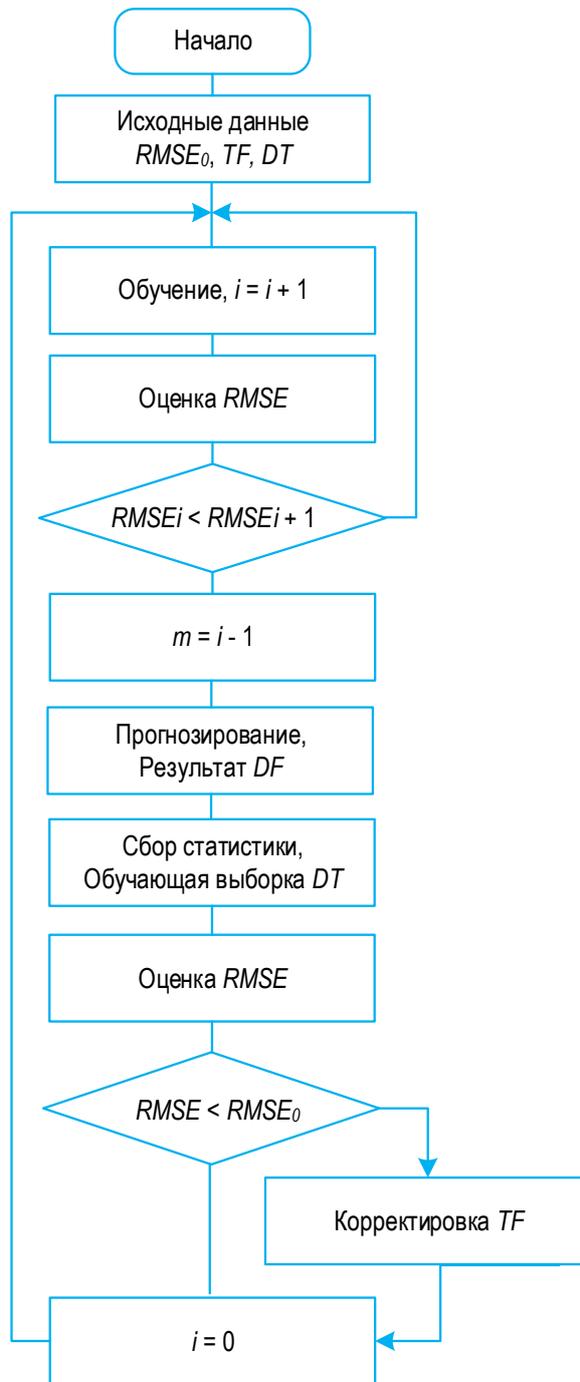


Рисунок 31 – Алгоритм обучения ИНС

На рисунках 32 и 33 приведен пример прогнозирования случайного процесса, представляющего собой общий трафик в двух взаимозависимых точках доступа в пределах одного дня с 22:22:49 до 22:41:13. Процесс представляет собой набор значений числа бит, переданных за интервалы, равные одной секунде.

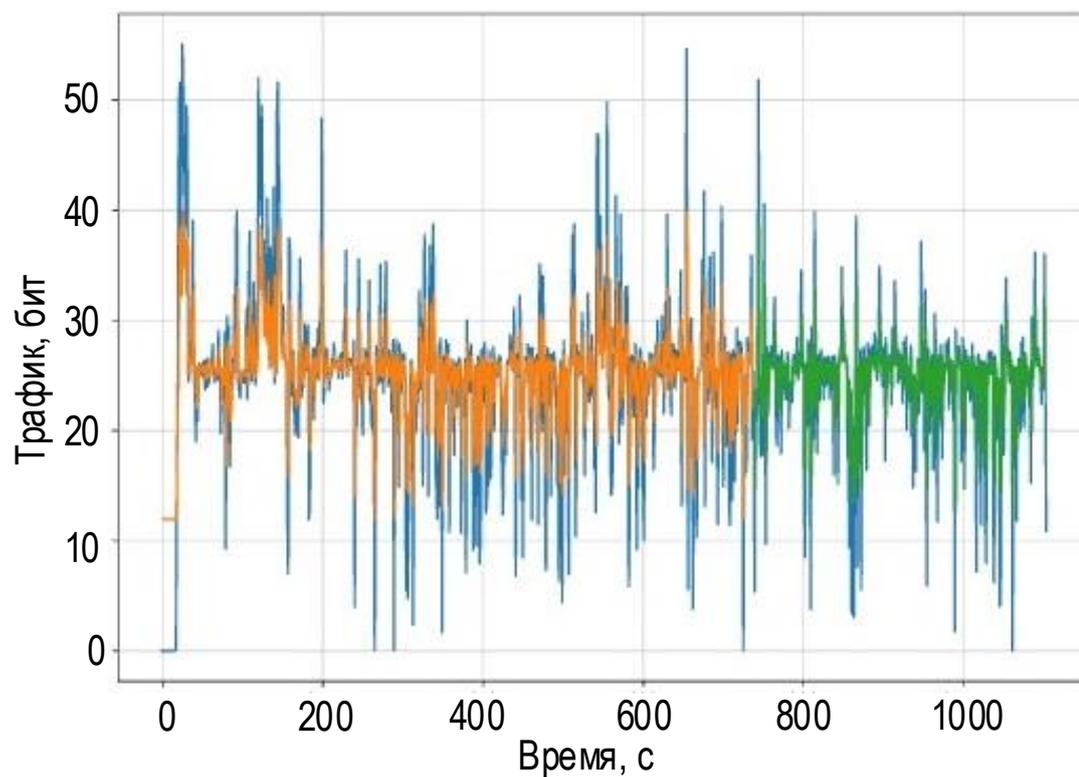


Рисунок 32 – Пример прогнозирования трафика с использованием ИНС типа LSTM: RMSE = 6,28

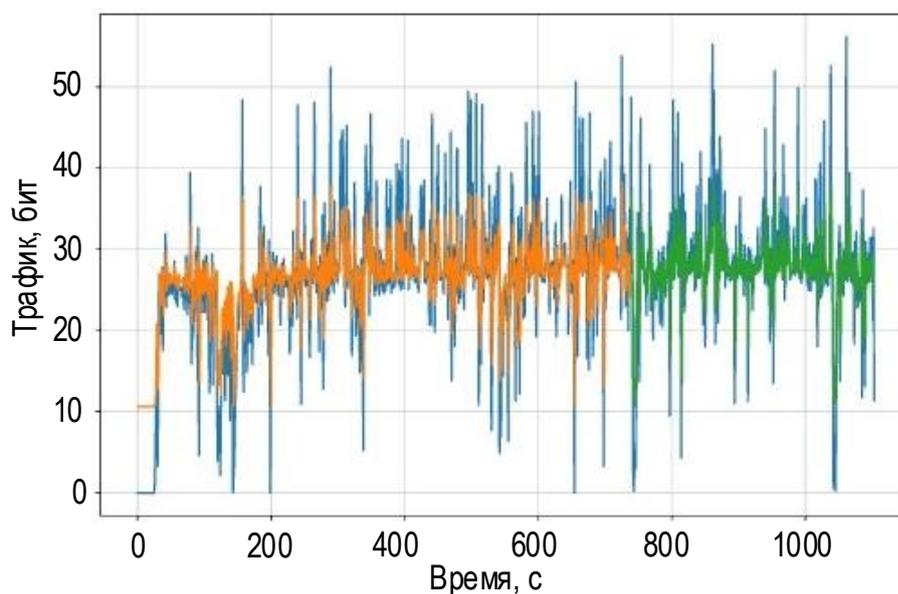


Рисунок 33 – Пример прогнозирования трафика с использованием ИНС типа LSTM: RMSE = 7,29

На приведенных примерах показан двухмерный случайный процесс, включающий в себя два потока трафика (две точки доступа). Синяя линия

представляет полученные в результате измерений данные, оранжевая кривая – аппроксимация исходного процесса ИНС после обучения, зеленая кривая – прогнозируемый процесс на фоне реализации (синяя кривая). Полученные результаты продемонстрировали высокую точность прогнозирования на достаточно продолжительном интервале. Объем тренировочной выборки состоял из 740 наблюдений. Продолжительность интервала прогнозирования составила в данном примере 33 % от общей продолжительности наблюдений в 1104 отсчетов. Ошибка прогнозирования составила для процесса на рисунке 4а:  $RMSE = 6,28$ , а на рисунке 4б:  $RMSE = 7,29$ . Следует отметить, что из графиков визуально заметна достаточно высокая точность прогнозирования. Прогнозируемый процесс повторяет колебания реального процесса, что происходит благодаря тому, что ИНС находит сложную закономерность не заметную на взгляд.

#### 4.4 Эффективность метода

Целью прогнозирования случайного процесса является получение значения случайной величины (последовательности или множества случайных величин), которые будут иметь место в будущем. Качество прогнозирования оценивается метрикой, характеризующей ошибку, т. е. разницу между прогнозируемым значением и фактическим значением в момент, на который выполнен прогноз. Для решения задачи прогнозирования с помощью ИНС необходимо построение соответствующей модели, сбор статистики (получение обучающей выборки), обучение ИНС и выполнение прогноза. При этом расходуются вычислительные ресурсы. В таком случае эффективность прогнозирования можно определить, как снижение ошибки прогнозирования при сохранении объема используемых ресурсов или уменьшение объема используемых ресурсов при сохранении ошибки прогнозирования.

В данном случае будем использовать первый подход, т. е. будем оценивать изменение ошибки прогнозирования при прогнозировании трафика трехмерной сети связи высокой плотности, как многомерного случайного процесса по сравнению с прогнозированием этого же трафика как множества независимых случайных процессов.

Будем оценивать ошибку прогнозирования с помощью  $RMSE$ , вычисляемого согласно (15).

Выражение (25) используется в обоих случаях, т. е. для случая прогнозирования трафика как многомерного случайного процесса при параллельном прогнозировании  $k$  временных рядов, так и для случая прогнозирования трафика как  $k$  независимых временных рядов. Соответствующие ошибки прогнозирования обозначим как  $RMSE_D$  и  $RMSE_I$ . Тогда эффективность прогнозирования трафика трехмерной сети высокой плотности, как многомерного случайного процесса будем оценивать в %, как:

$$E = 100 \frac{RMSE_D - RMSE_I}{RMSE_I}. \quad (25)$$

Значение (25) отражает относительное уменьшение ошибки прогнозирования за счет использования «параллельного» прогнозирования многомерного процесса, по сравнению с прогнозированием независимых случайных процессов. На рисунке 34 приведены результаты оценки эффективности прогнозирования трафика как многомерного процесса.

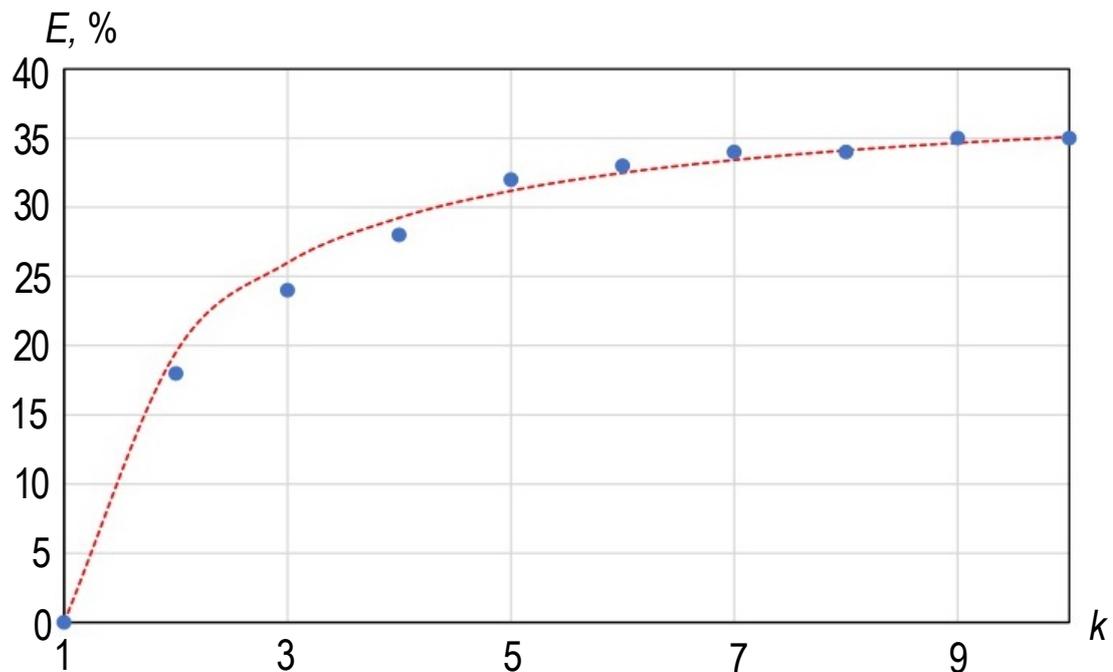


Рисунок 34 – Пример прогнозирования трафика с использованием ИНС типа LSTM: RMSE = 7,29

Из полученного графика видно, что эффективность прогнозирования трафика как многомерного случайного процесса в трехмерной сети связи высокой плотности возрастает с увеличением размерности.

Очевидно, что при  $k=1$  эффективность равна нулю, так как в этом случае процесс является одномерным. При росте размерности  $k$  эффективность метода возрастает, но скорость ее роста снижается. Такая зависимость вполне понятна, так как область взаимных влияний между отдельными потоками трафика в трехмерной сети не бесконечна, как было отмечено выше, она определяется ближайшими соседними узлами [71].

В рассмотренном примере эффективность метода составила 35 % при размерности  $k = 10$ .

#### 4.5 Выводы по главе

По содержанию главы можно сделать следующие выводы:

1. Разработана модель трафика трехмерной сети высокой плотности как многомерного случайного процесса;
2. Разработан метод использования ИНС типа LSTM для прогнозирования трафика в гетерогенных сетях пятого и последующих поколений в трехмерной сети высокой плотности как многомерного случайного процесса для долгосрочного прогноза.
3. Из полученных данных следует, что трафик трехмерной сети высокой плотности в задачах прогнозирования целесообразно рассматривать как многомерный случайный процесс, размерность которого равна количеству узлов сети, производящих трафик. Такой подход позволяет учесть взаимную зависимость потоков трафика, производимых соседними узлами сети.
4. Прогнозирование сетевого трафика как многомерного процесса с помощью ИНС демонстрирует хорошую точность долгосрочного прогноза, в отличие от параметрических моделей типа ARIMA, которые применяются для краткосрочного прогнозирования одномерных процессов.
5. Качество прогнозирования трафика трехмерной сети высокой плотности как многомерного случайного процесса может быть оценено с помощью суммарной среднеквадратической ошибки (*RMSE*), вычисляемой по всем измерениям случайного процесса.
6. Продуктивность использования модели многомерного случайного процесса для описания трафика трехмерной сети высокой плотности может быть оценена относительным изменением суммарной среднеквадратической ошибки.
7. Применение для прогнозирования трафика трехмерной сети высокой плотности модели многомерного случайного процесса, при получении прогноза при помощи ИНС типа LSTM, позволяет повысить эффективность

прогнозирования, согласно приведенному примеру, до 35 % (при размерности  $k = 10$ ).

8. Эффективность прогнозирования предложенным методом зависит от размерности случайного процесса, возрастая с увеличением размерности; скорость увеличения эффективности зависит от характеристик сети связи, а именно – от количества взаимных влияний между узлами сети.

## ЗАКЛЮЧЕНИЕ

По результатам исследований в диссертационной работе были получены следующие основные результаты:

1. Исследована научная литература в области изучения современного трафика. Современная гетерогенная сеть порождает сетевой трафик со сложной (неоднородной) структурой. Рост объемов разнородного трафика в инфокоммуникационных сетях актуализирует вопросы обеспечения качества предоставляемых услуг связи, что в свою очередь требует обращения к моделям прогнозирования.

2. Модели, построенные на основе данных, характеризующего один объект за ряд последовательных моментов времени (временные ряды) обладают свойством нестационарности, что означает, что их структура многокомпонентная. Поэтому задачи управления сетью основываются, в том числе и на предсказанных будущих данных для принятия правильного решения. Выявить и количественно выразить компоненты сложной структуры, определить наличие или отсутствие тенденции, периодичности, случайной компоненты является основной задачей анализа временного ряда.

3. Произведен анализ моделей и методов прогнозирования сетевого трафика для краткосрочных и долгосрочных прогнозов. Определено, что для краткосрочного прогноза при работе с агрегированными данными с целью прогноза объема трафика предпочтительнее использовать статистические модели, а в остальных случаях структурные. Среди статистических подходов наиболее популярным методом прогнозирования являются модели авторегрессии и проинтегрированного скользящего среднего ARIMA. Модель ARIMA является важным классом параметрических моделей, которые позволяют описывать нестационарные ряды. Модели авторегрессионного класса вполне подходят для интеграции в сетевые устройства предсказывать поведение объема трафика на коротком промежутке в реальном времени.

4. Произведен анализ моделей и методов прогнозирования сетевого трафика на основе ИНС. Алгоритмы нейронной сети с глубоким обучением могут идентифицировать нелинейную функцию и осуществить прогнозирование. ИНС типа LSTM используются для прогнозирования трафика в сотовых сетях и в транспортных системах.

5. Исследовано наличие во временных рядах сетевого трафика реального времени эффектов авторегрессионной условной гетероскедастичности.

6. Проведен анализ гибридных моделей авторегрессии и проинтегрированного скользящего среднего ARIMA с обобщенной условной гетероскедастичностью GARCH.

7. Модель авторегрессии проинтегрированного скользящего среднего ARIMA и модель с авторегрессионной условной гетероскедастичностью GARCH являются нелинейными моделями временных рядов, которые совмещают линейную модель ARIMA с условной дисперсией модели GARCH. Таким образом, в рамках самоподобного процесса приемлемо использовать не только модели ARIMA, но и существующие алгоритмы моделей GARCH ввиду того, что при усреднении по шкале времени у самоподобного процесса сохраняется склонность к всплескам.

8. Разработан алгоритм для прогнозирования трафика реального времени в гетерогенных сетях пятого и последующих поколений на основе гибридной модели авторегрессии и проинтегрированного скользящего среднего (ARIMA) и обобщенной условной гетероскедастичностью GARCH с преобразованием Бокса-Кокса для краткосрочного прогноза на языке программирования python.

9. Эмпирические результаты серии данных показывают, что гибридная модель ARIMA(1,2,2)–GARCH(2,0) обеспечивает оптимальные результаты в рамках предсказания будущих значений и эффективно повышает точность оценки прогнозирования трафика реального времени по сравнению с другими моделями.

10. Преобразование Бокса-Кокса не повлияло на качество прогноза при сравнении моделей ARIMA, но позволило оптимизировать параметры. Однако, преобразование Бокса-Кокса совместно с гибридной моделью ARIMA–GARCH

позволило улучшить прогноз на 8,5% при прогнозе на один шаг вперед и на 7,6% при прогнозе на два шага вперед.

11. Разработана модель трафика трехмерной сети высокой плотности как многомерного случайного процесса;

12. Разработан метод использования ИНС типа LSTM для прогнозирования трафика в гетерогенных сетях пятого и последующих поколений в трехмерной сети высокой плотности как многомерного случайного процесса для долгосрочного прогноза.

13. Трафик трехмерной сети высокой плотности в задачах прогнозирования целесообразно рассматривать как многомерный случайный процесс, размерность которого равна количеству узлов сети, производящих трафик. Такой подход позволяет учесть взаимную зависимость потоков трафика, производимых соседними узлами сети.

14. Прогнозирование сетевого трафика как многомерного процесса с помощью ИНС демонстрирует хорошую точность долгосрочного прогноза, в отличие от параметрических моделей типа ARIMA, которые применяются для краткосрочного прогнозирования одномерных процессов.

15. Качество прогнозирования трафика трехмерной сети высокой плотности как многомерного случайного процесса может быть оценено с помощью суммарной среднеквадратической ошибки (*RMSE*), вычисляемой по всем измерениям случайного процесса.

16. Продуктивность использования модели многомерного случайного процесса для описания трафика трехмерной сети высокой плотности может быть оценена относительным изменением суммарной среднеквадратической ошибки.

17. Применение для прогнозирования трафика трехмерной сети высокой плотности модели многомерного случайного процесса, при получении прогноза при помощи ИНС типа LSTM, позволяет повысить эффективность прогнозирования, согласно приведенному примеру, до 35 % (при размерности  $k = 10$ ).

18. Эффективность прогнозирования предложенным методом зависит от размерности случайного процесса, возрастая с увеличением размерности; скорость увеличения эффективности зависит от характеристик сети связи, а именно – от количества взаимных влияний между узлами сети.

19. Разработанные модели и методы позволят повысить точность прогнозирования сетевого трафика гетерогенной сети. В зависимости от вычислительной мощности системы стоит применять либо аналитические методы, либо методы на основе ИНС. Полученные результаты могут быть использованы для повышения эффективности прогнозирования сетевого трафика гетерогенной сети пятого и последующих поколений в области управления сетевым трафиком.

## СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ

ADF-тест	Dickey-Fuller test – Расширенный тест Дики-Фуллера
AIC	Akaike's information criterion – Информационный критерий Акаике
AR	Autoregressive – Авторегрессионная модель
ARCH	Autoregressive conditional heteroscedasticity - Модель авторегрессионной условной гетероскедастичности
ARIMA	Autoregressive integrated moving average – Модель авторегрессии и проинтегрированного скользящего среднего
ARMA	Autoregressive moving average – Модели авторегрессии и скользящего среднего
BIC	Bayesian information criterion – Байесовский информационный критерий
DNN	Deep neural network – Глубокие нейронные сети
FARIMA	Fractional autoregressive integrated moving average model – Дробно-интегрированная модель авторегрессии скользящего среднего
FFNN	Feed Forward Neural Network – Нейронная сеть прямого распространения
GARCH	Generalized autoregressive conditional heteroscedasticity – Модель с авторегрессионной условной гетероскедастичностью
GNN	Graph Neural Network – Графовые нейронные сети
HMM	Hidden Markov Model – Скрытая марковская модель
IoT	Internet of Things – Интернет-вещей
LSTM	Long short-term memory – Долгая краткосрочная память

MA	Moving average – Модель скользящего среднего
MAE	Mean Absolute Error - Средняя абсолютная ошибка
MAPE	Mean Absolute Percentage Error - Средняя абсолютная процентная ошибка
MSE	Mean Square Error - Среднеквадратичная ошибка
QoS	Quality of Service – Качество обслуживания
R-квадрат	Squared Coefficient of determination - Коэффициент детерминации
RF	Random Forest – Метод случайного леса
RMSE	Root mean square deviation – корень средней квадратичной ошибки
RNN	Recurrent neural network – Рекуррентные нейронные сети
SARIMA	Season autoregressive integrated moving average – Сезонная модель авторегрессии и проинтегрированного скользящего среднего
SDN	Software-defined networking - Программно-определяемая сеть
SVM	Support Vector Machine – Метод опорных векторов
WT	Wavelet Transform – Вейвлет-преобразование
АКФ	Автокорреляционная функция
ИНС	Искусственные нейронные сети
ИИ	Искусственный интеллект
ЧАКФ	Функция частной автокорреляции

## СПИСОК ИСПОЛЬЗУЕМЫХ ПЕРЕМЕННЫХ

$\beta_t$	Временной ряд для анализа
$\alpha_t$	Белый шум
$B$	Оператор сдвига назад ( $B\beta_t = \beta_{t-1}$ )
$\varphi(\cdot)$	Полином степени $p$
$\theta(\cdot)$	Полином степени $q$
$d$	Порядок взятия последовательной разности ( $\Delta\beta_t = \beta_{t-1} - \beta_t = (1-B)d\beta_t$ )
$a_t$	Значение текущего входного значения в рамках сигмоидального слоя
$h_{t-1}$	Значение предыдущего скрытого состояния
$c_{t-1}$	Значение состояния ячейки
$\tilde{C}_t$	Значения-кандидаты, которые можно добавлять к состоянию ячейки
$\varphi(B)$	Оператор авторегрессии порядка $p$
$\theta(B)$	Оператор скользящего среднего порядка $q$
$f(t)$	Функция плотностей распределения
$k$	Коэффициенты распределения
$X_t$	Реальное значение временного ряда
$\hat{X}_t$	Прогнозное значение
$L$	Интервал прогноза
$\sigma^2$	Дисперсия случайных отклонений
$e_t$	Последовательность независимых и одинаково распределённых случайных величин со средней, равной нулю, и дисперсией, равной единице
$\alpha$	Коэффициент модели GARCH
$\beta$	Коэффициент модели GARCH

$r$	Порядок GARCH-членов
$s$	Порядок ARCH-членов
$y_t^*$	Преобразованное значение в момент времени $t$
$N$	Объем выборки
$\hat{\rho}_j^2$	Квадрат автокорреляции $j$ -го порядка
$\lambda$	Среднеквадратичное значение ошибки
$p$	Вероятность
$X_k(t)$	Случайные процессы в точках сети
$x_i$	Значение процесса на $i$ -м отсчете интервала прогнозирования из выборки статистики
$\hat{x}_j^{(i)}$	Прогнозируемое значение на $i$ -м отсчете интервала прогнозирования из данных прогноза
$D_T^{(i)}$	Выборка значений одного из случайных процессов
$D_F^{(i)}$	Прогнозируемые значения
$L_{\min}$	Минимальный размер пакета (бит)
$b$	Скорость передачи данных (бит/с)
$n_t$	Количество значений в обучающей выборке
$T_t$	Продолжительность наблюдений
$X(t)$	Дискретный процесс
$x_u$	Количество данных, переданных за интервал $u$
$f(x_u)$	Плотность вероятности случайной величины
$H$	Коэффициент Херста
$F(x)$	Распределение исходного процесса
$F^{(m)}(x)$	Распределение процесса, полученного на $m$ интервалах $u$
$T$	Продолжительность обучающей выборки
$m$	Количество эпох обучения
$D_F$	Набор прогнозируемых значений

$E$	Эффективность прогнозирования
$k$	Размерность процесса

## СПИСОК ЛИТЕРАТУРЫ

1. Hu Y. C. Mobile edge computing—A key technology towards 5G / Y. C Hu, M. Patel, D. Sabella, N. Sprecher, Young V. // ETSI white paper. – 2015. – Т. 11. – №. 11. – С. 1-16.
2. Ateya A. A. Multilevel cloud based Tactile Internet system / A. Ateya, A. Vybornova, R. Kirichek and A. Koucheryavy // 2017 19th International Conference on Advanced Communication Technology (ICACT). – IEEE, 2017. – С. 105-110.
3. Атея, А. А. Архитектура сотовой системы 5G на базе MEC / А. А. Атея, А. С. Мутханна, А. Е. Кучерявый // Молодежная научная школа по прикладной теории вероятностей и телекоммуникационным технологиям (АРТСТ-2017). – 2017. – С. 23-29
4. Ласкин М. Б. Оценка суточной интенсивности движения пункта взимания платы на съезде внутригородской платной дороги / М.Б. Ласкин, А. С. Свистунова, А. Ю. Талавирия // Системный анализ в проектировании и управлении. – 2020. – Т. 24. – №. 2. – С. 257-274.
5. Ferreira G.O. Forecasting Network Traffic: A Survey and Tutorial with Open-Source Comparative Evaluation / G.O. Ferreira, C. Ravazzi, F. Dabbene, G. Calafiore, M. Fiore // IEEE Access - 2023 - DOI: 10.1109/ACCESS.2023.3236261.
6. Lechowicz P. Regression-based fragmentation metric and fragmentation-aware algorithm in spectrally-spatially flexible optical networks / P. Lechowicz // Computer Communications – 2021. - Vol. 175. - PP. 156–176. 2021.
7. Stepanov N. Applying machine learning to LTE traffic prediction: Comparison of bagging, random forest, and SVM / N. Stepanov, D. Alekseeva, A. Ometov, and E. S. Lohan // 2020 12th International Congress on Ultra Modern Telecommunications and Control Systems and Work- shops (ICUMT). – 2020. - PP. 119–123.
8. Миротин Е. А. Прогнозирование временных рядов с использованием непрореженного вейвлет-преобразования и односторонних фильтров / Е. А. Миротин // – 2011.

9. Шкляев А. О. Прогнозирование финансовых временных рядов методом скрытых марковских моделей / А. О. Шкляев // Научные записки молодых исследователей. – 2015. – №. 1. – С. 17-21.
10. Гребенников А. В. Прогнозирование значений трафика данных с использованием моделей временных рядов / А.В. Гребенников, Ю.А. Крюков, Д.В. Чернягин // Системный анализ в науке и образовании. – 2011. – №. 3. – С. 1-10.
11. Советов Б. Я. Авторегрессионные модели прогнозирования сетевого трафика / Б.Я. Советов, Т.М. Татарникова, В.В. Цехановский // Информационные технологии в управлении. – 2020. – С. 143-145.
12. Советов Б.Я., Татарникова Т.М., Пойманова Е.Д. Организация многоуровневого хранения данных / Б.Я. Советов, Т.М. Татарникова, Е.Д. Пойманова // Информационно-управляющие системы. – 2019. – No 2. – С. 68–75. DOI:10.31799/1684-8853-2019-2-68-75.
13. Татарникова, Т.М. Статистические методы исследования сетевого трафика / Т.М. Татарникова // Информационно-управляющие системы. – 2018. – №5(96). – С. 35-43.
14. Box, G.E.P. Time series analysis: forecasting and control / G.E.P. Box, J.M. Jenkins, G.C. Reinsel, G.M. Ljung // John Wiley & Sons – 2015. – PP. 720.
15. Shu, Y. Traffic prediction using FARIMA models / Y. Shu, Z. Jin, L. Zhang et al. // 1999 IEEE International Conference on Communications. – 1999. – Т. 2. – P. 891-895.
16. Agani, A. Forecast comparison of volatility models on Russian stock market / A. Ahanin // Applied Econometrics. – 2017. – Vol. 48. – P. 63-84.
17. Gorshenin A. Mobile network traffic analysis based on probability-informed machine learning approach / A. Gorshenin, A. Kozlovskaya, S. Gorbunov, I. Kochetkova // Computer Networks. –2024. –Vol. 247. –P. 110433. – DOI 10.1016/j.comnet.2024.110433.
18. Лебедева, О. А. Обзор инструментов для регрессионного анализа в R: от фундаментальных методов до нейронных сетей / О. А. Лебедева, И. С. Зарядов

- // Информационно-телекоммуникационные технологии и математическое моделирование высокотехнологичных систем: Материалы Всероссийской конференции с международным участием, Москва, 08–12 апреля 2024 года. – Москва: Российский университет дружбы народов им. П. Лумумбы, 2024. – С. 18-20. – EDN XWBOEG.
19. Park K. Self-Similar network traffic and performance evaluation / K. Park, W. Willinger // New York, John Wiley & Sons. – 2000. – P. 576.
  20. Тархов, Д.А. Нейросетевые модели и алгоритмы: справочник / Д. А. Тархов // – М.: Радиотехника. – 2014. – с. 349.
  21. Rutka, G. Network Traffic Prediction using ARIMA and Neural Networks Models / G. Rutka // Electronics And Electrical Engineering. – 2008. – №4(84). – P. 53-58.
  22. Привалов, А.Ю. Об использовании некоторых моделей самоподобного сетевого трафика в имитационном моделировании / А.Ю. Привалов, А.В. Благов // Математическое моделирование. – 2011. – №7. – С. 114-128.
  23. Zhou, B. Network traffic modeling and prediction with ARIMA/GARCH / B. Zhou, D. He, Z. Sun, W. Ng // 3rd International Working Conference on Performance Modeling and Evaluation of Heterogeneous Networks (Het-Nets 05). – 2005. – P. 1-10.
  24. Chen, C. Short-Time Traffic Flow Prediction with ARIMA-GARCH Model / C. Chen, J. Hu, Q. Meng, Y. Zhang // 2011 IEEE Intelligent Vehicles Symposium (IV). – 2011. – P. 607-612.
  25. Kim, S. Forecasting Internet Traffic by Using Seasonal GARCH Models / S. Kim // Journal of Communications and Networks. – 2011. – Vol. 13, Issue 6. – P. 621-624.
  26. Tran, T.Q. A multiplicative seasonal ARIMA/GARCH model in EVN traffic prediction / T.Q. Tran, Z. Ma, L. Hao et al. // International Journal of Communications, Network and System Sciences. – 2015. – Vol. 8, Issue 4. – P. 43-49.
  27. Azzouni A. A long short-term memory recurrent neural network framework for network traffic matrix prediction / A. Azzouni, G. Pujolle // – 2017.

28. Аверкин, А. Н. Объяснительный искусственный интеллект в анализе цифровых изображений на основе нейронных сетей глубокого обучения / А. Н. Аверкин, Е. Н. Волков, С. А. Ярушев // Известия Российской академии наук. Теория и системы управления. – 2024. – № 1. – С. 150-178. – DOI 10.31857/S0002338824010122. – EDN WJCMWV.
29. Горелова А. В., Любимова Т. В. Алгоритм обратного распространения ошибки / А.В. Горелова, Т.В. Любимова // Наука и современность. – 2015. – №. 38. – С. 151-156.
30. Ramakrishnan N. Network traffic prediction using recurrent neural networks / N. Ramakrishnan, T. Soni // 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA). – 2018. – PP. 187–193.
31. Пашшоев Б. Анализ нейросетевых моделей для прогнозирования временных рядов / Б. Пашшоев, Д.А. Петрусевич // Russian Technological Journal. – 2024. – Т. 12. – №. 4. – С. 106–116.
32. Алжеев А. В. Сравнительный анализ прогнозных моделей ARIMA и LSTM на примере акций российских компаний / А.В. Алжеев, Р. А. Кочкаров // Финансы: теория и практика. – 2020. – Т. 24. – №. 1. – С. 14-23.
33. Трегуб А.В., Трегуб И.В. Методика построения модели ARIMA для прогнозирования динамики временных рядов // Вестник Московского государственного университета леса – Лесной вестник, 2011, № 5, С. 179–183.
34. Sivanathan, A. Classifying IoT devices in smart environments using network traffic characteristics / A. Sivanathan, H.H. Gharakheili, F. Loi et al. // IEEE Transactions on Mobile Computing. – 2018. – Vol. 18, Issue 8. – P. 1745-1759.
35. Дмитриева, Ю.С. Анализ методов идентификации трафика для управления ресурсами в SDN / Ю.С. Дмитриева, Д.В. Окунева, В.С. Елагин // Труды учебных заведений связи. – 2023. – Т. 9, № 6. – С. 42-57.
36. Гребенщикова, А. А. Модели авторегрессии и проинтегрированного скользящего среднего ARIMA для прогнозирования сетевого трафика / А. А. Гребенщикова // Электросвязь. – 2024. – № 5. – С. 39-46. – DOI 10.34832/ELSV.2024.54.5.006. – EDN OUXNFB.

37. Дуброва, Т.А. Статистические методы прогнозирования / Т.А. Дуброва. – М.: ЮНИТИ-ДАНА, 2003. – 206 с.
38. Бородич, С.А. Эконометрика: учебное пособие для вузов / С.А. Бородич. – М.: Новое знание, 2004. – 407 с.
39. Гребенщикова, А. А. Обзор модели авторегрессии и проинтегрированного скользящего среднего  $Agima$  для прогнозирования сетевого трафика / А. А. Гребенщикова, В. С. Елагин // Актуальные проблемы инфотелекоммуникаций в науке и образовании : сборник научных статей: в 4х томах, Санкт-Петербург, 24–25 февраля 2021 года / Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича. Том 1. – Санкт-Петербург: Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича, 2021. – С. 266-271. – EDN PNYPJG.
40. Yaziz, S.R. The performance of hybrid ARIMA-GARCH modeling in forecasting gold price / S.R. Yaziz, N.A. Azizan, R. Zakaria, M.H. Ahmad // 20th international congress on modelling and simulation. – 2013. – P. 1201-1207.
41. Гребенщикова, А. А. Модели авторегрессии и проинтегрированного скользящего среднего ARIMA с применением авторегрессионной условной гетероскедастичности / А. А. Гребенщикова, В. С. Елагин // Актуальные проблемы инфотелекоммуникаций в науке и образовании (АПИНО 2022) : XI Международная научно-техническая и научно-методическая конференция, Санкт-Петербург, 15–16 февраля 2022 года. Том 1. – Санкт-Петербург: Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича, 2022. – С. 370-372. – EDN MXUUVC.
42. Srinivasan, P.V. Modeling and forecasting the stock market volatility of S&P 500 index using GARCH models / P.V. Srinivasan // IUP Journal of Behavioral Finance. – 2011. – Vol. 8, Issue 1. – P. 51-69.
43. Ljung, G.M. On a Measure of a Lack of Fit in Time Series Models / G.M. Ljung, G.E.P. Box. // Biometrika. –1978. – Vol. 65, Issue 2. – P. 297-303.

44. Федорова, Е.А. Статистическое моделирование оценки изменения эффективности фондового рынка и ее практическое применение / Е.А. Федорова // Аудит и финансовый анализ. – 2009. – №. 6. – С. 243-249.
45. Лемешко, Б.Ю. Критерии проверки отклонения распределения от нормального закона / Б.Ю. Лемешко. – М.: ИНФРА-М, 2023. – 369 с.
46. Pham, H.T. Estimation and forecasting of machine health condition using ARMA/GARCH model / H.T. Pham, B.S. Yang // Mechanical systems and signal processing. – 2010. – Vol. 24, Issue 2. – P. 546-558.
47. Engle, R.F. Autoregressive Conditional Heteroscedasticity with Estimates of Variance of United Kingdom Inflation / R.F. Engle // Econometrica. –1982. – Vol. 50, Issue 4. – P. 987-1007.
48. Крюков, Ю.А. ARIMA—модель прогнозирования значений трафика / Ю.А. Крюков, Д.В. Чернягин // Информационные технологии и вычислительные системы. – 2011. – №. 2. – С. 41-49.
49. 5G Traffic Datasets [электронный ресурс] // kaggle [сайт]. – <https://www.kaggle.com/datasets/kimdaegyeom/5g-traffic-datasets> (дата обращения: 05.05.24).
50. Гребенщикова, А. А. Модели ARIMA-GARCH для прогнозирования сетевого трафика реального времени / А. А. Гребенщикова // Электросвязь. – 2024. № 8. – С. 8-15.
51. Гайдамака, Ю. В. О математическом моделировании беспроводных сетей 5G/6G / Ю. В. Гайдамака, К. Е. Самуйлов // Системы управления, сложные системы: моделирование, устойчивость, стабилизация, интеллектуальные технологии: материалы IX Международной научно-практической конференции, Елец, 24–25 апреля 2023 года. – Елец: Елецкий государственный университет им. И.А. Бунина, 2023. – С. 11-15. – EDN ZGJUQJ.
52. Банникова, Е. А. Математическая модель обслуживания комбинации многоадресного и одноадресного трафика в сетях 5G / Е. А. Банникова, Ф. А. Москалева, Ю. В. Гайдамака // Информационно-телекоммуникационные технологии и математическое моделирование высокотехнологичных систем :

- Материалы Всероссийской конференции с международным участием, Москва, 08–12 апреля 2024 года. – Москва: Российский университет дружбы народов им. П. Лумумбы, 2024. – С. 60-64. – EDN QZPDLX.
53. Эсенг Манге, П. Л. Э. Система массового обслуживания с эластичным трафиком для анализа разделения ресурса сети 5G по задержке передачи данных / П. Л. Э. Эсенг Манге, А. С. Власкина, И. А. Кочеткова // Информационно-телекоммуникационные технологии и математическое моделирование высокотехнологичных систем: Материалы Всероссийской конференции с международным участием, Москва, 08–12 апреля 2024 года. – Москва: Российский университет дружбы народов им. П. Лумумбы, 2024. – С. 73-76. – EDN WHYVGP.
54. Кучерявый А.Е. Трехмерные многослойные гетерогенные сверхплотные сети. / А.Е. Кучерявый, А.И. Парамонов, М.А. Маколкина, и др. // Информационные технологии и телекоммуникации. – 2022. – Т. 10. –№ 3. – С. 1-12. DOI 10.31854/2307-1303-2022-10-3-1-12.
55. Бушеленков С.Н. Анализ и формирование структуры сети интернета вещей на основе моделей решеток. / С.Н. Бушеленков, А.И. Парамонов // Электросвязь. – 2021. – № 7. – С. 23-28. DOI: 10.34832/ELSV.2021.20.7.002.
56. Abdellah A.R. IoT traffic prediction with neural networks learning based on SDN infrastructure. / A.R. Abdellah, A.Volkov, A. Muthanna, and others // Lecture Notes in Computer Science. – 2020. – С. 64-76.
57. 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, и др. // Электросвязь. – 2021. – № 1. – С. 23-27.
58. Вентцель А.Д. Курс теории случайных процессов / А.Д. Вентцель // М. Наука. Физматлит. – 1996. – С. 399.
59. Joshi M. A Review of Network Traffic Analysis and Prediction Techniques / M. Joshi, T. H. Hadi // –2015.

60. Викулов А.С. Постановка задачи замощения плоскости в применении к частотно-территориальному планированию сетей IEEE 802.11. / А.С. Викулов, А.И. Парамонов // Радиотехнические и телекоммуникационные системы. – 2021. – № 1 (41). – С. 24-32.
61. Миллер Б.М. Теория случайных процессов в примерах и задачах. / Б.М. Миллер, А.Р. Панков // М. Физматлит. – 2002. – С. 320.
62. Manzoor S. Modeling of Wireless Traffic Load in Next Generation Wireless Networks / Manzoor S., Bajwa K.B., Sajid M., Manzoor H., Manzoor M., Ali N., Menhas M.I. // Mathematical Problems in Engineering – 2021. – P. 15.
63. Wang J. Spatiotemporal modeling and prediction in cellular networks: A big data enabled deep learning approach / J. Wang, J. Tang, Z. Xu, Y. Wang, G. Xue, X. Zhang, D. Yang // IEEE Conference on Computer Communications, 2017. – P. 1–9.
64. Li D. Spatiotemporal traffic flow prediction with KNN and LSTM / D. Li, Y. Yang, S. Zhang // Journal of Advanced Transportation. – 2019. –P. 1–10.
65. Hochreiter S. Long short-term memory / S. Hochreiter, J. Schmidhuber // Neural computation. – 1997. –vol. 9. – P. 1735–80.
66. Kavitha A. K. Deep learning model for traffic flow prediction in wireless network / A. K. Kavitha, S. Mary Praveena // Automatika – P. 848–857.
67. Шелухин О.И. Самоподобие и фракталы. Телекоммуникационные приложения / О.И. Шелухин, А.В. Осин, С.М. Смольский //М. Физматлит. – 2008. – P. 368.
68. Цыбаков Б.С. Модель телетрафика на основе самоподобного случайного процесса. / Б.С. Цыбаков // Радиотехника. – 1999. –№5.
69. Шелухин О.И. Фрактальные процессы в телекоммуникациях. / О.И. Шелухин, А.М. Тенякшев, А.В. Осин // М. Радиотехника. – 2003. – С. 480.
70. Sjöberg J. Overtraining, Regularization, and Searching for Minimum in Neural Networks / J. Sjöberg, L. Ljung // IFAC Proceedings Volumes, – vol. 25, – 1992, – P. 73-78.
71. Гребенщикова, А. А. Прогнозирование трафика трехмерной сети интернета вещей высокой плотности как многомерного случайного процесса / А. А.

Гребенщикова, В.С. Елагин // Труды учебных заведений связи. 2024. Т. 10. № 4. С. 116–126.

# ПРИЛОЖЕНИЕ А. ДОКУМЕНТЫ, ПОДТВЕРЖДАЮЩИЕ ВНЕДРЕНИЕ ОСНОВНЫХ РЕЗУЛЬТАТОВ ДИССЕРТАЦИОННОЙ РАБОТЫ



Акционерное общество  
«НАУЧНО-ПРОИЗВОДСТВЕННОЕ  
ПРЕДПРИЯТИЕ  
«МЕЖОТРАСЛЕВОЙ ЦЕНТР  
ЭРГОНОМИЧЕСКИХ ИССЛЕДОВАНИЙ  
И РАЗРАБОТОК»  
(АО «НПП «ЭРГОЦЕНТР»)

170021, г. Тверь, ул. Хрустальная, 2, корп. 4  
Тел. (4822) 52-08-96; Факс: (4822) 52-11-96  
E-mail: npp@ergocentr.ru

12.09.2024 № 366/24

На № от

УТВЕРЖДАЮ  
Генеральный директор  
АО «НПП «Эргоцентр»  
доктор технических наук,  
профессор

И.Н. Глушков



«12» сентября 2024 г.

## АКТ

о внедрении результатов диссертационной работы Гребеншиковой Александры Андреевны на тему «Модели и методы прогнозирования сетевого трафика в гетерогенных сетях связи с учётом его статистических характеристик», представленной на соискание ученой степени кандидата технических наук по специальности 2.2.15– Системы, сети и устройства телекоммуникаций

Научно-техническая комиссия в составе: председателя комиссии – советника генерального директора, кандидата технических наук, старшего научного сотрудника Отчиченко В. Л. и членов комиссии: заместителя начальника научно-исследовательского отделения, кандидата технических наук, старшего научного сотрудника Горещкого Ю. Г., ведущего научного сотрудника научно-исследовательского отделения, кандидата технических наук, старшего научного сотрудника Хуцишвили В. М., начальника отдела-2 научно-исследовательского отделения, кандидата технических наук, доцента Королькова С.И. составила настоящий акт о том, что результаты диссертационного исследования на соискание учёной степени кандидата технических наук Гребеншиковой Александры Андреевны на тему: «Модели и методы прогнозирования сетевого трафика в гетерогенных сетях связи с учётом его статистических характеристик» внедрены в ходе выполнения опытно-конструкторской работы, направленной на расширение функциональности комплексного имитационно-моделирующего стенда системы специального назначения в интересах решения задач обоснования

системотехнических решений по построению функциональных подсистем и всей системы специального назначения в целом (шифр – «Орфей-Эрго-2014»).

Разработанные автором метод прогнозирования объема трафика реального времени в гетерогенной сети пятого и последующих поколений на краткосрочном периоде на основе гибридной модели прогнозирования ARIMA(1,2,2)GARCH(2,0), а также модель трафика трехмерной сети связи высокой плотности как многомерного случайного процесса и метод прогнозирования с использованием искусственной нейронной сети реализованы в среде моделирования комплексного имитационно-моделирующего стенда системы специального назначения, разрабатываемой в рамках выполнения ОКР «Орфей-Эрго-2014», для анализа адекватности функционирования моделей пунктов управления из состава АСУ.

Реализация положений указанных методов и модели трафика позволила повысить точность прогнозирования трафика в интересах анализа пропускной способности каналов связи между непосредственно пунктами управления, а также между пунктами управления и управляемыми объектами.

Акт выдан для представления в диссертационный совет.

Председатель комиссии:

Советник генерального директора  
кандидат технических наук, старший научный сотрудник



В. Отчиченко

Члены комиссии:

Заместитель начальника научно-исследовательского отделения  
кандидат технических наук, старший научный сотрудник



Ю. Горецкий

Ведущий научный сотрудник  
научно-исследовательского отделения  
кандидат технических наук, старший научный сотрудник



В. Хуцишвили

Начальник отдела-2  
научно-исследовательского отделения  
кандидат технических наук, доцент



С. Корольков

## АКТ

о внедрении результатов диссертационной работы Гребенщиковой Александры Андреевны на тему «Модели и методы прогнозирования сетевого трафика в гетерогенных сетях связи с учётом его статистических характеристик», представленной на соискание ученой степени кандидата технических наук по специальности 2.2.15– Системы, сети и устройства телекоммуникаций

Настоящим актом подтверждаем, что научные результаты диссертационной работы Гребенщиковой Александры Андреевны «Модели и методы прогнозирования сетевого трафика в гетерогенных сетях связи с учётом его статистических характеристик», представленной на соискание ученой степени кандидата технических наук, внедрены в решения серии «Профит» разработки ООО "НТЦ СевенТест"

При разработке были использованы следующие новые научные результаты из диссертации А. А. Гребенщиковой:

- Метод прогнозирования объема трафика гетерогенной сети пятого и последующих поколений на краткосрочном периоде на основе модели ARIMA(1,5,4) обеспечивает уменьшение ошибки точности прогнозирования до 19%, что на 60% меньше чем с использованием исходной модели ARIMA(1,1,2).

- Модель трафика трехмерной сети связи высокой плотности как многомерного случайного процесса и метод прогнозирования с использованием искусственной нейронной сети позволяют повысить эффективность прогнозирования до 35%.

Председатель комиссии

Генеральный директор ООО "НТЦ СевенТест"  Б. Я. Розенцвайг

Член комиссии

Технический директор ООО "НТЦ СевенТест", к.т.н.  И. М. Ехриель



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](mailto:rector@sut.ru)

ОКПО 01179934 ОГРН 1027809197635

ИНН 7808004760 КПП 784001001

ОКТМО 40909000

13.09.2024 № 07/54  
на № \_\_\_\_\_ от \_\_\_\_\_

Утверждаю

И.о. проректора по  
научной работе



Рабин  
Алексей Владимирович

Акт

о внедрении научных результатов,  
полученных Гребенщиковой Александрой Андреевной

Комиссия в составе Елагина В.С., и.о. декана факультета инфокоммуникационных сетей и систем, Дунайцева Р.А., доцента кафедры сетей связи и передачи данных, Гольдштейна А.Б., доцента кафедры инфокоммуникационных сетей и Ворожейкиной О.И., заведующей лабораторией кафедры сетей связи и передачи данных составила настоящий акт о том, что научные результаты, полученные Гребенщиковой Александрой Андреевной, использованы:

1. При чтении лекций и проведении практических занятий по курсу «Математическое и программное обеспечение киберфизических систем» (Рабочая Программа № 23.05/1-Д, утверждена Первым проректором-проректором по учебной работе А.В. Абилов 01.03.2023), разделы программы:  
- Задачи прогнозирования. Математические подходы к проектированию киберфизических систем, программные инструменты.

- Задачи прогнозирования, трансформация задач прогнозирования в современной системе связи, формализованные методы прогнозирования, комплексные методы прогнозирования, перспективы развития методов прогнозирования. Постановка задач по построению оптимальной сети, проблемы выбора, оценки и прогнозирования основных показателей сети и поддерживаемых услуг, особенности планирования, базовые принципы. Оценка методов оптимизации для задач построения инфокоммуникационных сетей и систем.

В указанных дисциплинах используются следующие новые научные результаты, полученные Гребенщиковой Александрой Андреевной в диссертационной работе:

- Представлены методы прогнозирования объема трафика реального времени в гетерогенной сети пятого и последующих поколений на краткосрочном периоде на

основе гибридной модели прогнозирования авторегрессионных моделей проинтегрированного и скользящего среднего ARIMA и моделей условной гетероскедастичности GARCH.

- Исследование подтверждает наличие во временных рядах сетевого трафика реального времени эффектов авторегрессионной условной гетероскедастичности и расширяет существующие знания в области прогнозирования сетевого трафика в гетерогенной сети пятого и последующих поколений на краткосрочном периоде.

- Исследована эффективность гибридизации моделей авторегрессии и проинтегрированного скользящего среднего (ARIMA) и GARCH с преобразованием Бокса-Кокса для анализа и прогнозирования сетевого трафика реального времени в гетерогенной сети пятого и последующих поколений на краткосрочном периоде.

- Эффективность прогнозирования трафика как многомерного случайного процесса в трехмерной сети связи высокой плотности возрастает с увеличением размерности. Таким образом, такой трафик в задачах прогнозирования следует рассматривать как многомерный случайный процесс, размерность которого равна количеству узлов сети, производящих трафик.

Полученные научные результаты использованы при выполнении Соглашения о предоставлении из федерального бюджета гранта в форме субсидий, выделяемого для государственной поддержки научных исследований, проводимых под руководством ведущих ученых в российских образовательных организациях высшего образования, научных учреждениях и государственных научных центрах Российской Федерации от "06" июля 2022г. № 075-15-2022-1137 по приоритетному направлению научно-технологического развития Российской Федерации 20а - Переход к передовым цифровым, интеллектуальным производственным технологиям, роботизированным системам, новым материалам и способам конструирования, создание систем обработки больших объемов данных, машинного обучения и искусственного интеллекта.

И.о. декана факультета ИКСС,  
канд. техн. наук, доцент



В.С. Елагин

Доцент кафедры ССиПД,  
канд. техн. наук



Р.А. Дунайцев

Профессор кафедры ИКС,  
док. техн. наук



А.Б. Гольштейн

Зав. лабораторией кафедры ССиПД



О.И. Ворожейкина