

На правах рукописи

Гребенщикова Александра Андреевна

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

2.2.15. Системы, сети и устройства телекоммуникаций

Автореферат
диссертации на соискание ученой степени
кандидата технических наук

Санкт-Петербург – 2024

Работа выполнена в федеральном государственном бюджетном образовательном учреждении высшего образования «Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича» на кафедре инфокоммуникационных систем.

Научный руководитель: кандидат технических наук, доцент
Елагин Василий Сергеевич

Официальные
оппоненты:

Кучерявый Евгений Андреевич,
доктор технических наук, профессор,
Московский институт электроники и математики
имени А. Н. Тихонова Национального
исследовательского университета «Высшая школа
экономики», департамент электронной инженерии,
профессор

Маркелов Олег Александрович,
кандидат технических наук, доцент,
Санкт-Петербургский государственный
электротехнический университет «ЛЭТИ»
им. В.И. Ульянова (Ленина),
кафедра радиотехнических систем,
и.о. заведующего кафедрой

Ведущая организация: Федеральное государственное учреждение
«Федеральный исследовательский центр
«Информатика и управление»
Российской академии наук», г. Москва

Защита состоится 25 декабря 2024 года в 14.00 на заседании диссертационного совета 55.2.004.01, созданном на базе Федерального государственного бюджетного образовательного учреждения высшего образования «Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича», по адресу: Санкт-Петербург, пр. Большевиков, д. 22, корп. 1, ауд. 554/1.

С диссертацией можно ознакомиться в библиотеке СПбГУТ по адресу Санкт-Петербург, пр. Большевиков, д. 22, корп. 1 и на сайте www.sut.ru.

Автореферат разослан 25 октября 2024 года.

Ученый секретарь
диссертационного совета 55.2.004.01,
канд. техн. наук, доцент

А.Г. Владыко

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

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 искусственных нейронных сетей (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. Мутханни, А.А.А. Ateya, G.E.P. 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 (autoregressive integrated moving average) и гибридных моделей ARIMA с обобщенной условной гетероскедастичностью GARCH (generalized autoregressive conditional heteroscedasticity);

- разработка метода прогнозирования трафика в гетерогенных сетях пятого и последующих поколений на основе модели авторегрессии и проинтегрированного скользящего среднего 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 и обобщенной условной гетероскедастичностью с преобразованием Бокса-Кокса для краткосрочного прогноза;

- исследование методов прогнозирования сетевого трафика на основе применения ИНС;

- исследование модели трафика трехмерной сети высокой плотности как многомерного случайного процесса;

- разработка метода использования ИНС типа LSTM (long short-term memory) 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 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 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 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 $ARIMA(1,1,2)$.

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 Международной научно-технической и научно-методической конференции «Актуальные проблемы инфотелекоммуникаций в науке и образовании» (Санкт-Петербург, 2021, 2022), 27-ой международной конференции «International conference on Distributed Computer and Communication Networks: Control, Computation, Communications DCCN» (Москва, 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 Минобрнауки России и 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.

Структура и объем диссертации. Диссертация состоит из введения, четырех глав, заключения, списка сокращений и условных обозначений, списка используемых переменных, списка использованных источников и одного приложения. Полный объем диссертации составляет 110 страниц. Работа содержит 34 рисунков, 8 таблиц и список из 71 литературного источника.

ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

Во введении обоснована актуальность темы исследования и определены её ключевые особенности, сформулированы цели и задачи работы, перечислены основные положения, выносимые на защиту, определена научная новизна результатов, указаны теоретическая и практическая ценность результатов, приведены сведения об апробации работы, перечислены публикации по теме выполненного исследования.

В первой главе 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 ARIMA. 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

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

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

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. Для оптимального подбора параметров для модели ARIMA с применением условной гетероскедастичности GARCH был рассмотрен алгоритм оценки параметров модели ARIMA-GARCH. Пошаговая оценка параметров модели ARIMA(p,d,q)-GARCH(s,r) продемонстрирована на рисунке 1.



Рисунок 1 – Алгоритм оценки параметров модели ARIMA-GARCH

Произведен анализ моделей и методов прогнозирования сетевого трафика на основе ИНС и сделан вывод о том, что рекуррентные нейронные сети RNN (Recurrent neural network) обеспечивают лучшие результаты в прогнозировании последовательных данных по сравнению с нейронной сетью прямого распространения FFNN (Feed Forward Neural Network). Алгоритмы нейронной сети с глубоким обучением могут идентифицировать нелинейную функцию и осуществить прогнозирование. ИНС типа LSTM так же довольно часто встречаются в научной литературе в области прогнозирования сетевого трафика (например, прогнозирование трафика в сотовых сетях). LSTM специализируются на прогнозировании временных последовательностей благодаря своей архитектуре, которая представлена в виде трех фильтров.

В результате проведенного анализа представлены преимущества и недостатки рассмотренных моделей прогнозирования для временных рядов. Так же сделаны выводы о неоднородной структуре трафика в гетерогенной сети. Таким образом, рост

объемов разнородного трафика в инфокоммуникационных сетях актуализирует вопросы обеспечения качества предоставляемых услуг связи, что в свою очередь требует обращения к моделям прогнозирования.

Во второй главе описана структура модели авторегрессии и проинтегрированного скользящего среднего и разработан метод прогнозирования трафика в гетерогенных сетях пятого и последующих поколений на основе модели ARIMA для краткосрочного прогноза.

Произведен анализ трафика интернета вещей (Internet of Things, IoT), получены функции плотности распределения времени между пакетами и длин пакетов. Исследовано самоподобие такого трафика с применением RS-анализа (метод нормированного размаха), результаты которого приведены в таблице 1.

Таблица 1– 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.

Рассматриваемые временной ряд был разделен на тренировочные участки, которые в соответствии с методикой Бокса-Дженкинса проверялись на стационарность с помощью статистики Дики-Фуллера. Результаты представлены в таблице 2 для одного из тренировочных участков.

Таблица 2 – 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.

После оценки параметров модели ARIMA(p,d,q) была предложена модель 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).

С помощью программной среды Python был сформирован код для расчета оптимальной модели ARIMA(p,d,q). Результаты представлены в таблице 3, где значения информационного критерия AIC, который оценивает, насколько хорошо модель подходит под данные, сравниваются с разными моделями ARIMA.

Таблица 3 - 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 2 представлены результаты оценки такой модели с минимальным критерием AIC.

```

Dep. Variable:                Length    No. Observations:           4000
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 2 – Предварительные результаты по модели ARIMA(1,5,4)

Для оценки прогноза была выбрана средняя абсолютная процентная ошибка (mean absolute percentage error, MAPE):

$$\text{MAPE} = \frac{100\%}{L} \sum_{t=1}^L \left| \frac{X_t - \hat{X}_t}{X_t} \right|, \quad (2)$$

где X_t – реальное значение; \hat{X}_t – прогнозное значение; L – интервал прогноза.

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 MAPE=19% можно оценить, как хороший прогноз, но он уже достаточно близок к удовлетворительному.

В третьей главе была описана структура синтеза моделей авторегрессии и проинтегрированного скользящего среднего с применением условной гетероскедастичности ARIMA-GARCH и разработан метод прогнозирования трафика реального времени в гетерогенных сетях пятого и последующих поколений на основе гибридной модели авторегрессии и проинтегрированного скользящего среднего и обобщенной условной гетероскедастичностью с преобразованием Бокса-Кокса для краткосрочного прогноза.

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

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^s \alpha_i \alpha_{t-i}^2 + \sum_{j=1}^r \beta_j \sigma_{t-j}^2, \quad (3)$$

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 (autoregressive conditional heteroscedasticity).

Для исследования был выбран трафик реального времени и предложен алгоритм подбора и оценки гибридной модели ARIMA-GARCH (рисунок 3).

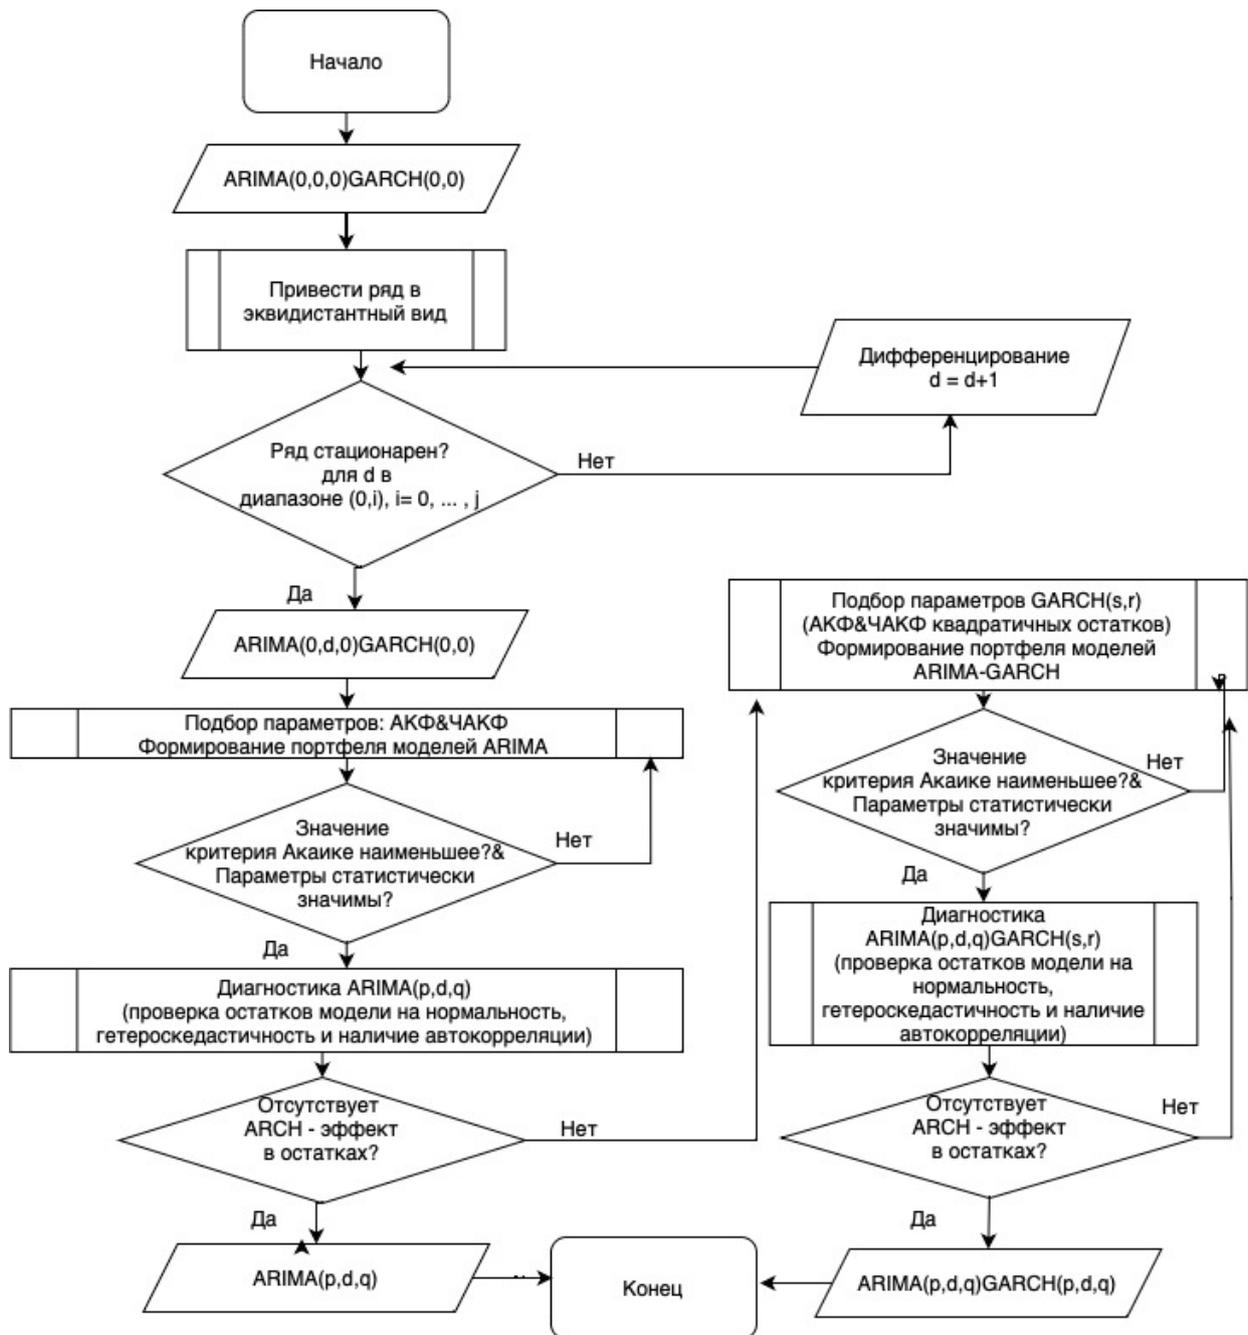


Рисунок 3 – Алгоритм подбора гибридной модели ARIMA-GARCH

Для преобразования данных был предложен метод Бокса-Кокса. Данный инструмент способен нормализовать данные и выровнять дисперсию. Таким образом, данные трансформировались по методу Бокса-Кокса (рисунок 3 и рисунок 4), который применяется только для положительных рядов ($y_t > 0$):

$$y_t^* = f(x) = \begin{cases} \frac{y_t^\lambda - 1}{\lambda}, \lambda \neq 0; \\ \ln(y_t), \lambda = 0, \end{cases} \quad (4)$$

где y_t^* – преобразованное значение в момент времени t ; λ – 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 проводилась с помощью расширенного теста Дики-Фуллера (augmented Dickey-Fuller test, ADF).

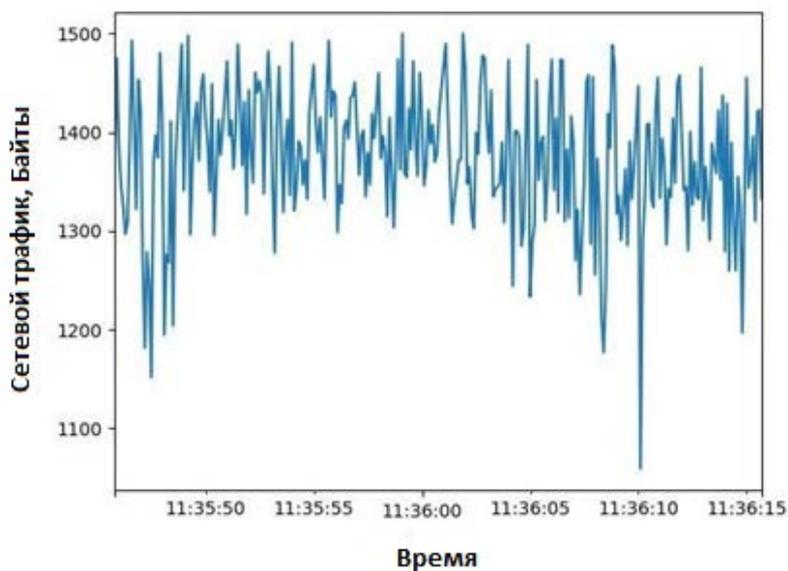


Рисунок 4 – Пример трафика реального времени

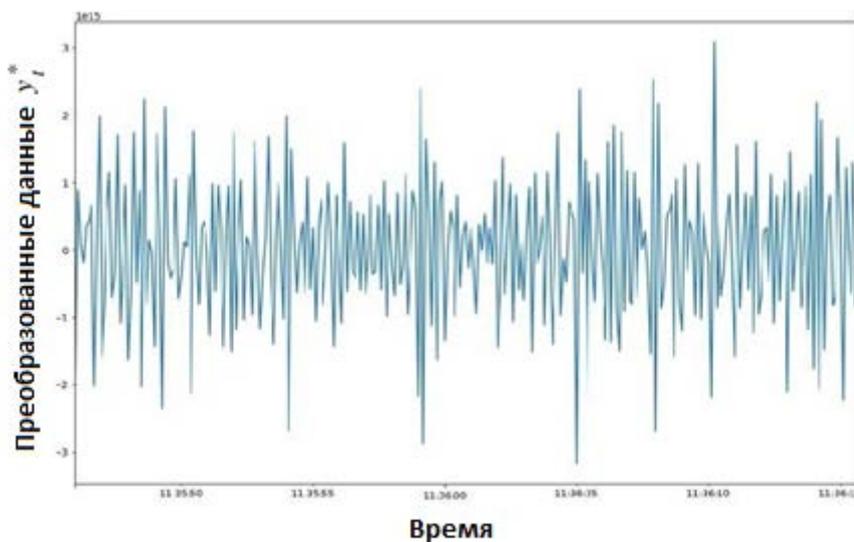


Рисунок 5 – Преобразованный ряд

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

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

$$Q = N(N+2) \sum_{j=1}^L \frac{\hat{p}_j^2}{(N-j)}, \quad (5)$$

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 χ^2 . Значения p выше 0,05 указывают на принятие нулевой гипотезы о точности модели при уровне значимости 95%.

Эффективного результата в построении моделей с ARCH-GARCH процессами в остатках можно достичь путем проверки остатков на нормальное распределение. Для проверки гипотезы о нормальном распределении остатков был выбран тест Шапиро-Уилка.

Таким образом была подобрана модель ARIMA(1,2,2). Для определения порядка параметров при построении модели GARCH (s,r) использовались автокорреляционная функция и функция частичной автокорреляции остатков модели ARIMA. Перед построением модели было подтверждено наличие условной гетероскедастичности с помощью теста множителей Лагранжа (ARCH LM-тест).

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 4 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. 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.

Таблица 4 – 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

АКФ и ЧАКФ квадратов стандартизированных остатков для гибридной модели ARIMA(1,2,2)-GARCH(2,0) продемонстрировали близкие к нулю значения (рисунок 6 и рисунок 7), что согласуется с Q-статистикой Льюнга-Бокса. Предположение о нормальности стандартизированных остатков для модели удовлетворилось тестом Шапиро-Уилка. Между тем тест ARCH-LM остатков модели показал, что условная гетероскедастичность больше не присутствует во временном ряде.

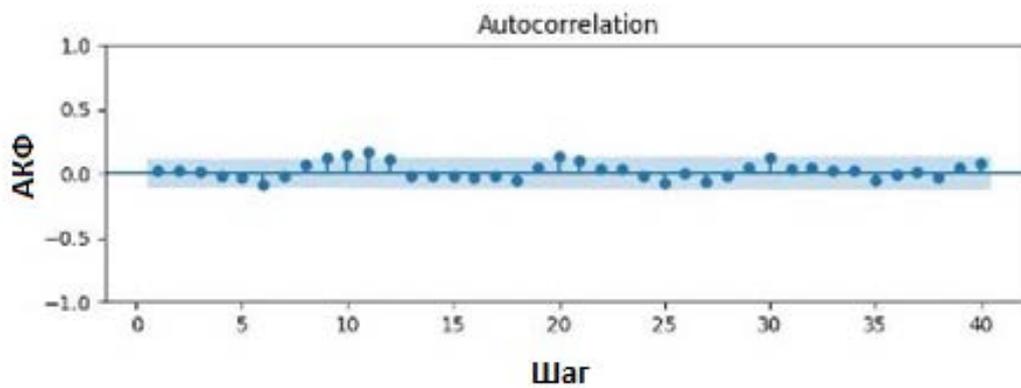


Рисунок 6 – Функция АКФ остатков модели ARIMA(1,2,2)-GARCH(2,0)

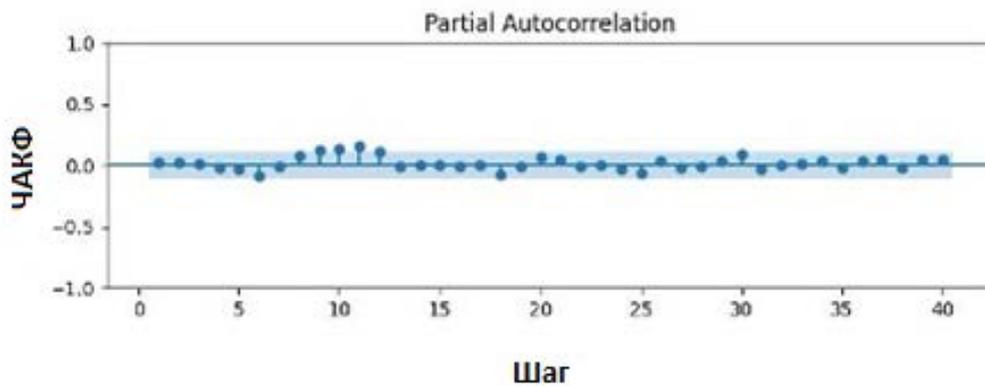


Рисунок 7 – Функция ЧАКФ остатков модели ARIMA(1,2,2)-GARCH(2,0)

На рисунке 8 представлен прогноз будущих значений, для всех исследуемых до этого 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.

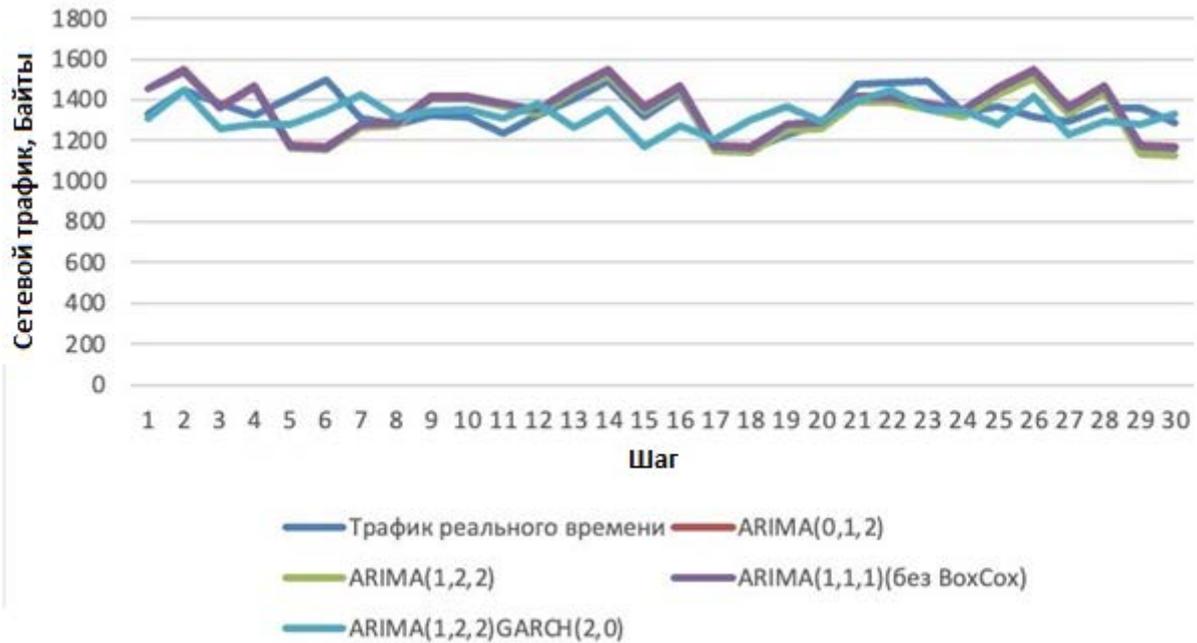


Рисунок 8 – Прогноз моделей ARIMA и гибридной модели ARIMA-GARCH

Для оценки точности прогноза использовалась средняя абсолютная процентная ошибка MAPE, как в формуле (2). Далее на рисунке 9 приведены результаты усредненных оценок, характеризующие качество прогнозной оценки MAPE.

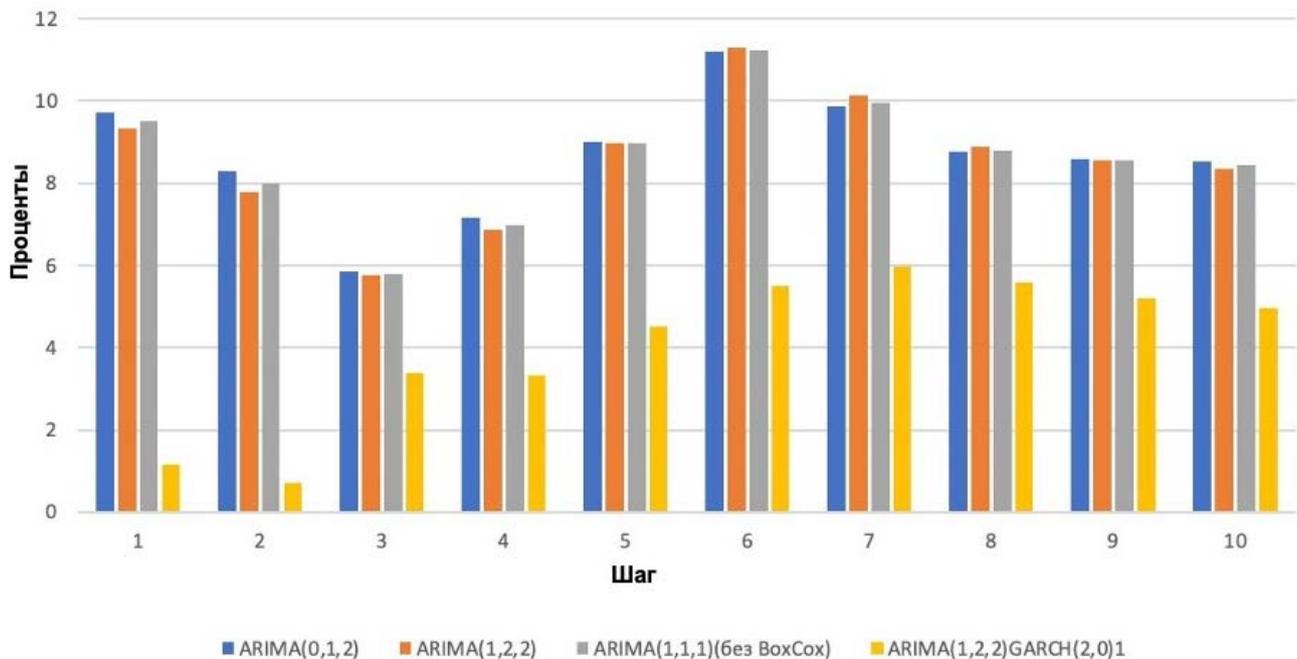


Рисунок 9 – Результаты прогнозной оценки MAPE

Из рисунка 9 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.

В четвертой главе диссертации предложена модель трафика трехмерной сети связи высокой плотности и метод прогнозирования с использованием искусственной нейронной сети.

В трехмерной сети точки доступа распределены в пространстве, например, как это показано на рисунке 10.

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.

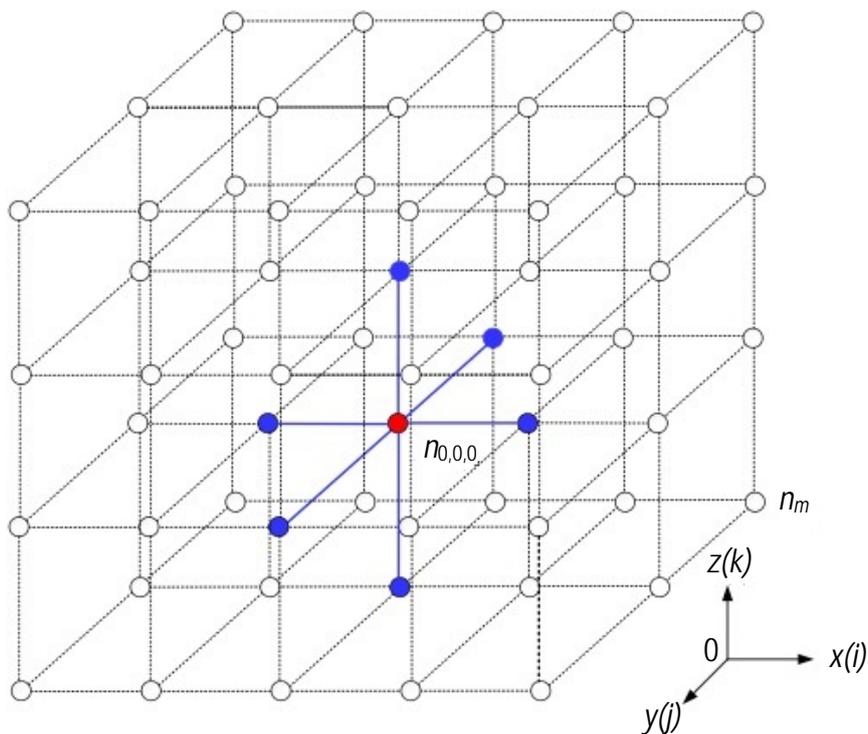


Рисунок 10 – Пример размещения точек доступа сети в пространстве

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

$$X^{(k)} = \{X_1(t), \dots, X_k(t)\}, \quad (6)$$

описываемый совместными функциями распределения:

$$F^{(k)} = \{F_1(x_1, x_2 \dots x_k, t), \dots, F_k(x_1, x_2 \dots x_k, t)\}, \quad (7)$$

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.

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 (6) и его функциями распределения (7).

Процесс прогнозирования трафика в 3D сети высокой плотности был описан последовательностью обработки трафика, как показано на рисунке 11.

Такая последовательность состоит из двух непрерывно повторяющихся фаз: фазы сбора статистических 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.

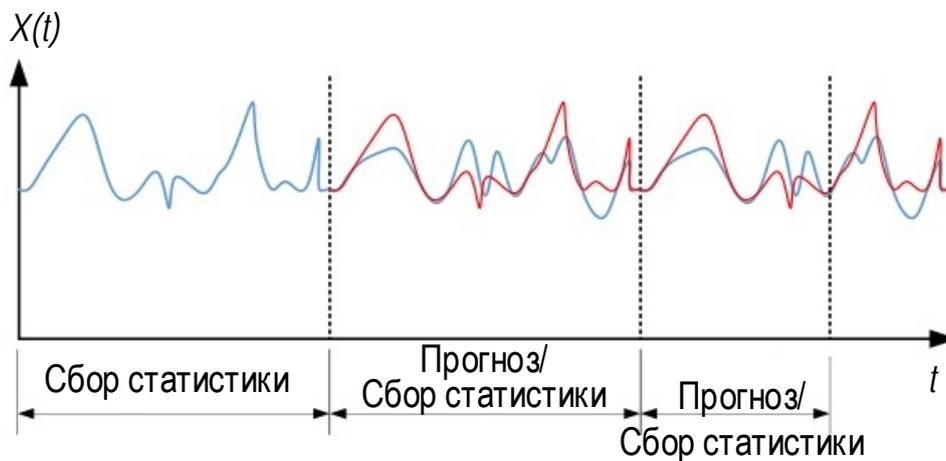


Рисунок 11 – Сбор статистики и прогнозирование

Для оценки эффективности полученного прогноза применялась средняя разница между значениями, спрогнозированными моделью, и фактическими значениями трафика – корень средней квадратичной ошибки (*RMSE*):

$$RMSE_i = \sqrt{\frac{1}{n} \sum_{j=1}^n (x_j^{(i)} - \hat{x}_j^{(i)})^2}, \quad (8)$$

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.

При использовании ИНС, *RMSE* зависит от объема обучающей выборки D_T . Выбор параметров прогнозирования определялся, как задача оптимизации, целевой функцией (%) в которой является:

$$O = \min_{T_t, m} RMSE(T_t, m), \quad (9)$$

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

Для того, чтобы учитывать актуальную ситуацию, обучение ИНС должно производиться непрерывно с учетом требований к продолжительности периода прогнозирования. Соответствующий алгоритм приведен на рисунке 12.

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

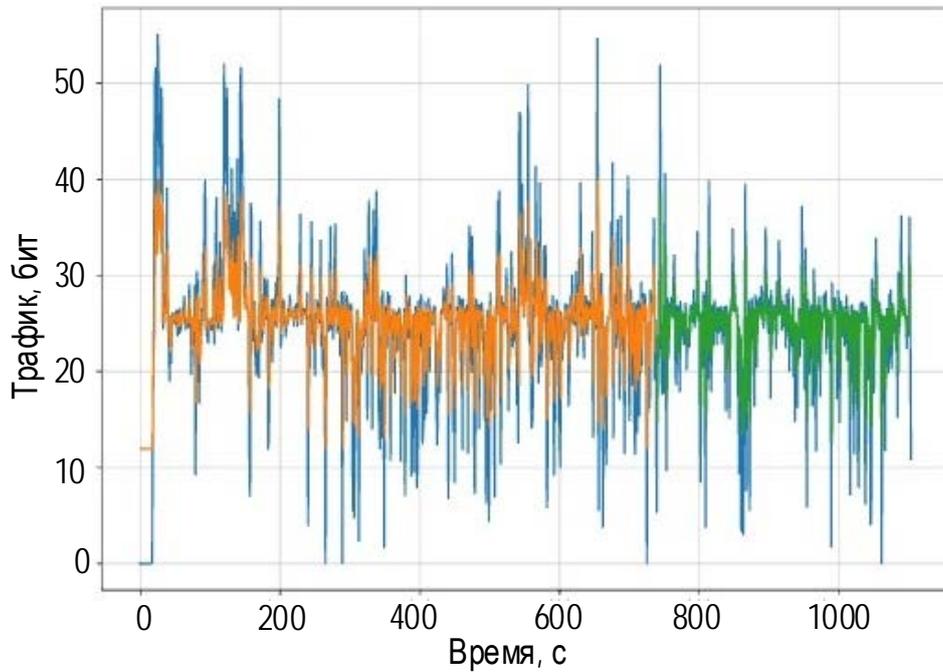


Рисунок 13 – Пример прогнозирования трафика с использованием ИНС типа LSTM:
RMSE = 6,28

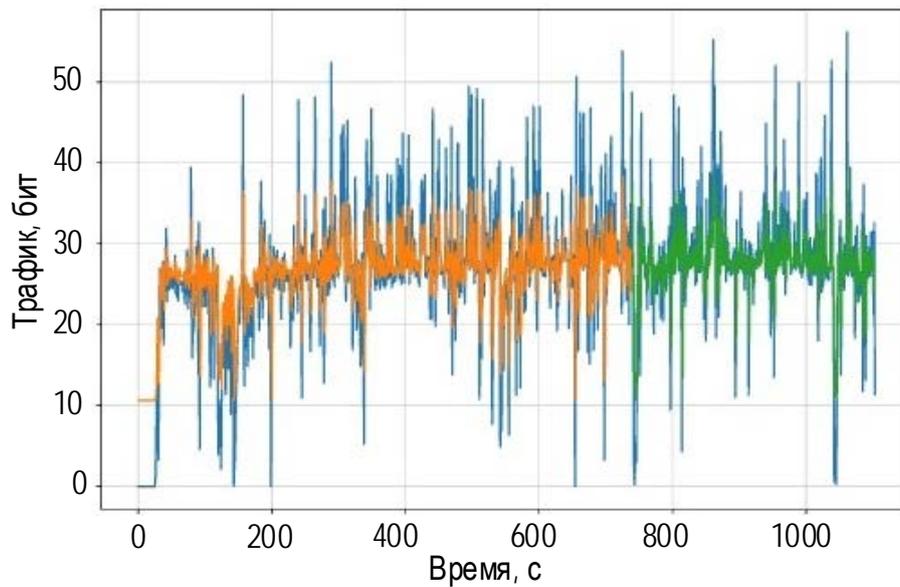


Рисунок 14 – Пример прогнозирования трафика с использованием ИНС типа LSTM:
RMSE = 7,29

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.

Объём 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 11: $RMSE = 6,28$, а на рисунке 12: $RMSE = 7,29$. 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.

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. Таким образом, оценивалось 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. Оценка ошибки прогнозирования производилась с помощью $RMSE$, вычисляемого согласно (8).

Выражение (10) 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 были обозначены как $RMSE_D$ и $RMSE_I$. Эффективность прогнозирования трафика трехмерной сети высокой плотности, как многомерного случайного процесса оценивалась в %, как:

$$E = 100 \frac{RMSE_D - RMSE_I}{RMSE_I}. \quad (10)$$

Значение (10) отражает относительное уменьшение ошибки прогнозирования за счет использования «параллельного» прогнозирования многомерного процесса, по сравнению с прогнозированием независимых случайных процессов. На рисунке 15 приведены результаты оценки эффективности прогнозирования трафика как многомерного процесса.

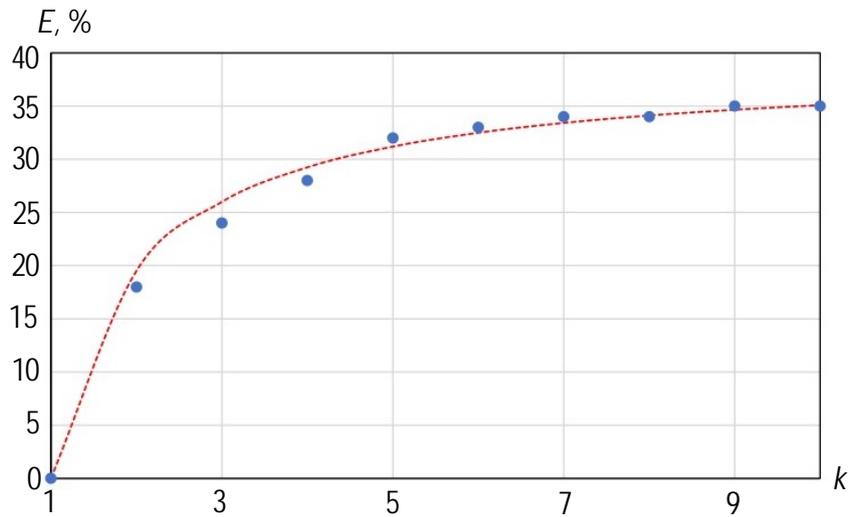


Рисунок 15 – Оценка эффективности прогнозирования трафика как многомерного случайного процесса (k – размерность)

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.

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

В заключении диссертации перечислены основные результаты диссертационной работы, рекомендации и перспективы дальнейшей разработки темы.

ЗАКЛЮЧЕНИЕ

1. Произведен анализ статистических и структурных моделей прогнозирования сетевого трафика гетерогенной сети. Представлены структуры параметрических моделей для прогнозирования сетевого трафика и предложены соответствующие алгоритмы подбора параметров.

2. Разработан метод прогнозирования объема трафика гетерогенной сети пятого и последующих поколений на краткосрочном периоде на основе скользящих средних,

при этом определены порядок авторегрессии и порядок скользящего среднего, что позволило сформировать модель $ARIMA(1,5,4)$ и обеспечить уменьшение средней абсолютной ошибки прогноза более чем в 4 раза по сравнению с использованием исходной модели $ARIMA(1,1,2)$.

3. Разработан алгоритм для прогнозирования трафика реального времени в гетерогенных сетях пятого и последующих поколений на основе гибридной модели авторегрессии и проинтегрированного скользящего среднего и обобщенной условной гетероскедастичностью с преобразованием Бокса-Кокса для краткосрочного прогноза. 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.

4. 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.

5. Предложенная модель трафика трехмерной сети высокой плотности способна учесть взаимное влияние между различными потоками трафика.

6. 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. Таким образом, 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.

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 до 35%. Эффективность прогнозирования предложенным методом зависит от размерности случайного процесса.

8. Разработанные методы позволяют повысить точность прогнозирования сетевого трафика гетерогенной сети с применением как аналитических методов прогнозирования, так и с помощью методов на основе ИНС.

СПИСОК РАБОТ, ОПУБЛИКОВАННЫХ ПО ТЕМЕ ДИССЕРТАЦИИ**Публикации в рецензируемых научных изданиях, рекомендованных ВАК**

1. 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.

2. Гребенщикова, А.А. Модели ARIMA-GARCH для прогнозирования сетевого трафика реального времени / А.А. Гребенщикова // Электросвязь. – 2024. № 8. – С. 8-15.

3. Елагин, В.С. Прогнозирование трафика трехмерной сети интернета вещей высокой плотности как многомерного случайного процесса / В.С. Елагин, А.А. Гребенщикова // Труды учебных заведений связи. – 2024. – Т. 10, № 4. – С. 38-47. – DOI 10.31854/1813-324X-2024-10-4-37-47.

Публикации в других изданиях

4. Гребенщикова, А.А. Обзор модели авторегрессии и проинтегрированного скользящего среднего Arima для прогнозирования сетевого трафика / А.А. Гребенщикова, В.С. Елагин // Актуальные проблемы инфотелекоммуникаций в науке и образовании. X Юбилейная научно-техническая и научно-методическая конференция : сб. науч. ст. в 4-х т. – СПб.: СПбГУТ, 2021. – Т. 1. С. 266-271. – EDN PNYRJJ.

5. 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. XI Международная научно-техническая и научно-методическая конференция : сб. науч. ст. в 4-х т. – СПб.: СПбГУТ, 2021. – Т. 1. С. 370-372. – EDN MXUUVS.