НАУЧНО-ИССЛЕДОВАТЕЛЬСКАЯ РАБОТА

«Разработка рекомендаций по применению технологий искусственного интеллекта для задач анализа и управления трафиком на сетях связи»

Россия
2021

Оглавление

Введение 5

1 Анализ и классификация основных задач по анализу и управлению трафиком на сетях связи, в которых возможно и эффективно применение искусственного интеллекта 7

1.1 Предварительные замечания и определения 7

1.2 Классификация задач анализа и управления трафиком 11

1.3 Задачи анализа 14

1.4 Задачи ограничения трафика 17

1.5 Задачи распределения трафика 19

1.6 Задачи генерации трафика 20

1.7 Возможность применения ИИ в задачах анализа и управления трафиком 21

2 Анализ алгоритмов машинного и глубокого обучения с точки зрения эффективности их применения для задач анализа и управления трафиком 22

2.1 Задачи, решаемые системами ИИ и их классификация 22

2.2 Основные алгоритмы моделей машинного обучения 23

2.2.1 Общие сведения 23

2.2.2 Искусственные нейронные сети 24

2.2.3 Деревья решений 26

2.2.4 Машины опорных векторов 26

2.2.5 Регрессионный анализ 27

2.2.6 Байесовские сети 28

2.2.7 Генетические алгоритмы 28

2.2.8 Тренировочные модели 29

2.2.9 Федеративное обучение 29

2.2.10 Биоинспирированные методы 30

2.2.11 Методы обучения искусственных нейронных сетей..... 31

3 Анализ целесообразности и необходимости использования робастного оценивания в задачах анализа трафика при использовании технологий искусственного интеллекта. 38

3.1 Робастное оценивание 38

3.2 Процедуры робастного оценивания в системах сбора статистики о трафике 39

3.2.1. Винзоризованные оценки..... 39

3.2.2. Усеченные оценки 40

3.2.2. Кусочно-линейная М-оценка Хампеля 41

3.3 Применение методов робастного оценивания при использовании ИИ 42

4 Прогнозы применения технологий искусственного интеллекта до 2025 и 2030 года в виде доли оказываемых услуг пользователям и устройствам с использованием технологий искусственного интеллекта 44

4.1 Методика прогнозирования развития технологий ИИ 44

4.2 Прогноз доли услуг, оказываемых с использованием ИИ в мире 50

4.3 Прогноз доли услуг, оказываемых с использованием ИИ в Российской Федерации 52

5 Прогнозы применения технологий искусственного интеллекта до 2025 и 2030 года в виде доли трафика, обслуживаемого с использованием технологий искусственного интеллекта 55

5.1 Методика прогнозирования 55

5.2 Прогноз доли трафика, оказываемых с использованием ИИ в мире 58

5.3 Прогноз доли трафика, оказываемых с использованием ИИ в Российской Федерации 59

6. Рекомендации по применению технологий искусственного интеллекта для задач анализа и управления трафиком на сетях связи 63

6.1 Анализ рекомендаций Сектора Стандартизации Телекоммуникаций Международного Союза Электросвязи (МСЭ-Т) 63

6.3 Рекомендации по применению технологий искусственного интеллекта для задач анализа и управления трафиком на сетях связи 70

Литература 79

Введение

Задачи анализа и управления трафиком являются составляют основу процессов управления современными сетями связи. Целью решения таких задач является обеспечение баланса между трафиком, качеством предоставления услуг и объемом ресурсов сети. Эти задачи также имеют место и на этапе проектирования сетей, когда требуется обеспечить эффективность технических решений на достаточно продолжительный интервал времени.

Решение этих задач может обеспечиваться различными методами. Качество решения тем выше, чем эффективнее использование ресурсов сети и выше качество обслуживания. Решение этих задач с использованием классических методов не всегда достаточно точно и оперативно, что обусловлено возможными неопределенностями, возникающими или из-за отсутствия точных методов и/или и-за недостатка информации. Эти проблемы решает участие человека (оператора), который восполняет имеющийся недостаток своими опытом и интуицией. В такой системе почти всегда необходимо участия человека в принятии решений.

В сложных системах, где нужно принимать множество решений возникает большой объем достаточно трудоемкой работы, при выполнении которой человек может допускать ошибки по различным причинам. Это приводит к росту трудоемкости и снижению эффективности системы.

В настоящее время возрос интерес к методам (технологиям) искусственного интеллекта (ИИ). Они в ряде случаев позволяют решить задачу, подобно тому, как это делает человек, но при этом они лишены присущих человеку недостатков, например, таких, как усталость и невнимательность. Эти методы, естественно, не являются полной заменой человека, но позволяют существенно повысить эффективность его работы.

В области телекоммуникаций существует множество задач. Для решения которых могут использоваться технологии ИИ, в том числе и задачи анализа и управления трафиком.

В данной работе приведены результаты анализа основных задач по управлению трафиком, для которых возможно применение искусственного интеллекта, анализа алгоритмов машинного и глубокого обучения, анализа целесообразности и необходимости использования робастного оценивания в задачах по трафику при использовании технологий искусственного интеллекта, прогнозы применения технологий искусственного интеллекта в виде доли услуг и доли трафика, рекомендации по применению технологий искусственного интеллекта для задач анализа и управления трафиком в сетях связи.

В работе также приведен анализ рекомендаций рекомендаций Сектора Стандартизации Телекоммуникаций Международного Союза Электросвязи (МСЭ-Т) и даны рекомендации по применению технологий искусственного интеллекта для задач анализа и управления трафиком на сетях связи.

1 Анализ и классификация основных задач по анализу и управлению трафиком на сетях связи, в которых возможно и эффективно применение искусственного интеллекта

1.1 Предварительные замечания и определения

Термин трафик в область телекоммуникаций пришел из области дорожного движения, где он традиционно обозначал движение автомобилей или пешеходов. Ввиду того, что между процессами, происходящими в сетях связи и процессами дорожного движения, существует определенная аналогия, данный термин прочно закрепился в области телекоммуникаций. Не существует четкого определения этого понятия. Обычно, под трафиком в сетях телекоммуникаций понимают процесс поступления некоторых событий (например, заявок или запросов на предоставление услуги). Такими событиями могут быть абонентские телефонные вызовы, запросы абонентов на предоставление услуги, передаваемые сообщения, пакеты данных, кадры или сегменты данных. Конкретный вид события зависит от того, какую сеть и на каком уровне мы рассматриваем.

Целью функционирования сети связи является предоставление услуг, т.е. обслуживание трафика. Функционирование сети описывается показателями качества предоставления услуг [1-4], которые имеют численное выражение и должны удовлетворять определенным критериям, которые являются нормативными и могут быть различны для различных услуг связи.

Для обеспечения и/или поддержания баланса между показателями качества, трафиком и объемом ресурсов сети необходимо решать задачи проектирования и управления на соответствующих этапах жизненного цикла сети связи.

Системы искусственного интеллекта (ИИ), в общем случае, определяются как системы, обладающие свойством выполнять творческие функции, которые считаются способностью человека.

В рамках данной работы будем рассматривать более узкое определение данного понятия, а именно: в смысле исполнения функций по анализу и управлению трафиком, которые выполняют люди.

Как известно, в практике эксплуатации сетей связи операторам связи приходится выполнять множество функций, связанных с мониторингом трафика, статистическим анализом данных и принятием решений по управлению сетью на основе данных о трафике. Для этой цели существуют соответствующие подразделения и специалисты. Как правило, большинство решений принимается специалистами в данной области на основании результатов анализа трафика, возможно, также и каких-либо дополнительных данных, например, аварийной сигнализации, заявок клиентов и т.д. Также, в большинстве случаев, этот процесс в той или иной мере автоматизирован. Автоматизированы наиболее трудоемкие процессы, к которым можно отнести, сбор и предварительную обработку статистических данных. В наименьшей степени, как правило, автоматизированы процессы и функции окончательного анализа данных и принятия решений по управлению сетью.

Последние являются наиболее ответственным этапом управления, поскольку могут привести как к положительным, в случае удачного решения, так и отрицательным результатам, в случае неудачного решения. Решение может оказаться неудачным по многим причинам, например, грубые ошибки исходных данных, влияние неучтенных внешних факторов и др. Человек в такой ситуации способен заметить неточность и предотвратить ее благодаря более широкому кругозору, возможно большей информированности и пониманию способов достижения цели.

Восприятие ситуации человеком и выбор решения также могут иметь и недостатки, по сравнению с автоматизированной системой, объясняемые «человеческим фактором», в качестве которого может выступать, например, необъективная переоценка тех или иных факторов.

Разумный баланс между автоматизированной системой и ролью человека в ней позволяет добиться некоторого удачного сочетания, в

котором принятие решений имеет минимальные риски, а функционирование системы наиболее эффективно.

Функции, выполняемые в данной системе человеком, давно привлекают внимание разработчиков систем принятия решения. Как правило, это системы, способные решать задачи анализа данных на основе наколенного опыта и принимать по результатам анализа «осмысленные» решения. Здесь слово «осмысленные» употреблено с целью показать, что решения подобны тем, которые бы принял человек.

Достоинства такой системы – это отсутствие человеческого фактора (переоценка или недооценка анализируемой информации из-за субъективности восприятия, усталости, отвлекающих факторов, недостатка опыта, невнимательности и т.д.). Человек (оператор) способен следить за ограниченным количеством (единицами) изменяющихся величин (процессов), которыми он управляет, в то время как потребность в управлении может быть гораздо шире. Совершенствование систем автоматического принятия решения способно решить проблемы с недостатками, обусловленными влиянием характерных человеческих качеств.

Безусловно, роль человека в такой системе остается доминирующей, он определяет и оценивает эффективность ее функционирования, но при этом в меньшей степени участвует в принятии частных решений, а может управлять «политиками» принятия решений.

Построение систем анализа данных и принятия решений может решаться различным образов, например, как классической системы автоматического управления [5] и системы обработки и классификации исходных данных с использованием статистических методов [6] из теории управления и статистического анализа. Такая система требует выбора параметров, которые будут всецело определять ее будущее функционирование. Для изменения функционирования такой системы требуется повторная оценка параметров и их изменение. Такая операция

может быть весьма трудоемкой, к тому же управление различными процессами может существенно отличаться, а их взаимные влияния могут привести к весьма сложной задаче, которую далеко не всегда можно решить.

Поэтому, наиболее привлекательными являются обучаемые системы, которые часто называют системами с искусственным интеллектом (ИИ). ИИ в такой системе выполняет, как правило, функции классификации, на основе которых строится система принятия решений. В рамках данной работы, как упоминалось ранее, мы будем рассматривать функциональность, необходимую для решения поставленных задач, а не системы ИИ вообще, функциональность которых может быть значительно шире. Такие системы способны к «обучению», т.е. процесс выбора их параметров в некотором смысле «автоматизирован» и основан на приобретении «опыта». Очень часто для реализации таких систем используют искусственные нейронные сети (ИНС). В целом, ИНС следует рассматривать как один из вариантов построения системы ИИ.

Из литературы известно, что первая работа, относящиеся к ИНС вышла в 1943 г. В этой фундаментальной работе [7] было определено понятие нейронной сети. С этого момента в данной области было выполнено множество работ, которые привели к появлению различных практических приложений, которые весьма эффективно решают задачи распознавания образов (распознавание изображений и звуков), а также управления принятием решений (голосовые меню, боты и т.д.). Следует отметить, что для данной области характерен именно прикладной характер решаемых задач и практические решения, в то время как теоретических моделей функционирования ИНС не так много, а описывают они лишь ограниченный круг вариантов. Это связано со сложностью аналитического представления функционирования ИНС.

Следует отметить, что работы по развитию ИНС до настоящего времени не привели к появлению систем ИИ, подобных интеллекту человека, однако они достаточно эффективно решают ответственные задачи, например,

идентификации при контроле доступа (по лицу, голосу, отпечатку пальцев, роговице глаза и т.д.). Положительный опыт их использования дает основание для возможности их применения и в задачах, связанных с управлением сетями телекоммуникаций.

В дальнейшем, в данной работе под системой ИИ будем понимать, прикладную систему, построенную с использованием ИНС и предназначенную для решения задач анализа и управления в сетях телекоммуникаций.

1.2 Классификация задач анализа и управления трафиком

Обслуживание трафика является целью функционирования сети связи, а мерами функционирования являются качество функционирования, выражаемое набором показателей качества обслуживания QoS и количеством производимой работы, определяемым параметрами трафика (количество вызовов, сообщений, пакетов, бит и возможно других единиц измерения).

При построении и эксплуатации сетей связи решается задача выбора компромисса между тремя основными группами параметров: трафика, качества обслуживания и объемом ресурсов, рисунок 1.1.

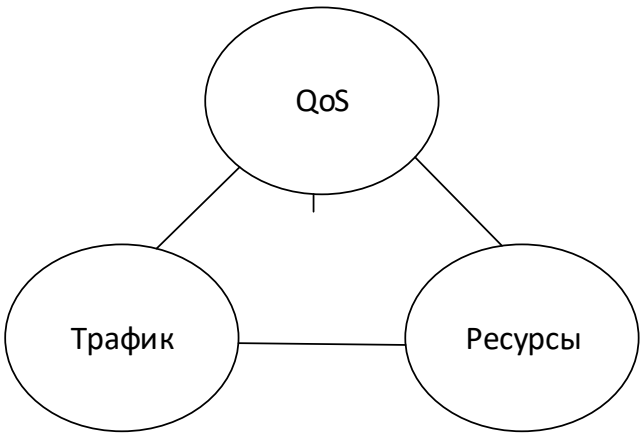

Рисунок 1.1 – Баланс качества, трафика и ресурсов

Обозначим параметры трафика $A = \{a_1, \ldots, a_{ka}\}$, качества обслуживания $Q = \{q_1, \ldots, q_{kq}\}$, ресурсов $V = \{v_1, \ldots, v_{kv}\}$, в общем случае можно записать следующие выражения:

$$Q = f(A,V) \tag{1.1}$$

$$V = g(A,Q) \tag{1.2}$$

$$A = h(Q,V) \tag{1.3}$$

где $f = \{f_1,\dots f_{ka}\}$, $g = \{g_1,\dots g_{kg}\}$ и $h = \{h_1,\dots h_{kh}\}$ – группы некоторых функциональных зависимостей для каждого из выражаемых параметров.

Задачи в области анализа и управления трафиком можно условно классифицировать на три группы: задачи анализа трафика, задачи управления трафиком и задачи генерации трафика, рисунок 1.2.

Задачи анализа трафика включают в себя разнообразные задачи сбора статистических данных и их анализа. Целью могут быть: построение аналитической или имитационной модели трафика, оценка параметров трафика, исследование периодичности или долговременных изменений трафика (тренда).

Задачи управления трафиком включают в себя задачи ограничения трафика с целью предотвращения перегрузок элементов сети, задачи маршрутизации трафика, т.е. распределение трафика по возможным маршрутам доставки данных и задачи модификации трафика.

Рисунок 1.2 – Классификация задач анализа и управления трафиком

Модификация трафика предполагает некоторое воздействие на трафик с целью изменения свойств потока. Такое воздействие, например, может обеспечить получение требуемых свойств потока для приложений, чувствительных к таким свойствам, как изменение разброса задержки доставки данных.

Задачи генерации трафика возникают в случае, например, тестирования производительности оборудования или пропускной способности линий связи. Аналогичные задачи могут возникнуть при построении имитационных моделей, реализуемых в виде компьютерных программ или комбинированных систем моделирования, включающих в себя натурные и имитационные модели.

Задачи моделирования трафика предполагают возможность создания случайного потока с заданными свойствами. Перечень таких свойств может быть различен, набор этих свойств должен быть достаточно широк, чтобы он мог обеспечить получение потока со свойствами, близкими к свойствам

реального потока, либо некоторого критического (предполагаемого) потока, для которого исследуется функционирование сети связи.

Описанные выше задачи являются основными задачами, которые необходимо решать при эксплуатации сети связи.

Более подробно задачи, приведенные в данной классификации, представлены далее.

1.3 Задачи анализа

Кратко сформулировать цель задач анализа трафика можно следующим образом: получение знаний о трафике.

Знания о трафике, могут включать в себя:

1. Модель трафика как случайного потока;

2. Параметры модели трафика, средняя интенсивность трафика (среднее количество заявок в единицу времени), среднее время обслуживания заявки (средние продолжительность сессии, разговора, просмотра видео, прослушивания аудио, передачи пакета, длина пакета и др.);

3. Законы изменения параметров трафика во времени (периодичность трафика, долговременные зависимости изменения – сезонные изменения);

4.Тенденции и прогнозы изменения параметров трафика, как долговременные (месяцы, годы), так и кратковременные (время соизмеримое с продолжительностью обслуживания).

5.Распределение трафика по услугам связи;

7.Распределение трафика по направлениям связи;

8. Информационное содержание трафика.

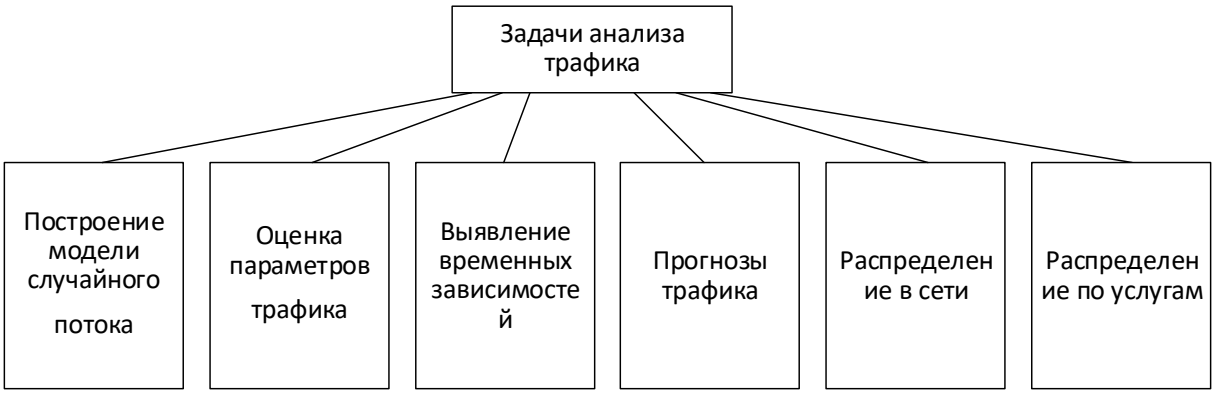

Рисунок 1.3 – Задачи анализа трафика

Обычно, в задачах построения и эксплуатации сетей связи требуются первые 7 пунктов, последний пункт является результатом глубокого анализа трафика и может представлять интерес лишь с точки зрения выполнения некоторых прикладных задач, например, требований государственных органов к хранению передаваемой по сети информации, а также специальных задач, неотносящихся к деятельности операторов связи.

Решение задач анализа трафика включают в себя несколько этапов:

-этап сбора статистических данных;

-предварительная обработка статистических данных;

-статистический анализ;

-применение полученных результатов.

Этап сбора статистических данных включает в себя такие элементы как: разработку плана проведения измерений (сбора статистики), проведение измерений, которое может занимать некоторый интервал времени, либо быть непрерывным, например, в течение всего срока эксплуатации сети связи. В последнем случае непрерывные измерения могут периодически или эпизодически корректироваться для уточнения требований, которые могут изменяться в процессе эксплуатации сети связи.

В плане проведения измерений определяются измеряемые параметры трафика, объекты измерения, вид измерений, время проведения, продолжительность, объем собираемых данных.

Предварительная обработка статистических данных включает в себя входной контроль данных на содержание грубых или иных выявляемых ошибок, например, неполные данные, искажение формата представления, ошибки времени проведения измерений, выход значений за допустимые (возможные) границы и т.д. Следует отметить, что на данном этапе возможны и более сложные процедуры контроля данных, такие как робастные оценки или применение систем ИИ, обучаемых в процессе функционирования системы мониторинга.

Этап статистического анализа включает в себя получение требуемых оценок параметров трафика: средних значений, значений доверительных интервалов, эмпирических гистограмм, аппроксимаций гистограмм аналитическими законами распределений, получение временных зависимостей. Этап статистического анализа является достаточно формальной процедурой, выполняемой с использованием известного математического аппарата, однако выбор параметров для этой процедуры не всегда тривиален. Например, подбор функции распределения, коррекция размера выборки, определение границ значений на гистограмме и др. В решении таких задач чаще всего участвует специалист аналитик. При использовании технологий ИИ имеется возможность частично или полностью переложить данные функции на систему ИИ.

Применение полученных результатов в контексте задач анализа трафика выражается в подготовке соответствующих материалов, пригодных для использования потребителями баз данных, файлов, отчетов, таблиц, графических иллюстраций и др. Полученные результаты могут использоваться в различных целях, например, как исходные данные для выполнения проектных решений по развитию сети связи, как данные о параметрах трафика для систем эксплуатации сетевого оборудования, как данные для получения прогнозов на различные интервалы времени и т.д.

Следует отметить, что для решения текущих и перспективных задач операторам связи целесообразно иметь непрерывно пополняемую и

обновляемую базу данных параметров трафика. Ее наличие дает возможность оперативного получения нужной статистической информации за различные периоды времени, что позволяет благодаря надежности исходных данных повысить эффективность решения задач проектирования и эксплуатации.

1.4 Задачи ограничения трафика

Задачи ограничения трафика относятся к классу задач управления. Ограничение трафика предполагает использование дисциплины обслуживания с отказами, при этом некоторая доля трафика может быть потеряна. В случае неконтролируемых потерь потерянным может быть любой трафик независимо от его содержания и направления передачи. Потери наступают тогда, когда полностью заполнен буфер узла связи, в таком случае поступивший пакет данных стирается (отбрасывается). Временной интервал, в течение которого входной буфер заполнен, а все поступающие пакеты теряются, называется режимом перегрузки. Такой режим нежелателен для систем связи, так как он приводит к снижению качества обслуживания, причем это снижение не контролируемо и может привести к полному отказу в предоставлении услуги.

Искусственное ограничение трафика создается намеренным стиранием некоторых пакетов, что также приводит к потерям и снижению качества обслуживания, однако, управление потерями дает возможность не прерывать полностью оказание услуги. Например, при обслуживании нескольких потоков передачи речи, неуправляемые потери могут привести к отказу в услуге из-за высоких потерь в одном из них, но если потери распределены равномерно между всеми потоками, то отказа не произойдет, а произойдет пропорциональное снижение качества для всех потоков.

Для реализации такого способа ограничения трафика требуется возможность идентификации потоков или приоритетов трафика. При

наличии приоритетов управляемое ограничение трафика позволяет исключить или снизить влияние трафика более низкого приоритета на трафик более высокого приоритета путем организации нескольких буферов или использования одного буфера с приоритетным обслуживанием. В таком случае ограничение трафика может быть реализовано дифференцированно для каждого из приоритетов.

Ограничение (управляемые потери) трафика могут быть реализованы, например, методом, аналогичным call-gapping [8]. Этот метод предполагает «прореживание» потока, после приема некоторой заявки на обслуживания все заявки в течение определенного интервала времени отбрасываются (возможны и модификации данного алгоритма).

Любой из методов ограничения трафика влияет на его интенсивность, так, что результирующая интенсивность трафика определяется как

$$\lambda = \lambda_0(1-p) \qquad (1.4)$$

где λ_0 – интенсивность исходного потока трафика, λ - интенсивность результирующего потока, $0 \le p \le 1$ - доля отбрасываемых заявок.

Благодаря снижению интенсивности заявок происходит повышение качества обслуживания заявок результирующего потока.

При использовании подобных методов ограничения трафика определенную сложность представляет выбор отбрасываемых пакетов. Как было отмечено выше, при этом необходимо учитывать принадлежность пакета определенному потоку, его приоритет, вид услуги. Получить все эти данные не всегда возможно, поэтому в данной задаче представляет интерес решение задачи классификации, т.е. определения класса, к которому относится очередной пакет, а каждый из классов определяется одним или несколькими из перечисленных признаков. Эти задачи как раз и могут решаться с помощью систем ИИ.

1.5 Задачи распределения трафика

Задачи распределения трафика выполняют свои функции на сетевом уровне. Эти задачи наиболее интересны и привлекательны в сетях со сложной топологией, где возможно множество маршрутов доставки данных. Вероятно, перспективные сети связи, включающие в себя сверхплотные сети ИВ и ТИ, базирующиеся на технологии SDN являются именно такими объектами. Распределение трафика в сети предполагает задачу выбора маршрута доставки данных между отправителем и получателем.

При моделировании сети графом, для решения данной задачи используют известные из теории графов [9] алгоритмы и методы поиска маршрутов по заданному критерию. Однако, для известные алгоритмы поиска путей дают частные оптимальные решения, т.е. для конкретного случая, в то время как задача управления сетью предполагает эффективное (оптимальное) использование ресурса сети.

От маршрутизации трафика в сети зависит качество обслуживания и использование ресурсов. Проблема состоит в том, что вариантов маршрутизации трафика в подобной сети может быть чрезвычайно много, что приводит к невозможности получения точного решения. Существуют эмпирические методы получения приближенных решений для распределения трафика в сети [10], которые дают не самые плохие решения, но не гарантируют оптимального решения.

Данная задача в наибольшей степени интересна с точки зрения использования систем ИИ. Для ее решения требуется достаточно большой объем исходных данных (состояние сети), к тому же для ее эффективного решения требуется опираться не только на текущее состояние, но и на его прогнозируемые значения.

1.6 Задачи генерации трафика

Задачи генерации трафика связаны с необходимостью тестирования сетей связи или их отдельных элементов. Генерация трафика предполагает некоторую техническую реализацию устройств (программную, аппаратную или комбинированную) которые обеспечивают формирование искусственного потока заявок (пакетов), свойства которого можно изменять в зависимости от требований задачи.

Генерируемый поток пакетов должен обладать заданными свойствами, например, быть максимально схожим с потоками, имеющими место в сети связи или напротив, иметь некоторую специфику, для которой проводится эксперимент.

Для описания потоков в современных сетях связи используют теорию вероятностей и торию массового обслуживания. Определяя в качестве основных свойств: распределение вероятности интервалов времени между пакетами и размеров пакетов, а также свойства, характеризующие пачечность потока и некоторые другие (свойства самоподобия [11]).

Достаточно сложно учесть все эти свойства в одной математической модели, которая бы была в основе процесса генерации. Однако, на практике существует возможность получить поток подобный наблюдаемому (близкий по свойствам) имея только эмпирические данные. Такая возможность особенно привлекательна с использованием систем ИИ, которые способны накапливать опыт на основе наблюдений за реальным трафиком в течении длительного времени.

Задачи генерации трафика могут решаться как на натурных моделях, т.е. в действующей сети связи, так и в рамках имитационных моделей в виде программного обеспечения имитирующего такую сеть. В той и другой форме первом и втором виде эти задачи будут востребованы.

1.7 Возможность применения ИИ в задачах анализа и управления трафиком

Рассмотрев основные задачи анализа и управления трафиком в сетях телекоммуникаций и подходы к их решению можно обобщить степень целесообразности применения систем ИИ. В таблице 1.1 приведены обобщенные данные и результаты экспертной оценки применимости систем ИИ в соответствующем круге задач.

Таблица 1.1 – Степень применимость систем ИИ при решении задач

N	Задача	Степень применимость ИИ (0-5)
1	Анализ трафика	5
2	Ограничение трафика	3
3	Распределение трафика	5
4	Генерация трафика	4

В таблице приведена балльная оценка применимости систем ИИ для решения определенного круга задач. Как видно из экспертных оценок, все рассмотренные задачи могут решаться с применением ИИ. При этом, в наибольшей степени системы ИИ применимы в задачах анализа и распределения трафика.

2 Анализ алгоритмов машинного и глубокого обучения с точки зрения эффективности их применения для задач анализа и управления трафиком

2.1 Задачи, решаемые системами ИИ и их классификация

Задачи, решаемые с помощью систем ИИ, рассматриваемых в данной работе можно условно классифицировать следующим образом.

-Задачи классификации – это наиболее востребованный класс задач, при использовании ИИ. Решение задачи заключается в получении ответа о принадлежности к определенному классу на основе на основе набора признаков (в технологиях ИИ описывается как обучение с учителем).

-Задачи регрессии – это задачи прогнозирования на основе выборки некоторых исходных (чаще всего статистических) данных. Решением является вещественное число, представляющее собой прогнозируемое значение некоторого признака.

-Задачи кластеризации – распределение данных на группы по некоторым признакам (в технологиях ИИ описывается как обучение без учителя).

-Задачи понижения размерности – сведение исходного количества признаков к меньшему количеству.

-Задачи выявления выбросов – выделение данных, отличающихся от нормальных случаев. Задача схожа с задачей классификации, разница заключается в малом объеме обучающих данных, содержащих выбросы (аномальные значения).

Классификация видов машинного обучения

В общем случае методы обучения систем ИИ можно разделить на два класса: обучение с учителем и обучение без учителя.

Обучение с учителем предполагает наличие ряда гипотез, которые нужно подтвердить или опровергнуть. Например, имеет ли место аварийное

состояние сети или нет; требуется выбрать определенный маршрут из заданного набора маршрутов и т.д.

Обучение без учителя предполагает решение задачи без наличия заданных гипотез, например, требуется разделить имеющиеся объекты по некоторым признакам на группы: разделить заданное количество потоков трафика на группы по признаку интенсивности трафика или размеру пакета, или интервалам времени между пакетами, или по комбинации признаков.

2.2 Основные алгоритмы моделей машинного обучения

2.2.1 Общие сведения

Алгоритмы машинного обучения — это процедуры, которые помогают исследовать и анализировать наборы исходных данных и находить в них определенный смысл. Процедура — это набор шагов, представляющих однозначные инструкции, которые могут выполняться в виде программы для вычислительного устройства. Цель машинного обучения заключается в обнаружении некоторой закономерности, с помощью которой можно решать задачи прогнозирования или классификации.

В алгоритмах машинного обучения используются входные данные – параметры.

В различных алгоритмах применяются разные способы анализа данных. Они часто группируются по методам машинного обучения, в рамках которых используются: контролируемое обучение, неконтролируемое обучение и обучение с подкреплением. В наиболее популярных алгоритмах для прогнозирования целевых категорий, поиска необычных точек данных, прогнозирования значений и обнаружения сходства используются регрессия и классификация.

Модели

Процесс машинного обучения включает в себя создание модели, которая обучается на некоторых обучающих данных, а затем может

обрабатывать дополнительные данные, например, для прогнозирования. Для систем машинного обучения использовались и исследовались различные типы моделей.

2.2.2 Искусственные нейронные сети

Искусственная нейронная сеть - это взаимосвязанная группа узлов, подобная обширной сети нейронов в головном мозге. Здесь каждый круговой узел представляет собой искусственный нейрон, а стрелка представляет собой соединение между выходом одного искусственного нейрона и входом другого.

Искусственные нейронные сети (ИНС) - это модель, основанная на наборе связанных блоков или узлов, называемых «искусственными нейронами», которые в общих чертах моделируют нейроны в биологическом мозге. Каждое соединение, как синапсы в биологическом мозге, может передавать информацию, «сигнал», от одного искусственного нейрона к другому. Искусственный нейрон, который получает сигнал, может обработать его, а затем передать сигнал дополнительным искусственным нейронам, подключенным к нему. В обычных реализациях ИНС сигнал в соединении между искусственными нейронами является действительным числом, а выходной сигнал каждого искусственного нейрона вычисляется некоторой нелинейной функцией суммы его входных сигналов. Связи между искусственными нейронами называются «ребрами». Искусственные нейроны и ребра обычно имеют вес, который корректируется по мере обучения. Вес увеличивает или уменьшает силу сигнала в соединении. Искусственные нейроны могут иметь такой порог, что сигнал отправляется только в том случае, если совокупный сигнал пересекает этот порог. Обычно искусственные нейроны объединены в слои. Разные слои могут выполнять разные виды преобразований на своих входах. Сигналы проходят от первого

слоя (входной) к последнему (выходному), возможно, после многократного прохождения слоев.

Первоначальная цель подхода ИНС заключалась в том, чтобы решать проблемы так же, как это делает человеческий мозг. Однако со временем внимание переключилось на выполнение конкретных задач, что привело к отклонениям от биологии. Искусственные нейронные сети использовались для решения множества задач, включая компьютерное зрение, распознавание речи, машинный перевод, фильтрацию социальных сетей, настольные игры и видеоигры, а также медицинскую диагностику.

Глубокое обучение состоит из нескольких скрытых слоев в искусственной нейронной сети. Этот подход пытается смоделировать то, как человеческий мозг преобразовывает свет и звук в зрение и слух. Некоторыми успешными приложениями глубокого обучения являются компьютерное зрение и распознавание речи.

Например, ИНС с долговременной краткосрочной памятью LSTM (Long Short-Term Memory) - разновидность архитектуры рекуррентных нейронных сетей. В отличие от традиционных рекуррентных нейронных сетей LSTM-сеть хорошо приспособлена к обучению на задачах классификации, обработки и прогнозирования временных рядов в случаях, когда важные события разделены во времени интервалами с неопределённой продолжительностью и границами. Относительная невосприимчивость к длительности временных разрывов дает LSTM преимущество по отношению к альтернативным рекуррентным нейронным сетям, скрытым марковским моделям и другим методам обучения для последовательностей в различных сферах применения. Сети LSTM показывают хорошие результаты в распознавании рукописного текста, в задачах распознавания речи, а также для серей Интернета вещей.

2.2.3 Деревья решений

При обучении этим методом дерево решений используется в качестве модели прогнозирования для перехода от наблюдений за элементом (представленном в ветвях) к выводам о целевом значении элемента (представленному в листьях). Это один из подходов к прогнозному моделированию, используемых в статистике, интеллектуальном анализе данных и машинном обучении. Модели деревьев, в которых целевая переменная может принимать дискретный набор значений, называются деревьями классификации; в этих древовидных структурах листья представляют метки классов, а ветви представляют соединения функций, которые ведут к этим меткам классов. Деревья решений, в которых целевая переменная может принимать непрерывные значения (обычно действительные числа), называются деревьями регрессии. При анализе решений дерево решений может использоваться для визуального и явного представления решений и принятия решений. При интеллектуальном анализе данных дерево решений описывает данные, но результирующее дерево классификации может быть входом для принятия решения.

2.2.4 Машины опорных векторов

Машины опорных векторов SVM (Support Vector Machine), также известные как сети опорных векторов, представляют собой набор связанных контролируемых методов обучения, используемых для классификации и регрессии. Имея набор обучающих примеров, каждый из которых помечен как принадлежащий к одной из двух категорий, обучающий алгоритм SVM строит модель, которая предсказывает, попадает ли новый пример в ту или иную категорию. Алгоритм обучения SVM - это не вероятностный двоичный линейный классификатор, хотя существуют такие методы, как

масштабирование Платта для использования SVM в настройке вероятностной классификации. Помимо выполнения линейной классификации, SVM могут эффективно выполнять нелинейную классификацию, используя так называемый трюк с ядром, неявно отображая свои входные данные в пространственных объектах большой размерности.

2.2.5 Регрессионный анализ

Регрессионный анализ включает в себя большое количество статистических методов для оценки взаимосвязи между входными переменными и связанными с ними характеристиками. Наиболее распространенной формой является линейная регрессия, когда определяется одна линия, которая наилучшим образом соответствует заданным данным в соответствии с математическим критерием, таким как обычный метод наименьших квадратов. Последний часто расширяется с помощью методов регуляризации для смягчения переобучения и систематической ошибки, как в случае регрессии гребня. При решении нелинейных задач модели перехода включают полиномиальную регрессию (например, используемую для подбора линии тренда в Microsoft Excel), логистическую регрессию (часто используемую в статистической классификации) или даже ядерную регрессию, которая вводит нелинейность, используя трюк с ядром для неявного отображения входных переменных в многомерное пространство.

Весьма полезная нелинейная авторегресионная рекуррентная нейронная сеть с внешними входами NARX (Nonlinear AutoRegressive eXogenous) в моделировании временных рядов представляет собой нелинейную авторегрессионную модель, которая получает внешние входные данные, независимые от самой модели. Эффективно применяется в задачах краткосрочного и долгосрочного прогнозирования.

2.2.6 Байесовские сети

Байесовская сеть, сеть убеждений или направленная ациклическая графическая модель - это вероятностная графическая модель, которая представляет набор случайных величин и их условную независимость с направленным ациклическим графом DAG (Directed Acyclic Graph). Например, байесовская сеть может представлять вероятностные отношения между болезнями и симптомами. Учитывая симптомы, сеть может использоваться для вычисления вероятности наличия различных заболеваний. Существуют эффективные алгоритмы, выполняющие вывод и обучение. Байесовские сети, моделирующие последовательности переменных, таких как речевые сигналы или белковые последовательности, называются динамическими байесовскими сетями. Обобщения байесовских сетей, которые могут представлять и решать проблемы принятия решений в условиях неопределенности, называются диаграммами влияния.

2.2.7 Генетические алгоритмы

Генетический алгоритм - это алгоритм поиска и эвристический метод, который имитирует процесс естественного отбора, используя такие методы, как мутация и кроссовер, для создания новых генотипов в надежде найти хорошие решения данной проблемы. В машинном обучении генетические алгоритмы использовались в 1980-х и 1990-х годах. И наоборот, методы машинного обучения использовались для повышения производительности генетических и эволюционных алгоритмов.

2.2.8 Тренировочные модели

Обычно для хорошей работы модели машинного обучения требуют большого количества данных. Поэтому, при обучении модели машинного обучения необходимо собрать большую репрезентативную выборку данных из обучающей выборки. Данные из обучающего набора могут быть такими же разнообразными, как текст, набор изображений и данные, собранные от отдельных пользователей службы. При обучении модели машинного обучения следует остерегаться переобучения. Обученные модели, полученные на основе предвзятых данных, могут приводить к искаженным или нежелательным прогнозам. Алгоритмическая ошибка - это потенциальный результат не полностью подготовленных данных для обучения.

2.2.9 Федеративное обучение

Федеративное обучение - это адаптированная форма распределенного искусственного интеллекта для обучения моделей машинного обучения, которая децентрализует процесс обучения, позволяя сохранять конфиденциальность пользователей, не отправляя их данные на централизованный сервер. Федеративное обучение также увеличивает эффективность за счет децентрализации процесса обучения на многих устройствах. Например, Gboard использует федеративное машинное обучение для обучения моделей прогнозирования поисковых запросов на мобильных телефонах пользователей без необходимости отправлять отдельные поисковые запросы обратно в Google.

2.2.10 Биоинспирированные методы

К методам машинного обучения часто относят методы решающие различные задачи, обычно задачи оптимизации, имитируя некоторые процессы, происходящие в живой природе – биоинспирированные методы, подобно упомянутому выше генетическом алгоритму.

Наиболее популярны методы роевого интеллекта. Приведем наиболее популярные из них.

Метод роя частиц (Particle Swarm Optimization, PSO) — метод численной оптимизации, для использования которого не требуется точное значение градиента целевой функции.

Муравьиный алгоритм (ant colony optimization, ACO) – это метод решающий задачу выбора оптимального (кратчайшего пути или гамильтонова цикла в графе) решения имитируя поведение муравьиной колонии. Алгоритм имитирует поведение в результате которого муравьям удается найти кратчайший маршрут между муравейником и объектом, вызвавшим интерес. Данный метод позволяет, например, получить приближенное решение задачи коммивояжера.

Пчелиный алгоритм (Artificial bee colony algorithm ABC). ABC - имитирует поведение медоносных пчел. Алгоритм состоит из трех этапов: рабочей пчелы, пчелы-надзирателя, и пчелы-разведчика. Алгоритм имитирует поведение нескольких видов пчел, которые выполняют определенные функции в процесс сбора меда. Алгоритм применим при решении задач оптимизации невыпуклых функций.

Метод стаи серых волков (Grey Wolf Optimizer GWO) – метод решения задачи оптимизации, путем имитации поведения стаи волков во время охоты. В качестве жертвы рассматривается некоторое оптимальное значение. Алгоритм применим при оптимизации невыпуклых функций.

Метод роя сальп (Salp Swarm Algorithm SSA) – основан на имитации поведения колонии малых морских организмов – сальп, обитающих

большими колониями и способных демонстрировать рациональное поведение колонии несмотря на примитивность каждого из организмов в отдельности. Данный алгоритм также является алгоритмом оптимизации.

Существуют и другие методы: алгоритм летучих мышей, алгоритм капель воды, стохастический диффузионный поиск, многороевая оптимизация и ряд других.

Все приведенные выше методы имеют некоторое общие принципы, которые состоят в том, что они производят случайный поиск, но характер поведения (метод поиска) определяется некоторым неслучайным алгоритмом, имитирующим тот или иной природный процесс.

Авторы разработали эти методы, взяв за прототип процессы, происходящие в природе, которые демонстрируют практические решения сложных аналитических задач. Эти методы имеют различную эффективность при решении различных задач, поэтому для выбора должно производиться исследование среди известных методов на предмет их эффективности для решения конкретной задачи.

2.2.11 Методы обучения искусственных нейронных сетей

Рассмотренные выше модели и методы машинного обучения могут иметь широкий круг применений в различных задачах анализа и управления. При использовании ИНС возникает задача, связанная с обучением нейронной сети. В данном смысле это более узкая задача, которая направлена на обеспечение функционирования ИНС. Для ее решения также могут использоваться различные методы, в том числе и рассмотренные выше.

Среди всех существующих методов обучения можно выделить два класса: детерминированные и стохастические.

Детерминированный метод итеративно корректирует параметры сети, основываясь на ее текущих параметрах, величинах входов, фактических и

желаемых выходов. Яркой иллюстрацией подобного метода является метод обратного распространения ошибки.

Стохастические методы обучения изменяют параметры сети случайным образом. При этом сохраняются только те изменения, которые привели к улучшениям.

Обучение с учителем. Алгоритм называется алгоритмом обучения с учителем, если во время обучения сеть располагает правильными ответами (выходами сети) на каждый входной пример, то есть заранее задается множество пар векторов. В процессе обучения сеть меняет свои параметры таким образом, чтобы давать нужное отображение.

Обучение без учителя. Алгоритм обучения без учителя может применяться тогда, когда известны только входные сигналы. На их основе сеть учится давать наилучшие значения выходов. Понятие «наилучшее значение» определяется алгоритмом обучения. Обычно алгоритм подстраивает параметры так, чтобы сеть выдавала одинаковые результаты для достаточно близких входных значений.

Метод Хэбба. Самым старым обучающим правилом является постулат обучения Хэбба. Хэбб выдвинул гипотезу о том, как обучаются биологические нейроны. Он предположил, что вес соединения между двумя нейронами усиливается, если оба эти нейрона возбуждены. Хэбб опирался на следующие нейрофизиологическне наблюдения: если связанные между собой нейроны активизируются одновременно и регулярно, то сила связи возрастает. Важной особенностью этого правила является то, что изменение веса связи зависит только от активности нейронов, которые соединены данной связью.

Правило коррекции по ошибке. Даная модель разработана Фрэнком Розенблаттом. Модель использует алгоритм обучения с учителем, то есть обучающее множество состоит из множества входных векторов, для каждого из которых указан выходной вектор. Несмотря на некоторые ограничения, она стала основой для многих современных наиболее сложных алгоритмов

обучения с учителем. Суть алгоритма состоит в том, что для каждого входного примера задается желаемый выходной вектор. Если реальный выходной вектор сети не совпадает с желаемым, то параметры сети будут скорректированы. Для вычисления величины коррекции используется разница между реальным и желаемым выходами сети, причем коррекция весов будет происходить только в случае ошибочного ответа.

Обучение методом соревнования. В отличие от обучения Хэбба, в котором множество выходных нейронов могут возбуждаться одновременно, при соревновательном обучении выходные нейроны соревнуются между собой за активизацию. То есть, из всего множества выходных нейронов используется только один нейрон с самым большим выходом. Такой алгоритм напоминает процесс обучения биологических нейронных сетей. Обучение методом соревнования позволяет классифицировать входные данные: похожие примеры группируются сетью в один класс и представляются одним образцовым элементом. При этом каждый нейрон из множества выходных нейронов «отвечает» только за один класс.

Метод обратного распространения ошибки (Backpropagation) — метод вычисления градиента, который используется при обновлении весов многослойного перцептрона. Это итеративный градиентный алгоритм, который используется с целью минимизации ошибки работы многослойного перцептрона и получения желаемого выхода. С этой целью может использоваться, например, метод Флетчера-Ривса (метод сопряженных градиентов) или метод Левенберга — Марквардта (комбинация метода Ньютона и метода градиентного спуска). Идея этого метода состоит в распространении сигналов ошибки от выходов сети к её входам, в направлении обратном прямому распространению сигналов в обычном режиме работы.

Для возможности применения метода обратного распространения ошибки передаточная функция нейронов должна быть дифференцируема. Метод является изменением классического метода градиентного спуска.

Метод коррекции с обратной передачей сигнала ошибки - стохастический метод обучения персептрона, необходимый, чтобы гарантировать сходимость при переменных связях больше чем у одного слоя. Метод был предложен Розенблаттом для перцептрона с переменными S-A связями и может быть использован для бинарных многослойных перцептронов. Является альтернативой методу обратного распространения ошибки, но в отличие от него гарантирует процесс сходимости (достижение решения).

2.2.12. Примеры использования машинного и глубокого обучения для прогнозирования задержки и пропускной способности.

Прогнозирование задержки в сетях связи пятого поколения является одной из важнейших задач для обеспечения требуемых параметров по качеству обслуживания и качеству восприятия. Действительно, в целом ряде приложений задержка не должна превышать единицы миллисекунд, поэтому краткосрочный прогноз значения задержки в условиях колебания трафика очень важен.

В работах [31,32] для решения этой задачи было предложено использовать машинное обучение и следующие нейронную сеть и алгоритмы обучения:

- Нелинейная авторегресионная рекуррентная нейронная сеть с внешними входами NARX,
- Trainlm (Алгоритм Левенберга-Марквардта с обратным распространением),
- Trainrp (Устойчивый алгоритм обучения нейронной сети с обратным распространением),
- Traincgf (Алгоритм сопряженных градиентов Флетчера-Ривса для обучения нейронной сети с обратным распространением и обновлениями).

Для сравнения эффективности и выбора того или иного алгоритма обучения использовались значения корня из среднеквадратичной ошибки

RMSE (Root Mean Square Error) и средней абсолютной ошибки в процентах MAPE (Mean Absolute Percent Error).

Результаты моделирования представлены в таблице 2.1. При этом использовалось как прогнозирование на один шаг вперед, так и на несколько шагов вперед.

Таблица 2.1. Сравнение эффективности алгоритмов обучения при прогнозировании задержки.

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

Как видим, для прогнозирования задержек высокую эффективность по точности имеют нелинейные рекуррентнтные сети NARX и алгоритм обучения Левенберга-Марквардта с обратным распространением.

Прогнозирование трафика Интернета Вещей представляет собой также одну из важнейших задач для обеспечения требуемого качества обслуживания и качества восприятия, поскольку Интернет Вещей привносит в сети связи свойства высокой и сверх высокой плотности сетей [33,34]. В работах для прогнозирования трафика Интернета Вещей в сетях связи пятого поколения [35,36] применялось глубокое обучение DL (Deep Learning) с использованием нейронной сети долговременной краткосрочной памяти LSTM (Long Short-Term Memory). При этом число скрытых нейронов составляло: 50, 200, 500. На рис.2.1, 2.2 и 2.3 приведены результаты моделирования из [35,36] для всех исследуемых значений скрытых нейронов.

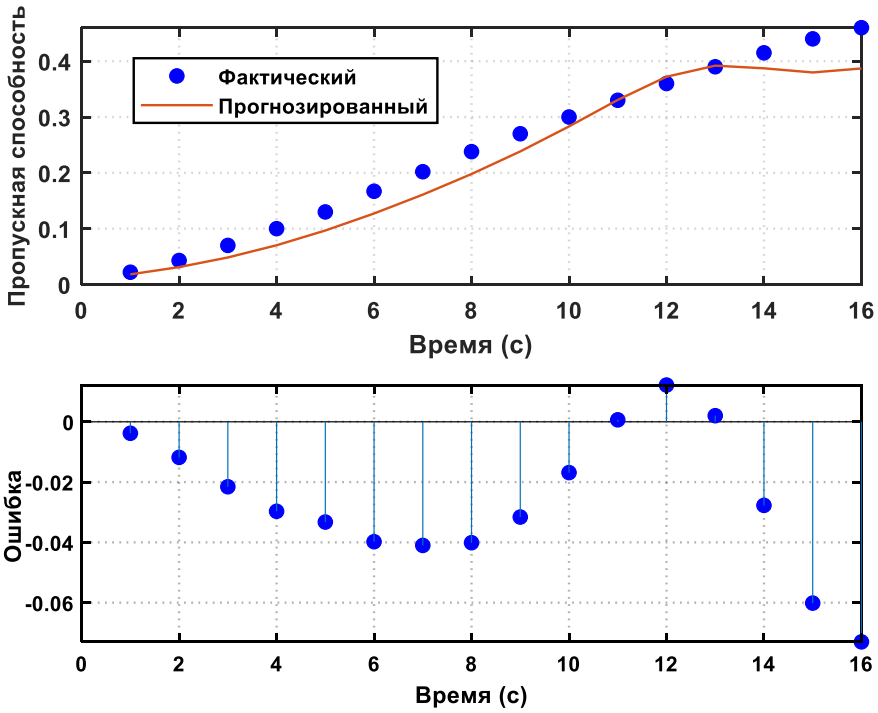

Рис.2.1. Прогнозируемая и фактическая пропускная способность и RMSE при 500 скрытых нейронов в слое LSTM.

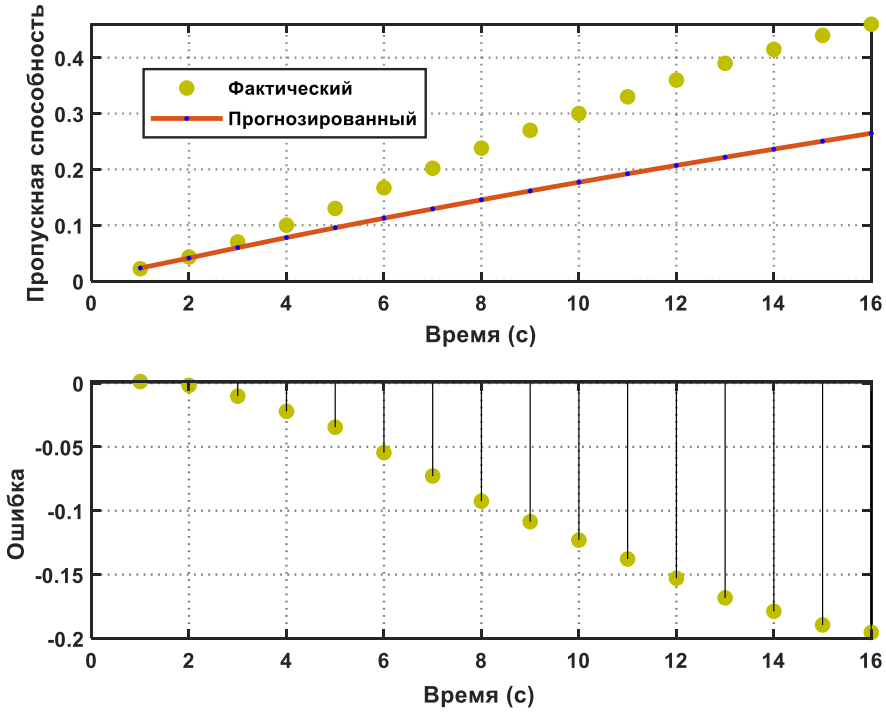

Рис.2.2. Прогнозируемая и фактическая пропускная способность и RMSE при 200 скрытых нейронов в слое LSTM.

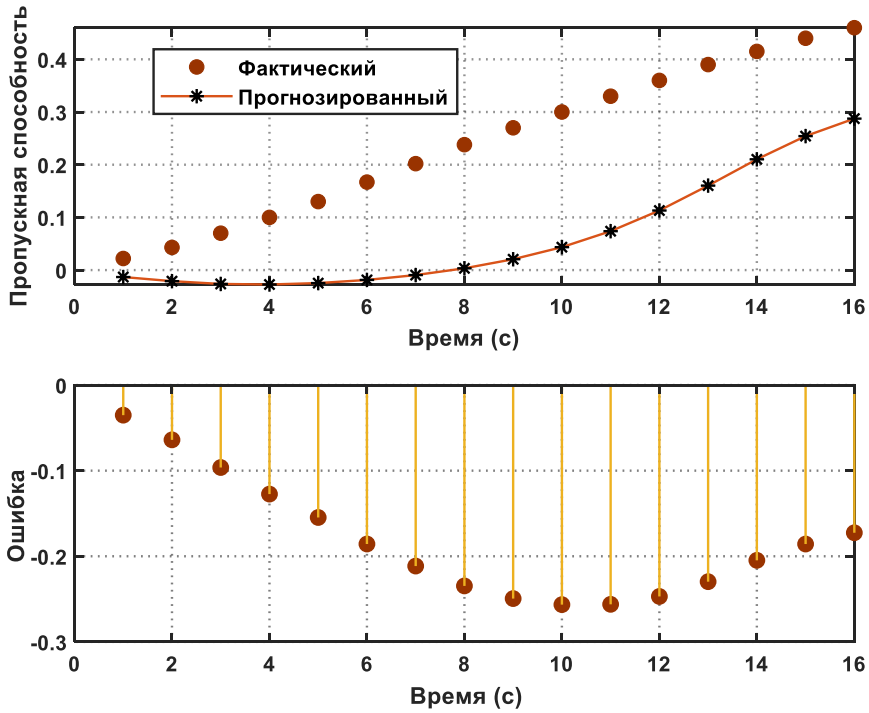

Рис.2.3. Прогнозируемая и фактическая пропускная способность и RMSE при 50 скрытых нейронов в слое LSTM

Как видим, использование нейронной сети долговременной краткосрочной памяти LSTM при числе скрытых нейронов 500 позволяет прогнозировать пропускную способность с достаточной для практических условий точностью.

3 Анализ целесообразности и необходимости использования робастного оценивания в задачах анализа трафика при использовании технологий искусственного интеллекта.

3.1 Робастное оценивание

В процессе наблюдений (измерений, мониторинга трафика и качества обслуживания) могут произойти различные ситуации, которые могут привести к потере или искажению получаемых данных. Искажение данных может иметь различный характер. Во многих случаях эти искажения носят характер «выбросов», т.е. численные значения искаженных данных существенно отличаются от численных значений неискаженных. При рассмотрении таких данных человек может интуитивно обратить на них внимание, однако, выбросы не всегда являются следствием ошибки. В случае обнаружения таких «выбросов» необходимо принять решение о дальнейших действиях. В данной ситуации можно: забраковать все данные (из-за низкого уровня доверия к ним), можно исключить выбросы (удалить только часть данных), можно заменить выбросы некоторыми значениями. В любом из этих случаев имеет место риск потери некоторой информации, например, если выброс не был следствием ошибки. Но если не производить никаких действий, то выброс также может привести к искажению информации.

Таким образом, имеет место задача предварительной обработки данных с целью минимизации потери информации из-за ошибок исходных данных.

Вместо того чтобы удалять выпадающие наблюдения, можно использовать процедуры оценки параметров распределения, нечувствительные к структуре данных. Такие процедуры оценивания называются робастными.

Многие робастные оценки были предложены и исследованы в Принстонском обзоре 1972 г [12]. В настоящем материале рассмотрим три наиболее распространенные робастные процедуры:

винзоризованные оценки, усеченные оценки и кусочно-линейные М-оценки на примере М-оценки Хампеля.

3.2 Процедуры робастного оценивания в системах сбора статистике о трафике

3.2.1. Винзоризованные оценки

Винзоризованные оценки применяются при оценивании среднего и дисперсии распределений, при построении доверительных интервалов, а также при проверке гипотез относительно генерального среднего в ситуациях, когда можно предполагать присутствие выбросов [37]. В этой процедуре крайние значения в упорядоченном ряду наблюдений не отбрасываются, а изменяются. Обозначим через y1 <y2<…<yn упорядоченный ряд для выборки x1, x2, ..., xn, состоящей из n наблюдений. Тогда g-винзоризованные наблюдения получаются заменой g первых наблюдений на yg+1, а g последних — на yn-g (при $1 \le g < n/2$).

Тогда

$$z_1 = z_2 = \ldots = z_g = y_{g+1} \tag{3.1}$$

$$z_{g+1} = y_{g+1}, \quad 2 \le i \le n - 2g - 1 \tag{3.2}$$

$$z_n = z_{n-1} = \ldots = z_{n-g+1} = y_{n-g}, \tag{3.3}$$

При этом оценками среднего и дисперсии исходного распределения служат

$$\bar{z} = \frac{1}{n}\sum_{i=1}^{n} z_i \tag{3.4}$$

$$S_z^2 = \frac{1}{n-1}\sum_{i=1}^{n}(z_i - \bar{z})^2 \qquad (3.5)$$

Приближенный 100(1—α)%-ный g-винзоризованный доверительный интервал для среднего

$$\bar{z} = \frac{1}{n}\sum_{i=1}^{n} z_i \qquad (3.6)$$

$$\bar{z} \pm t_{1-\alpha/2}(h-1)\left[\frac{n-1}{h-1}\right]\frac{S^2}{\sqrt{n}} \qquad (3.7)$$

где $h = n - 2g$

3.2.2. Усеченные оценки

Усеченные оценки среднего получаются отбрасыванием g крайних наблюдений с обоих концов упорядоченной выборки y1 <y2<…<yn. Таким образом, α-усеченная оценка среднего μ равна

$$m(\alpha) = \frac{1}{h}\sum_{i=g+1}^{n-g} y_i \qquad (3.8)$$

где α выбирается так, чтобы g = nα, если nα — целое, или целой части от nα; a h = n — 2g, как и ранее.

Для достаточно больших значений п и при некоторых ограничениях величина n(α) распределена приблизительно нормально.

Стандартное отклонение для n(α) можно вычислить по формуле

$$S_{m(\alpha)} = \sqrt{SS(\alpha)/h(h-1)} \qquad (3.9)$$

где SS(α) обозначает винзоризованную сумму квадратов

$$(g+1)\left[y_{g+1}-m(\alpha)\right]^2+\left[y_{g+2}-m(\alpha)\right]^2+\cdots+$$
$$+\left[y_{n-g-1}-m(\alpha)\right]^2+(g+1)\left[y_{n-g}-m(\alpha)\right]^2$$

(3.10)

Приближенный 100(1—α)%-ный α-усеченный интервал для среднего μ равен

$$m(\alpha)\pm t_{1-\alpha/2}(h-1)S_{m(\alpha)} \qquad (3.11)$$

3.2.2. Кусочно-линейная М-оценка Хампеля

Эта процедура использует понятие М-оценки, введенное в [38]. В ней вместо обычной квадратичной функции отклонения, используемой в методе наименьших квадратов, берется некоторая непостоянная функция ρ, а в качестве оценки среднего μ принимается выражение, минимизирующее сумму $\sum_{i=1}^{n}\rho(x_i-\mu)$.

В более общей формулировке М-оценка определяется как решение уравнения вида

$$\sum_{i=1}^{n}\psi\left[(x_i-\mu)/s\right]=0 \qquad (3.12)$$

где s — единица измерения шкалы.

При этом ρ есть производная от функции:

$$\psi(y) = \operatorname{sgn}(y) \times \begin{cases} |y| & 0 < |y| \le 1{,}7 \\ 1{,}7 & 1{,}7 < |y| \le 3{,}4 \\ \dfrac{(8{,}5 - |y|)1{,}7}{5{,}1} & 3{,}4 \le |y| \le 8{,}5 \\ 0 & y > 8{,}5 \end{cases} \tag{3.13}$$

Смысл этой функции в том, что она приписывает наблюдениям эмпирически подобранные веса так, чтобы при некоторых предположениях минимизировать влияние крайних наблюдений. Кусочно-линейная М-оценка Хампеля для параметра положения определяется как решение уравнения

$$S = \sum_{i=1}^{n} \psi\left[(x_i - T)/s\right] = 0 \tag{3.14}$$

Это решение находится при помощи итеративной процедуры, в которой начальное значение To для решения T принимается равным медиане, а фиксированной оценкой множителя s служит медиана абсолютных отклонений от To.

3.3 Применение методов робастного оценивания при использовании ИИ

Методы робастного оценивания могут быть эффективным инструментом обработки исходных данных с целью исключения влияния ошибочных данных на результат. Как было отмечено выше, технологии ИИ также могут использоваться в целях входного контроля данных, однако, когда речь идет о данных, предназначенных для обучения системы ИИ, то необходим независимый инструмент, позволяющий исключить ошибки в обучающих данных, которые могу привести к нежелательным результатам, проявляющимся в отклонении функционирования ИИ от желаемого.

Таким образом, робастные оценки широко используются для обработки данных, применяемых для обучения систем ИИ.

Наряду с этим робастные оценки могут быть использованы совместно с технологиями ИИ в задачах контроля данных как дополнительный инструмент, позволяющий оценить эффективность работы ИИ и являющийся дополнительной защитой от грубых ошибок исходных данных в задачах принятия ответственных решений.

В задачах контроля данных, предназначенных для обучения систем ИИ, могут быть использованы винзоризованные, усеченные оценки и кусочно-линейные М-оценки в зависимости от вида и формы представления исходных данных.

Рассмотренные выше оценки построены на основе модификации выборки исходных данных таким образом, чтобы уменьшить влияние ошибок на среднее значение, получаемое на основе данной выборки.

Часто в задачах обучения систем ИИ требуется иметь сами исходные данные, т.е. выборочные значения, а не средние значения, полученные на их основе. В таком случае можно использовать описанные выше приемы модификации выборок, которые далее в модифицированном виде могут быть использованы в задачах обучения.

Применение робастных оценок для обработки данных обучения может быть эффективным инструментом уменьшения влияния ошибок в исходных данных на работу системы ИИ, а следовательно, и на эффективность выполнения функций анализа и управления трафиком в сетях связи.

4 Прогнозы применения технологий искусственного интеллекта до 2025 и 2030 года в виде доли оказываемых услуг пользователям и устройствам с использованием технологий искусственного интеллекта

4.1 Методика прогнозирования развития технологий ИИ

Стимулом развития технологий ИИ является развитие IT отраслей, а именно, вычислительной техники и телекоммуникаций. Интеграция вычислительных технологий и технологий телекоммуникаций приводит к качественно новому уровню, характерному для современной инфокоммуникационной структуры. ИИ является весьма удобными инструментом, применение которого стало возможным с одной стороны из-за роста возможностей вычислительных устройств, а с другой стороны из-за доступности информации. В настоящее время системы ИИ как правило решают задачи классификации данных, которые являются основой решения широкого круга задач анализа и управления. Благодаря этому системы ИИ применимы как при реализации услуг связи, так и при реализации элементов сети связи как функции анализа и управления.

Можно найти множество примеров современных услуг, реализуемых с применением ИИ, например, услуги распознавания речи, услуги распознавания лиц, распознавание окружающих предметов (услуги дополненной реальности), голосовые меню, голосовая идентификация, распознавание символов (текстов), услуги перевода и многие другие. Технологии ИИ находят применение в игровых, офисных и иных программах. Поскольку большинство современных программ ориентированы на работу в сети связи, можно полагать, что доля программ с использованием ИИ отражает долю услуг, использующих ИИ.

Согласно прогнозу ряда авторитетных аналитических компаний [13-19], прогноз роста доли программного обеспечения с использованием технологий ИИ. Прогноз приведен на рисунке 4.1.

Как видно из приведенного графика видно, что уже сегодня доля программного обеспечения с использованием технологий ИИ составляет около 25%. Согласно данному прогнозу, за 4 года эта доля увеличивается на величину около 20%, т.е. до 44%. Учитывая современные тенденции данный прогноз вполне понятен и ожидаем.

Глобальный рынок искусственного интеллекта телекоммуникаций был оценен в 679,0 млн долларов США в 2019 году и, как ожидается, будет расти со среднегодовым темпом роста (CAGR) 38,4% в период с 2020 по 2027 год (в среднем 5,5% в год) [14]. Телекоммуникации - одна из самых быстрорастущих отраслей, использующих ИИ. во многих аспектах своего бизнеса, включая улучшение качества обслуживания клиентов и надежность сети. Телекоммуникационные компании используют ИИ в первую очередь для приложений по обслуживанию клиентов (CRM). Например, использование чат-ботов и виртуальных помощников для обработки огромного количества запросов в службу поддержки по установке, обслуживанию и устранению неполадок. Кроме того, виртуальные помощники масштабируют и автоматизируют ответы на претензии в службу поддержки, что улучшает качество обслуживания клиентов и сокращает бизнес-расходы. Например, компания Vodafone Ltd. улучшила качество обслуживания клиентов примерно на 68% после внедрения своего чат-бота под названием TOBi для обработки запросов клиентов.

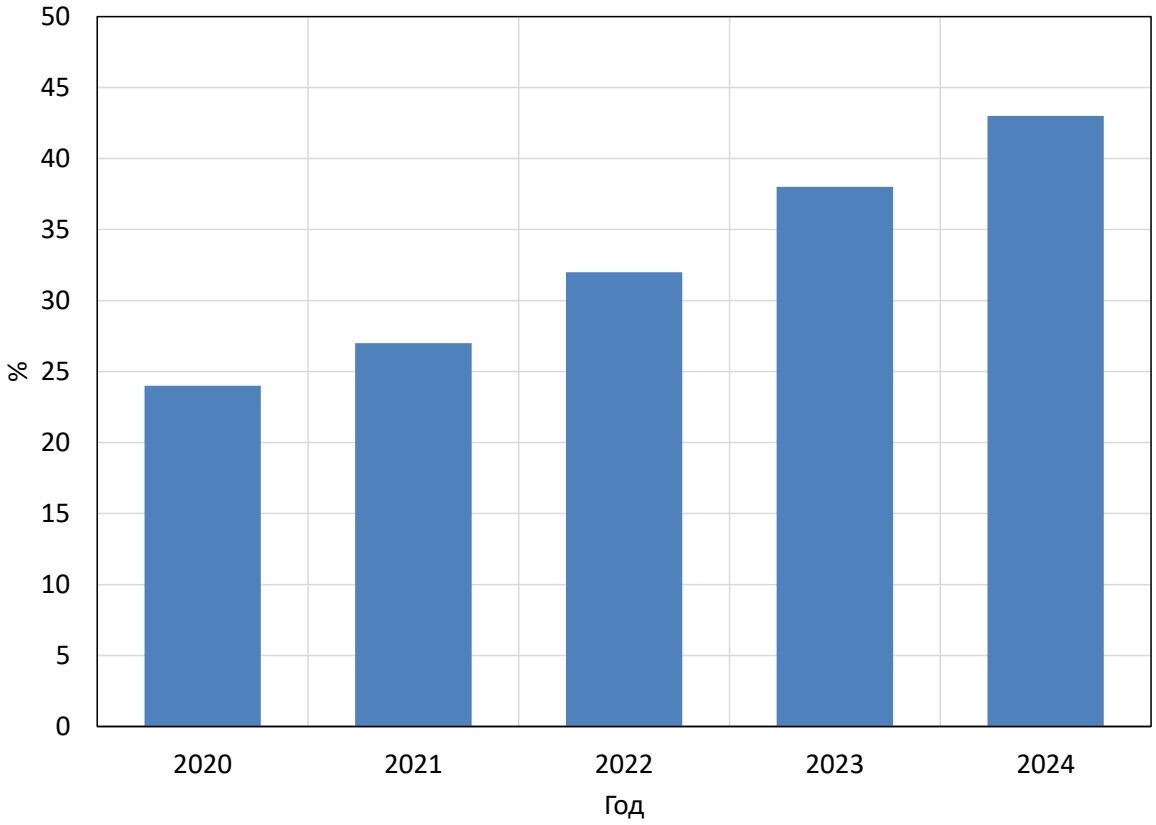

Рисунок 4.1 – Прогноз доли программного обеспечения с использованием ИИ в мире

Телекоммуникационные компании могут сократить операционные расходы и улучшить качество обслуживания клиентов за счет внедрения искусственного интеллекта и автоматизации.

Кроме этого, развивающиеся услуги Over-The-Top (OTT), такие как потоковое видео, изменили распространение и потребление аудио- и видеоконтента. Поскольку все больше потребителей обращаются к услугам OTT, потребительский спрос на пропускную способность значительно вырос. Перенос такого постоянно растущего трафика от услуг OTT приводит к высоким операционным расходам (OpEx) для телекоммуникационной отрасли. Искусственный интеллект помогает телекоммуникационной отрасли снизить эксплуатационные расходы за счет минимального вмешательства человека, необходимого для настройки и обслуживания сети. Кроме того,

автоматизация позволяет телекоммуникационным компаниям быстрее привлекать клиентов и вводить новые услуги в более короткие сроки.

Для получения прогноза проникновения технологий ИИ в услуги телекоммуникаций в РФ воспользуемся ассоциативным методом.

Данный метод заключается в предположении, что динамика развития ИИ, как одного из наиболее перспективных направлений сегодня и в будущем, будет происходить по сценарию близкому к известным сценариям развития наиболее востребованных технологий телекоммуникаций в прошлом.

Возьмем за основу статистику развития сетей подвижной связи, как наиболее яркий пример динамики проникновения инноваций, т.е. выберем его в качестве прототипа. На основе имеющейся статистики опишем законы развития и оценим динамику изменения среднемирового уровня и динамику развития в Российской Федерации. На основе сравнения полученных зависимостей найдем соотношение их параметров для закона, описывающего развитие в мире и закона, полученного для РФ.

Условно данный подход можно представить в виде следующего алгоритма, рисунок 4.2.

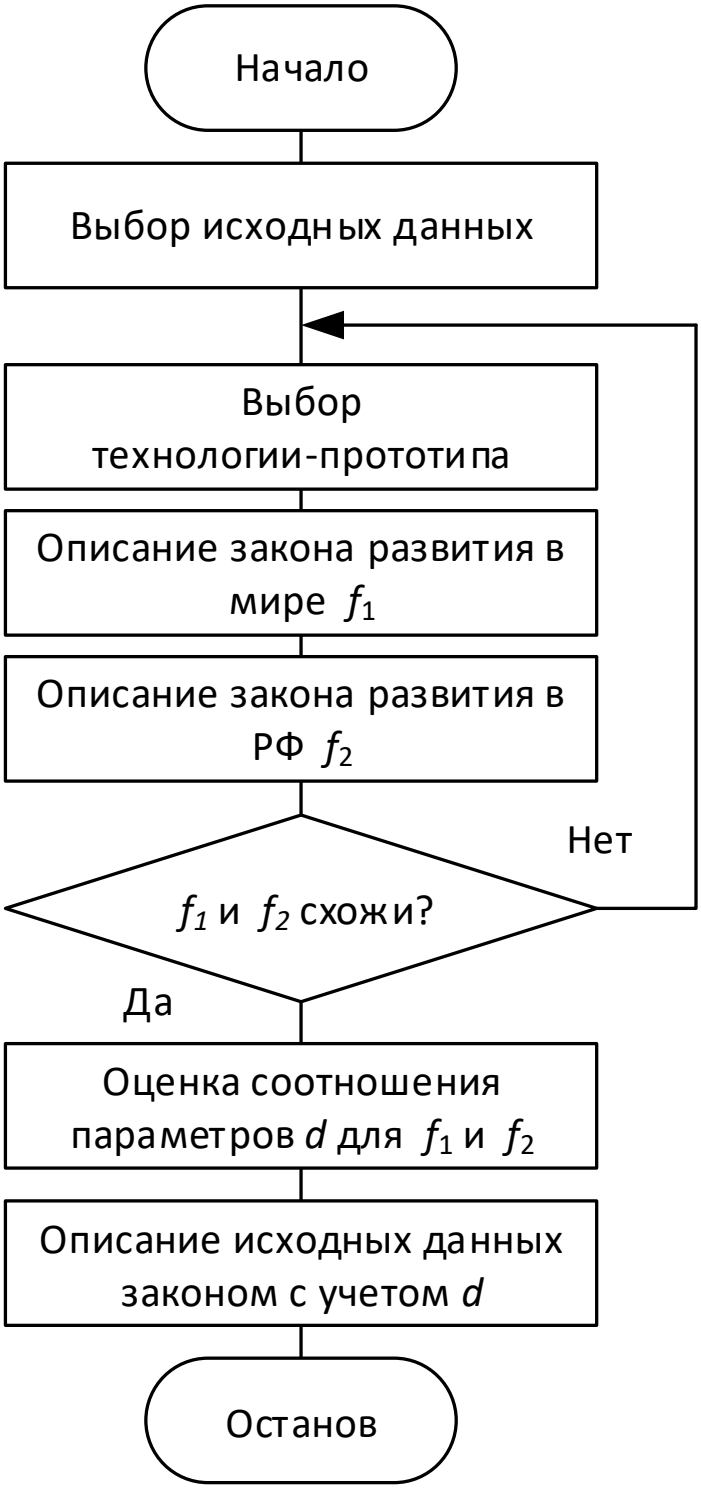

Рисунок 4.2 – Алгоритм получения прогноза

Для описания законов развития выбираются некоторые функциональные зависимости, которые достаточно хорошо описывают статистические данные. Проверка схожестей этих зависимостей является сложно формализуемой задачей. Идеальным вариантом является описание

зависимостей одной и той же функцией, в таком случае на следующем шаге нужно только определить соотношение между параметрами этих функций.

Для реализации данного алгоритма воспользуемся прогнозами авторитетных компаний по развитию технологий ИИ в мире [13, 16-19]. Эти данные примем за исходные.

Для оценки динамики развития технологий ИИ в РФ сравним динамику развития телекоммуникационных технологий в мире и РФ на примере проникновения сетей подвижной связи. Статистические данные за период с 2000 до 2020 г. для РФ и среднемировые приведены на рисунке 4.3.

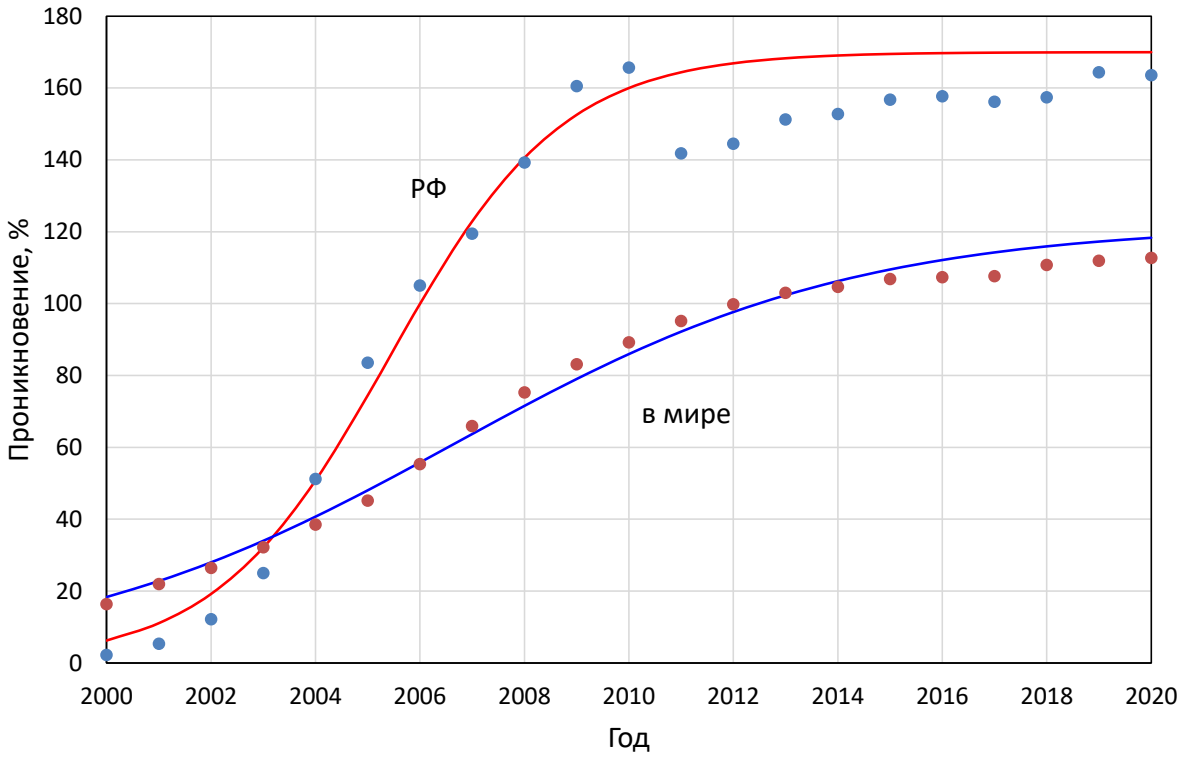

Рисунок 4.3 – Статистика развития сетей подвижной связи в РФ и среднемировые

Эти статистические данные достаточно точно могут быть аппроксимированы логистической кривой вида

$$f_1(t), f_2(t) = \frac{\gamma_0}{1 + e^{-\frac{t - t_9}{b}}} \qquad (4.1)$$

где γ_0 - предельно достижимое проникновение, t0 –точка полуперегиба, b-наклон кривой.

Таким образом, обе зависимости, в данном случае, описаны одним и тем же аналитическим законом. Сравнивая обе кривые, получены корректирующие коэффициенты для параметров этих кривых (точки полуперегиба и наклона), характеризующие различие среднемировой динамики развития и динамики для РФ.

Таблица 4.1 – Значения параметров

Зависимость	t_0	b	d
f_1	2005,41	1,66	1,23
f_2	2006,66	3,84	2,32

Таким образом, получен закон развития, который описан логистической кривой, а в таблице 4.1 получены коэффициенты, отражающие различие законов развития в РФ от среднемирового развития. На основе этих данных могут быть получены прогнозы развития технологии ИИ в мире и в Российской федерации.

4.2 Прогноз доли услуг, оказываемых с использованием ИИ в мире

С учетом приведенных прогнозов и полученных выше коэффициентов, учитывающих особенности развития телекоммуникаций в мире получен прогноз доли услуг с использованием технологий ИИ, рисунок 4.4 и таблица 4.2.

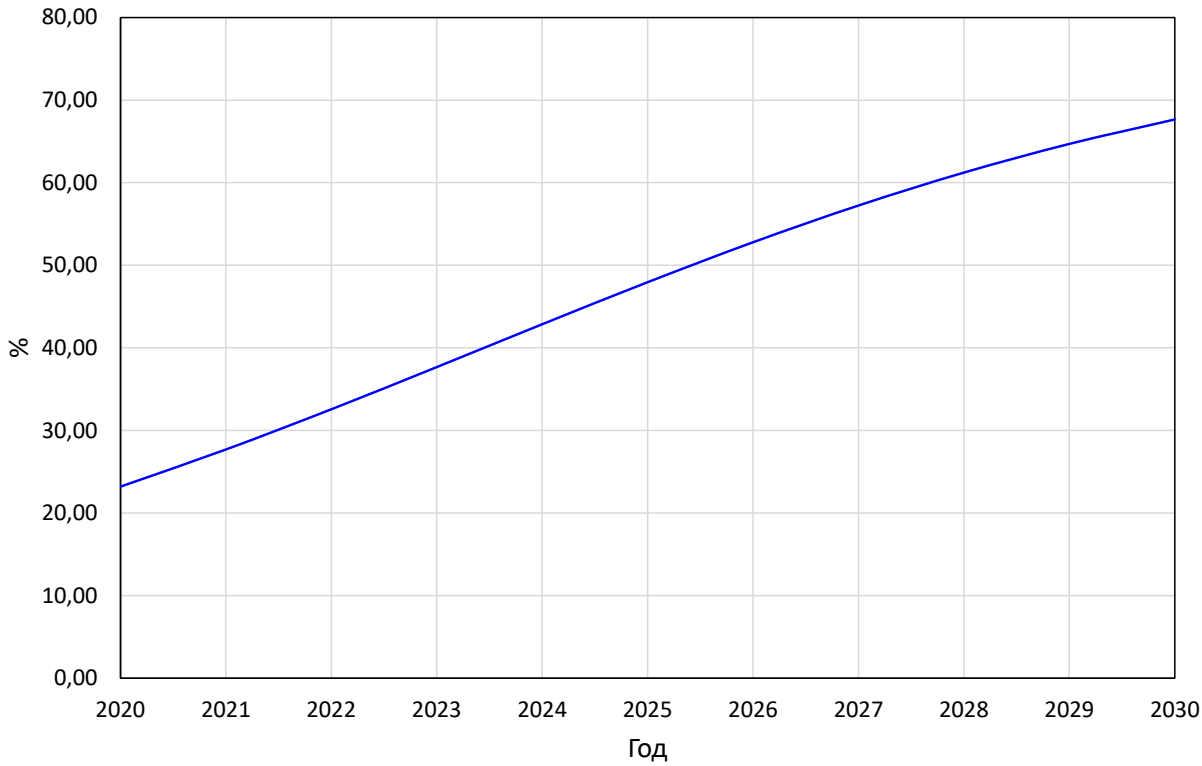

Рисунок 4.4 – Прогноз доли услуг с использованием ИИ в мире

Таблица 4.2 - Прогноз доли услуг с использованием ИИ в телекоммуникациях в мире до 2030 г.

Год	**Доля %**
2020	23,20
2021	27,69
2022	32,56
2023	37,67
2024	42,85
2025	47,95
2026	52,78
2027	57,23
2028	61,22
2029	64,69
2030	67,65

Как видно из приведенных данных, на протяжении периода прогнозирования ожидается рост доли услуг с использованием ИИ, средний прирост в мире составляет 4,4% в год на периоде продолжительностью 10 лет. К концу 2030 г. ожидается, что доля таких услуг составит около 67%.

Большая доля услуг будет в различной степени использовать технологии ИИ. Также, вполне вероятно, что некоторая доля услуг не будет использовать технологии ИИ, например, из соображений наличия некоторой альтернативы, которая всегда имеет место в процессе развития технологий. На сегодняшний день сложно определить, что именно может быть такой альтернативой, возможно, это использование классических методов классификации и управления.

4.3 Прогноз доли услуг, оказываемых с использованием ИИ в Российской Федерации

С учетом приведенных прогнозов и полученных выше коэффициентов, учитывающих особенности развития телекоммуникаций в РФ получен прогноз доли услуг с использованием технологий ИИ в Российской Федерации, и в мире рисунок 4.5 и таблица 4.3.

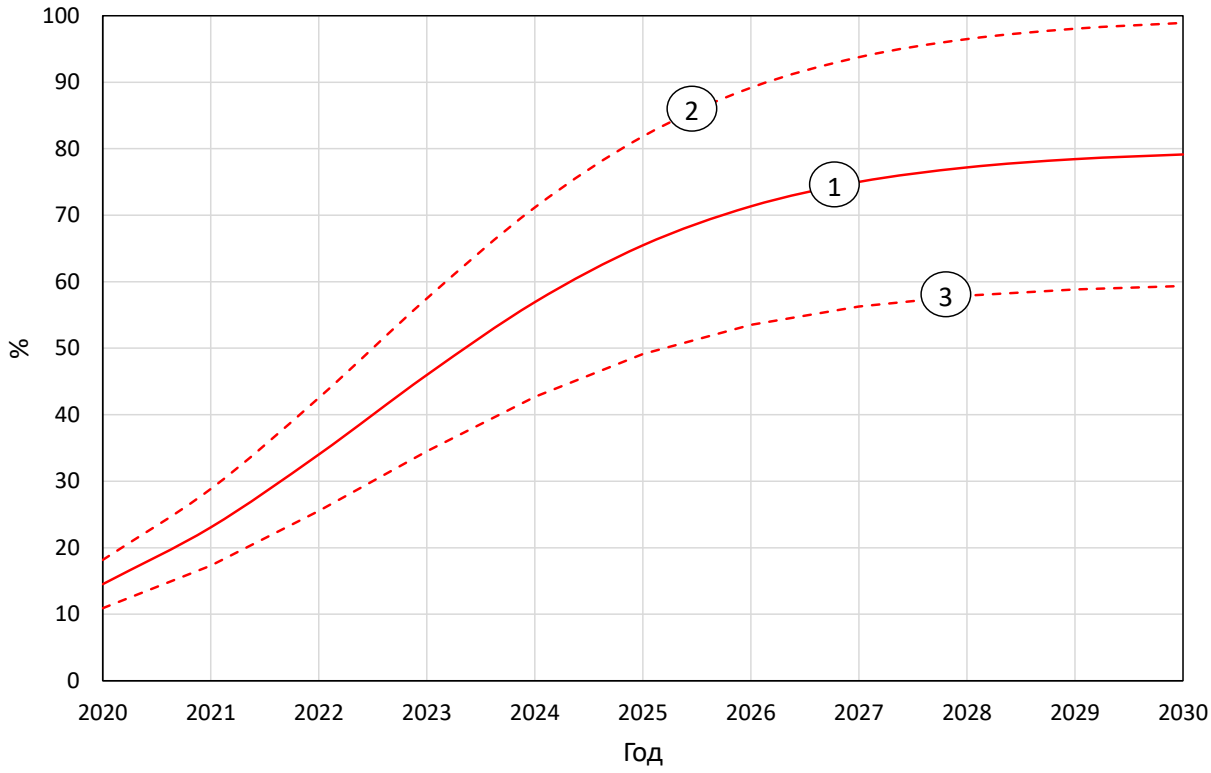

Рисунок 4.5 – Прогноз доли услуг с использованием ИИ в РФ

Таблица 4.3 - Прогноз доли услуг с использованием ИИ в телекоммуникациях в РФ до 2030 г.

Год	**Доля %**		
	Опт. прогноз	Песс. прогноз	Пр. прогноз
2020	18,16	10,89	14,52
2021	28,83	17,30	23,07
2022	42,53	25,52	34,02
2023	57,47	34,48	45,98
2024	71,17	42,70	56,93
2025	81,84	49,11	65,48
2026	89,17	53,50	71,34
2027	93,76	56,26	75,01
2028	96,49	57,89	77,19
2029	98,05	58,83	78,44

2030	98,92	59,35	79,14

Были получены три прогноза: прагматический, оптимистический и пессимистический. Прагматический прогноз получен при величине предельного проникновения равной 80%, такая величина характерна для проникновения различных услуг, в частности услуг сетей подвижной связи.

Оптимистический прогноз получен при величине предельного проникновения равной 100%, такая величина характерна является предельно достижимой, данный прогноз можно рассматривать как верхнюю границу.

Пессимистический прогноз получен при величине предельного проникновения равной 80% и меньшей скорости проникновения технологий, которая выбрана равной среднемировой.

Наиболее ожидаемыми являются значения прагматического прогноза. Как видно из приведенных данных, на протяжении периода прогнозирования ожидается рост доли услуг с использованием ИИ, средний прирост в РФ составляет 6,5% в год на периоде продолжительностью 10 лет. К концу 2030 г. ожидается, что доля таких услуг составит около 80%.

Принимая в учет интерес к технологиям ИИ и современные тенденции, такой прогноз вполне ожидаем. Большая доля услуг будет в различной степени использовать технологии ИИ. Также, вполне вероятно, что некоторая доля услуг не будет использовать технологии ИИ, например, из соображений наличия некоторой альтернативы, которая всегда имеет место в процессе развития технологий. На сегодняшний день сложно определить, что именно может быть такой альтернативой, возможно, это использование классических методов классификации и управления.

5 Прогнозы применения технологий искусственного интеллекта до 2025 и 2030 года в виде доли трафика, обслуживаемого с использованием технологий искусственного интеллекта

5.1 Методика прогнозирования

Для прогнозирования доли трафика, обслуженного с использованием технологий ИИ также воспользуемся ассоциативным методом, описание которого приведено п.4.1.

К трафику, обслуженному с использованием технологий ИИ будем относить трафик, при обслуживании которого в сети связи так или иначе использовались технологии ИИ, т.е. будем рассматривать применение технологий ИИ на уровнях ниже прикладного уровня, к которому были отнесены услуги, описанные в предыдущем разделе.

При выборе исходных данных будем исходить из следующих соображений. Будем полагать, что динамика проникновения технологий ИИ в технику телекоммуникаций описывается динамикой изменения рынка технологий ИИ и динамикой проникновения технологий сетей пятого поколения (5G). Перспективные сети связи на различных уровнях широко используют технологии ИИ и когнитивные технологии. В частности, основой сетей 5G являются программно-определяемые сети (SDN), в которых технологии ИИ могут применяться в процессах управления сетью и обслуживания трафика. Таким образом, доля трафика, обслуживаемого в сетях 5G может быть отнесена к трафику, обслуженному с применением технологий ИИ. Наряду с сетями 5G современные сети 4G также применяют технологии ИИ, например, в системах взаимодействия с клиентами (CRM). Такие системы не принимают непосредственного участи в обслуживании трафика, однако, их роль в управлении сетью очевидна, поэтому, их также следует учитывать в виде доли трафика.

В качестве исходных данных воспользуемся прогнозом изменения трафика различных поколений сетей связи [13]. На рисунке 5.1 приведен прогноз Ericsson.

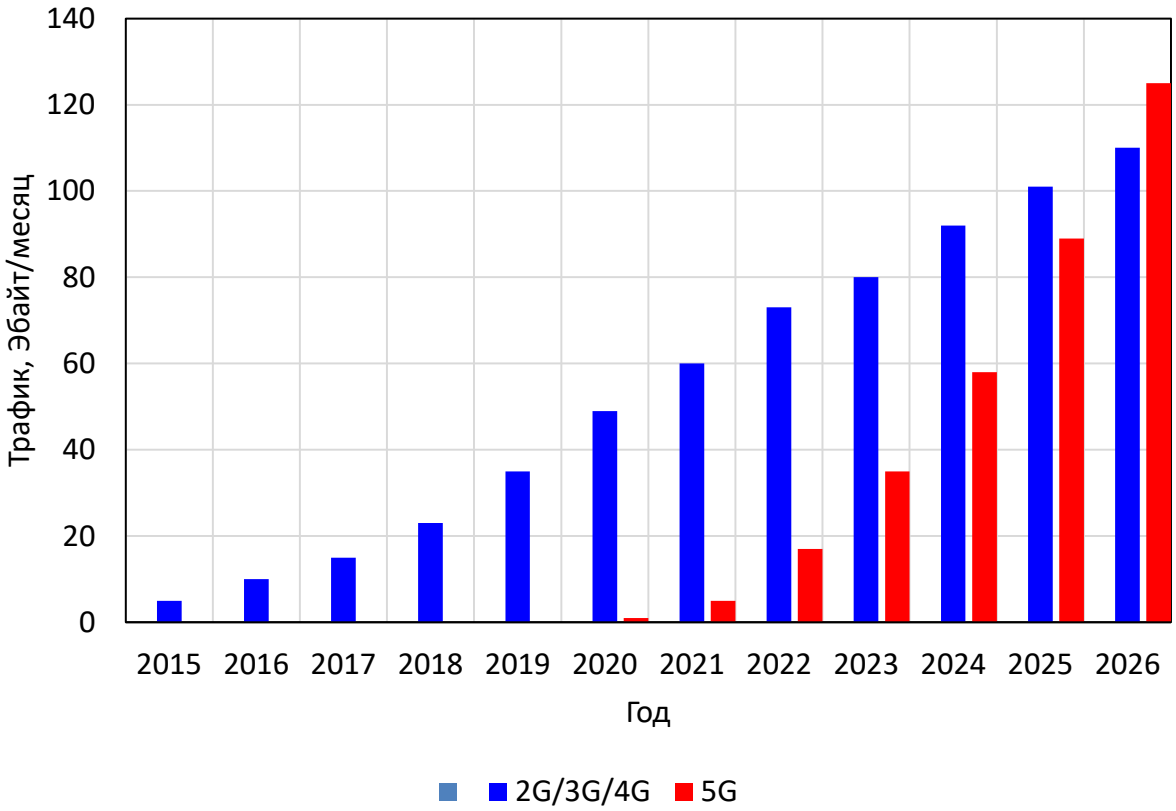

Рисунок 5.1 – Прогноз трафика по технологиям построения сетей

На базе данного прогноза получим прогноз доли трафика сетей 5G. Для исходных данных выбрана в качестве аппроксимации логистическая кривая. Прогноз доли трафика 5G в мире приведен на рисунке 4.2.

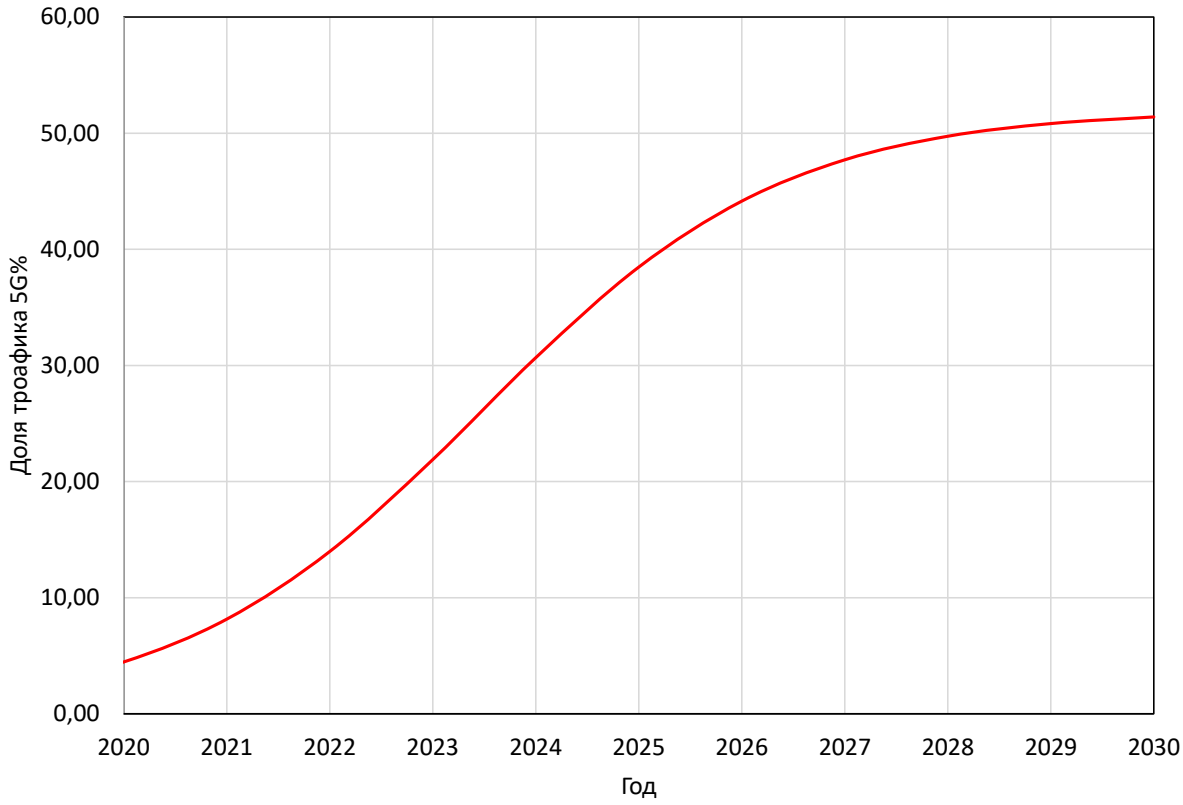

Рисунок 5.2 – Прогноз доли трафика сетей 5G

Из приведенного прогноза видно, что доля трафика сетей 5G к 2030 г. возрастает до 50% в мире. С учетом динамики проникновения технологий телекоммуникаций в РФ, следует ожидать, что этот процесс в РФ будет происходить несколько быстрее, а достижимая величина будет выше.

Вторая составляющая трафика, обслуженного с применением технологий ИИ – это трафик обслуженный системами 3G и 4G с применением элементов ИИ в программном обеспечении управления, в частности CRM.

По данным [15] несмотря на потенциальные возможности использования технологий ИИ в CRM системах только 12% пользователей (на 2019 г.) использовали эти возможности. Это говорит о том, что имеется потенциальный резерв использования технологий ИИ в сетях 3G и 4G.

5.2 Прогноз доли трафика, оказываемых с использованием ИИ в мире

Объем обслуженного сетями связи трафика постоянно увеличивается, согласно прогнозам [16] в среднем на 24% в год.

С использованием приведенных выше прогнозов и ассоциативного метода получен прогноз изменения доли трафика в мире, обслуженного с применением технологий ИИ, рисунок 5.3 и таблица 5.1.

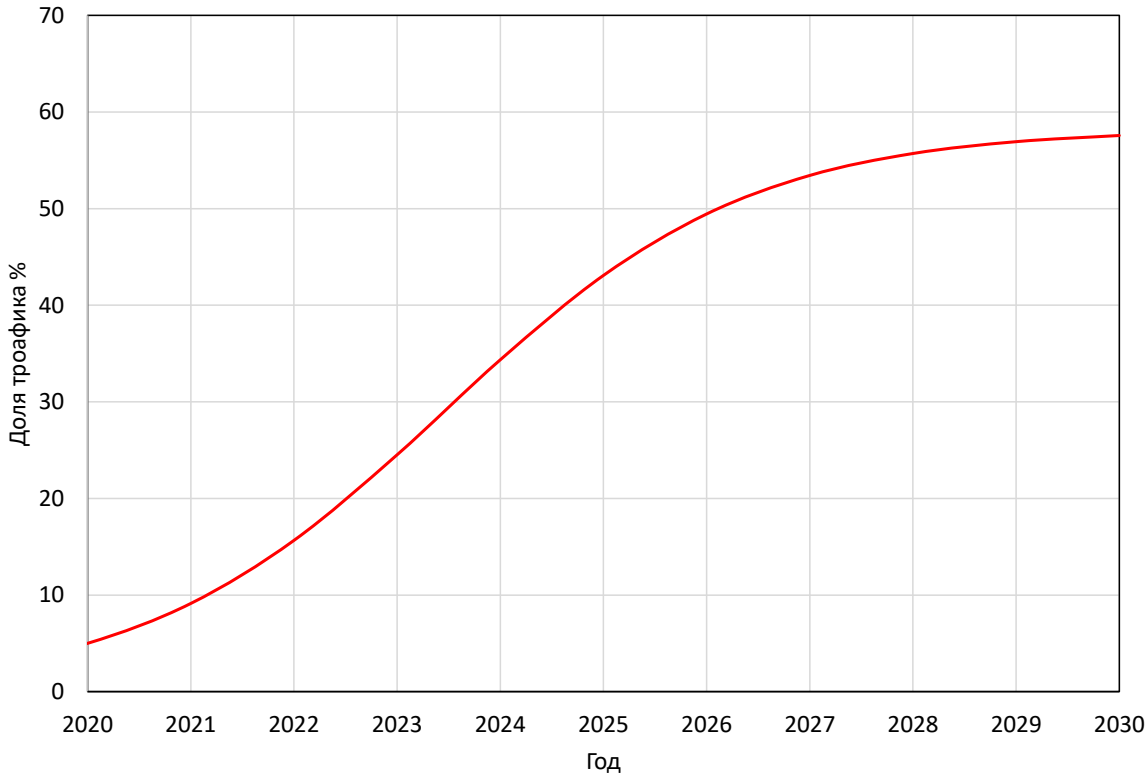

Рисунок 5.3 – Прогноз доли трафика, обслуженного с применением ИИ в мире

Из полученного прогноза видно, что он повторяет закон роста доли пользователей 5G с некоторым количественным отличием, обусловленным развитием систем CRM.

Таблица 5.1 - Прогноз доли трафика, обслуженного с использованием ИИ в мире до 2030 г.

Год	**Доля %**
2020	5,01
2021	9,14
2022	15,66
2023	24,53
2024	34,36
2025	43,09
2026	49,45
2027	53,44
2028	55,71
2029	56,93
2030	57,57

Согласно полученному прогнозу доля трафика, обслуженного с использованием технологий ИИ возрастает по закону близкому к логистическому, к 2030 г. ее величина достигает около 58%. Среднемировые показатели учитывают проникновение технологии во всех странах, уровень которого в различных странах может сильно различаться.

5.3 Прогноз доли трафика, оказываемых с использованием ИИ в Российской Федерации

С учетом динамики проникновения технологий телекоммуникаций в РФ получен прогноз изменения доли трафика, обслуженного с использованием технологий ИИ в РФ. Прогноз приведен на рисунке 5.4. и в таблице 5.2. При построении прогноза учитывались особенности динамики

проникновения телекоммуникационных технологий в РФ, что выражается в отличие скорости роста и достижимого ровня проникновения.

Полученный прогноз показывает, что рост доли трафика, обслуженного с использованием технологий ИИ увеличивается на всем интервале прогнозирования, а к 2030 г. достигает уровня около 78%. Из прогноза также видно, что наибольшая скорость проникновения технологий ИИ ожидается в период с 2024 до 2028 гг., после 2028 г. тренд переходит в фазу замедления роста, что говорит о достаточно глубоком, близком к предельному, проникновении.

В настоящее время невозможно точно оценить предельный уровень проникновения технологий ИИ. С одной стороны, его следовало бы выбрать как 100% уровень, что вполне вероятно. Однако, как демонстрирует опыт развития телекоммуникаций, полная смена технологий, например, поколений сети связи, происходит чрезвычайно медленно. Это объясняется необходимостью сохранять совместимость оборудования разных поколений. Вероятно, аналогичные процессы будут иметь месть место и в данном случае, поэтому предельное проникновение, вероятно, будет несколько ниже 100%.

Кроме сказанного выше, что на сегодняшний день сложно точно оценить степень проникновения технологий ИИ в системы CRM в будущем, а также не вполне ясно стоит ли относить трафик, при наличие ИИ в системы CRM к доле обслуженного трафика с использованием ИИ. Были построены три прогноза.

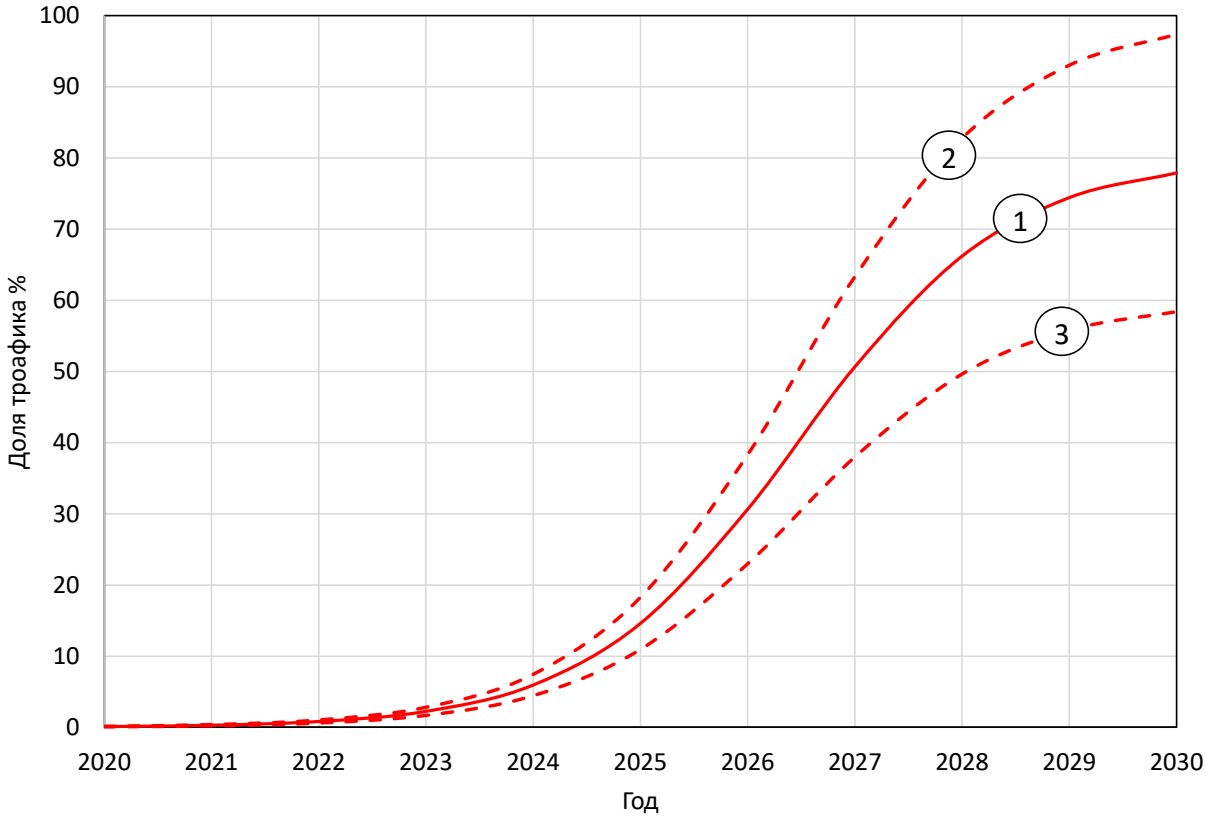

Рисунок 5.3 – Прогноз доли трафика, обслуженного с применением ИИ в РФ

Таблица 5.2 - Прогноз доли трафика, обслуженного с использованием ИИ в РФ до 2030 г.

Год	**Доля %**		
	Опт. прогноз	Песс. прогноз	Пр. прогноз
2020	0,13	0,08	0,11
2021	0,37	0,22	0,30
2022	1,03	0,62	0,82
2023	2,81	1,68	2,24
2024	7,43	4,46	5,94
2025	18,24	10,95	14,59
2026	38,29	22,97	30,63
2027	63,31	37,98	50,65
2028	82,75	49,65	66,20

2029	93,03	55,82	74,42
2030	97,37	58,42	77,90

Кривая 1 соответствует наиболее ожидаемому сценарию развития (прагматический прогноз) он построен при допущениях, что предельный уровень проникновения ИИ составит около 80%, а проникновение технологий в CRM будет расти до того же уровня (80%).

Кривая 2 соответствует верхней границе прогноза (оптимистический прогноз) он построен при допущениях, что предельный уровень проникновения ИИ составит около 100%, а проникновение технологий в CRM будет расти до того же уровня (100%).

Кривая 3 соответствует нижней границе прогноза (пессимистический прогноз) он построен при допущениях, что предельный уровень проникновения ИИ составит около 80%, при этом в CRM не учитывается в определении доли трафика.

Рассматривая и пессимистический прогнозы как границы интервала прогнозирования, можно отметить, что ожидаемая доля трафика, обслуженного с использованием ИИ к 2030 г может составить от 60 до 98%, наиболее ожидаемой является величина около 78%.

6. Рекомендации по применению технологий искусственного интеллекта для задач анализа и управления трафиком на сетях связи

6.1 Анализ рекомендаций Сектора Стандартизации Телекоммуникаций Международного Союза Электросвязи (МСЭ-Т)

В рамках изучения технологий ИИ в МСЭ-Т была создана группа по машинному обучению для перспективных сетей, включая 5G FG ML5G. Группа была создана 13-й Исследовательской комиссией МСЭ-Т на собрании в Женеве 6-17 ноября 2017 года. Данная группа разработала десять технических спецификаций для машинного обучения (ML) для перспективных сетей сети связи, включая интерфейсы, сетевые архитектуры, протоколы, алгоритмы и форматы данных. Группа FG ML5G работала с января 2018 года по июль 2020 года.

В таблице 6.1 приведен перечень рекомендаций МСЭ-Т по искусственному интеллекту, разработанных на основе результатов группы FG ML5G.

Таблица 6.1. Рекомендации МСЭ-Т по искусственному интеллекту.

	Номер, дата принятия	**Наименование стандарта**
1	ITU-T Y.3170, сентябрь 2018	Требования по обеспечению качества обслуживания на основе машинного обучения для сети IMT-2020
2	ITU-T Y.3172, июнь 2019	«Архитектурная основа для машинного обучения в перспективных сетях, включая IMT-2020»
3	Дополнение 55 к Y.3170 серии, октябрь 2019	«Машинное обучение в сетях будущего, включая IMT-2020: сценарии использования»

4	ITU-T Y.3173, февраль 2020	«Основы для оценки уровней интеллекта будущих сетей, включая IMT-2020».
5	ITU-T Y.3174, февраль 2020	«Основы обработки данных для обеспечения машинного обучения в будущих сетях, включая IMT-2020»
6	ITU-T Y.3175, апрель 2020	Функциональная архитектура основанного на машинном обучении качества обслуживания для сетей IMT-2020.
7	ITU-T Y.3176, сентябрь 2020	«Интеграция рынка машинного обучения в будущие сети, включая IMT-2020».
8	ITU-T Y.3177, февраль 2021	Архитектурная структура сетевой автоматизации на основе искусственного интеллекта для управления ресурсами и отказами в будущих сетях, включая IMT-2020
9	ITU-T Y.3178, июль 2021	Функциональная структура услуг в сетях связи, базирующихся на искусственном интеллекте, для будущих сетей, включая сети IMT-2020.
10	ITU Y.3179, апрель 2021	Структура моделей машинного обучения для предоставления услуг в будущих сетях, включая IMT-2020.

Рекомендация ITU-T Y.3170 определяет требования к обеспечению качества обслуживания (QoS) на основе машинного обучения для сетей мобильной связи 2020 (IMT-2020).

В Рекомендации МСЭ-Т Y.3170 представлен обзор методов обеспечения QoS на основе машинного обучения для сети IMT-2020. Рекомендация ITU-T Y.3170 включает обзор возможностей обнаружения и прогнозирования аномалий QoS с использованием машинного обучения. В

Рекомендации МСЭ-Т Y.3170 описывается функциональная модель обеспечения QoS на основе машинного обучения, которая включает такие функциональные компоненты, как: сбор данных QoS; предварительная обработка данных; хранение данных, моделирование и обучение; QoS.

Рекомендация ITU-T Y.3172 определяет архитектурную основу для машинного обучения (ML) в перспективных сетях связи, включая IMT-2020. В рекомендации представлен набор архитектурных требований и конкретных архитектурных компонентов, необходимых для выполнения этих требований. Эти компоненты включают, но не ограничивается конвейером машинного обучения, а также функциями управления и оркестровки машинного обучения. Также описана интеграция этих компонентов в перспективные сети, включая IMT-2020 и руководство по применению базовой структуры в различных сетях для различных технологий.

В дополнении 55 к Y.3170 проанализированы варианты использования машинного обучения в перспективных сетях, включая IMT-2020. При этом выделено пять основных областей применения машинного обучения:

- Сетевой слайсинг и базирующиеся на машинном обучении самоорганизующиеся сети,
- Методы машинного обучения, относящиеся к уровню пользовательского оборудования,
- Методы машинного обучения, относящиеся к уровню приложений,
- Методы машинного обучения, относящиеся к уровню сигнализация или управления,
- Методы машинного обучения, относящиеся к уровню безопасности.

Следует отметить, что рекомендация достаточно подробно описывает разнообразные области применения машинного обучения в сетях и системах телекоммуникаций. Рассмотрим, например, области применения для сетевого слайсинга и базирующихся на машинном обучении самоорганизующихся сетях.

Начинается этот раздел с задач по когнитивным гетерогенным сетям и базирующихся на машинном обучении самоорганизующимся сетям. При этом сбор данных для таких сетей осуществляется на основе систем мониторинга, а также пробниках для требуемых параметров (например, потери кадров, задержки, джиттер). Сбор данных производится для всех сетей, включая сети радиодоступа, ядро сети, транспортную сеть, а также для различных радио технологий с учетом мульти вендорных условий.

Для сетей радиодоступа собираются следующие данные:

- географическое положение пользовательского оборудования,

- результаты измерений радио обстановки для пользовательского оборудования и/или узлов доступа,

- распределение ресурсов по пользовательскому оборудованию и/или узлам доступа,

- соединениям для систем сигнализации по пользовательскому оборудованию и/или узлам сети доступа,

- данные для классификации типов трафика для пользовательского оборудования и/или по узлам сети доступа,

- данные для классификации услуг для пользовательского оборудования и/или по узлам сети доступа, например, по услугам сетей связи с ультра малыми задержками, массивному машинному доступу, широкополосному мобильному доступу,

- использование ресурсов соты и/или узлов доступа,

- показатели функционирования для соты и/или узлов доступа, такие как доступность, пропускная способность, мощность и т.д.

Для ядра сети собираются следующие данные:

- показатели функционирования ядра сети, например, скорость, отказы и их причина,

- структура трафика на уровне ядра сети, например, агрегированный трафик на услугу, число сессий на услугу и т.п.,

- показатели по составляющим сети, например, на узел доступа, на линии и т.д.,

- детальные данные о соединениях, включая IP-адреса, улуги, местоположение.

Далее, в разделе по пользовательскому оборудованию с целью профилирования трафика приводится информация о сборе данных по трафику (подраздел 6.2.1). Отмечается, что сбор трафика должен производиться в реальном времени в соответствии с используемым пользовательским оборудованием приложением и типом протокола. При этом для обработки трафика могут использоваться сверточные нейронные сети и метод глубокого обучения LSTM. Отмечается также, что может использоваться и федеративное машинное обучение.

В следующем разделе про долгосрочные прогнозы трафика отмечается полезность использования авторегрессионных моделей типа ARIMA и опять-таки сетей LSTM.

Следует отметить, что, несмотря на достаточно высокий уровень проработки рекомендации, комплексного решения проблем по использованию технологий искусственного интеллекта для задач анализа и управления трафиком в дополнении 55 не наблюдается, что вполне объяснимо, поскольку, судя по всему, такой задачи и не ставилось. В связи с этим предлагается подготовить новую рекомендацию МСЭ-Т по использованию технологий искусственного интеллекта для анализа и управления трафиком на сетях связи.

Рекомендация МСЭ-Т Y.3173 определяет структуру для оценки интеллекта перспективных сетей, включая IMT-2020, и вводит метод оценки уровней интеллекта перспективных сетей, включая IMT-2020. Архитектурное представление для оценки уровней сетевого интеллекта в соответствии с архитектурной структурой, определенной в рекомендации МСЭ-Т Y.3172.

Также определена взаимосвязь между структурой, описанной в настоящей Рекомендации, и соответствующей работой в других стандартах

или отраслевых органах, а также применение метода для оценки уровней сетевого интеллекта в нескольких типичных случаях использования.

В Рекомендации МСЭ-Т Y.3174 описана основы обработки данных, для машинного обучения в перспективных сетях, включая (IMT) -2020. В рекомендации даны требования к механизмам сбора и обработки данных в различных сценариях использования машинного обучения в перспективных сетях, включая IMT-2020. На основе этого описывается дается общая структура для обработки данных и примеры ее реализации в конкретных базовых сетях.

В рекомендации МСЭ-Т Y.3175 определяется функциональная архитектура обеспечения качества обслуживания (QoS) на основе машинного обучения (ML) IMT-2020. В рекомендации МСЭ-Т Y.3175 сначала дается анализ архитектурной основы ML в IMT-2020 (Рекомендация МСЭ-Т Y.3172). Затем в ней приводится функциональная архитектура обеспечения QoS на основе ML для сети IMT-2020, включая эталонные точки. Наконец, эта рекомендация определяет процедуры обеспечения QoS на основе ML для сети IMT-2020.

В Рекомендации МСЭ-Т Y.3176 представлены требования высокого уровня и архитектура для интеграции рынков машинного обучения (ML) в перспективные сети связи, включая IMT-2020. Основываясь на этих требованиях, Рекомендация описывает архитектуру для интеграции рынков машинного обучения, принимая во внимание архитектурную структуру из Рекомендации МСЭ-Т Y.3172 в качестве основы.

В Рекомендации МСЭ-Е Y.3177 представлена архитектура сетевой автоматизации на основе искусственного интеллекта (ИИ) для управления ресурсами сети для повышения ее производительности. Это обеспечивается за счет постоянного мониторинга сети и ускорения принятия решений о перераспределении ресурсов, в том числе в условиях отказа оборудования, с использованием методов машинного обучения.

Рекомендация ITU-T Y.3178 определяет функциональную основу для предоставления сетевых услуг на основе технологий искусственного интеллекта в будущих сетях будущего, в том числе IMT-2020. В данной Рекомендации рассматриваются следующие вопросы:

- ролевая бизнес-модель для предоставления сетевых услуг на основе технологий ИИ;

- высокоуровневые требования к ролям и их взаимодействиям с операционной точки зрения на основе технологий ИИ;

- функциональные компоненты и их взаимодействие на основе технологий ИИ для предоставления сетевых услуг.

В рекомендации МСЭ-Т Y.3179 рассматриваются структура моделей машинного обучения (ML) для сетей будущего, включая IMT-2020. Структура включает требования высокого уровня и описание архитектуры высокого уровня, охватывающее определение архитектурных компонентов и контрольных точек.

Разработанные в МСЭ-Т рекомендации направлены на систематизацию понятий, определений, моделей и методов использования технологий ИИ в сетях связи. Основной задачей использования технологий ИИ, определенной в рекомендациях серии Y.3170, является обеспечение требований к качеству обслуживания QoS, что непосредственно связано с задачами анализа и управления обслуживанием трафика в перспективных сетях связи. Вместе с тем, анализ рекомендаций показал, что целесообразна разработка новой рекомендации МСЭ-Т по использованию технологий искусственного интеллекта для анализа и управления трафиком на сетях связи.

6.3 Рекомендации по применению технологий искусственного интеллекта для задач анализа и управления трафиком на сетях связи

Использование технологий ИИ в задачах анализа и управления трафиком позволяет повысить эффективность решения этих задач за счет систематизации и определения типовых решений, которые могут быть использованы в различных приложениях и адаптированы к ним путем машинного обучения.

Можно определить следующие рекомендации по применению технологий ИИ в задачах анализа трафика.

1. Технологии ИИ рекомендуется использовать в задачах входного контроля данных при реализации функций непрерывного мониторинга трафика, а также же при выполнении периодических или эпизодических измерений параметров трафика. В данном случае с помощью технологий ИИ может быть реализован поиск ошибок в исходных данных, дополняющий методы робастных оценок. Такой метод можно отнести к решению задачи классификации с помощью обучаемой системы с учителем.

2. Технологии ИИ также рекомендуется использовать в задачах моделирования трафика при выборе модели на основе анализа статистических данных мониторинга трафика. При решении данной задачи также решается задача классификации, в которой исследуемый поток трафика следует отнести к одному из известных типов по критерию близости вероятностной модели (функции распределения). Данная задача может решаться как в научно-исследовательских целях, так и в целях использования полученной модели в задачах имитационного моделирования сети связи для решения задач ее эксплуатации и развития. Для решения данной задачи рекомендуется использовать ИНС при использовании обучения с учителем (статистические данные о трафике), например, LSTM сеть.

3. Технологии ИИ также рекомендуется использовать в задачах анализа временных зависимостей: периодичности и долговременных тенденций изменения параметров трафика. В данном случае технологии ИИ могут использоваться в задачах прогнозирования трафика на различные временные периоды. При этом данными для обучения являются статистические данные, полученные путем мониторинга за достаточно длительный период времени, а функция ИИ заключается в их аппроксимации. Для решения задач могут быть использованы ИНС с обучением с учителем, например, NARX.

Можно определить следующие рекомендации по применению технологий ИИ в задачах управления трафиком.

1. Технологии ИИ возможно применять в задачах ограничения трафика. Данная задача решается в целях ограничения нагрузки на систему связи для обеспечения требуемых показателей качества обслуживания. В данном случае функцией ИИ является анализ данных о трафике (выделение потоков или пакетов) с целью пропорционального их изменения - стирания (отбрасывания) пакетов. В данном случае имеют место управляемые потери данных, а целью управления может быть, например, недискриминационное (распределенное по нескольким потокам) ограничение трафика. В данном случае может быть использовано обучение с учителем, а качестве данных для обучения могут быть использованы обслуживаемые потоки данных.

2. Технологии ИИ рекомендуется использовать в задачах распределения трафика, а именно в задачах распределения потоков трафика в сети связи. Данные задачи связаны с поиском и выбором маршрутов, а также решением задачи рационального распределения потоков трафика в сети с целью повышения эффективности использования сетевых ресурсов. В таком случае технология ИИ осуществляет выбор маршрутов для потоков трафика на основе анализа данных о состоянии сети связи (данные о маршрутах, загрузке, качестве обслуживания, техническом состоянии). Данная задача решается как задача классификации с использованием обучения с учителем или без учителя в зависимости от реализации.

3. Технологии ИИ также рекомендуется применять в системах анализа технического состояния сети на основе данных о трафике и данных аварийной сигнализации. Данные задачи можно отнести к задачам эксплуатации сети связи. Они могут решаться как задачи классификации на основе исходных данных мониторинга трафика, качества обслуживания, аварийной сигнализации при обучении с учителем. Решением данной задачи может быть диагностика технического состояния сети, которая может быть использована при поиске неисправностей и иных отклонений состояния сети от штатного. Решение данной задачи служит для выявления причин снижения качества функционирования. Для решения данной задачи могут быть использованы методы дерева решений, а также ИНС с обучением с учителем.

Технологии ИИ рекомендуется использовать в задачах генерации трафика:

1. Технологии ИИ могут быть использованы в качестве основы для построения генераторов трафика с заданными свойствами. Генераторы трафика могут быть использованы в задачах эксплуатации сетей связи в качестве средств тестирования оборудования. Данными для обучения являются данные мониторинга трафика в реальной сети связи. Технологии ИИ в данном случае решают задачи аппроксимации модели наблюдаемого трафика. Для решения задачи могут использоваться ИНС с обучением с учителем, в частности, LSTM, а также авторегрессионная модель NARX.

2. Задачи генерации трафика в системах имитационного моделирования. Данные задачи схожи с задачами натурного моделирования трафика, но решаются программным способом в системах имитационного моделирования. В таком случае технологии ИИ могут быть использованы в качестве программных модулей генераторов трафика. Обучение при этом может производится как на статистических данных мониторинга трафика на реальной сети, так и на искусственно полученных данных с целью изучения поведения сети в критических условиях. Решение данных задач аналогично

приведенному выше, т.е. ИНС с обучением с учителем, в частности, LSTM, а также авторегрессионная модель NARX. Отличие заключается в объекте, который представляет собой не физическую сеть, а ее модель.

7. Заключение

В результате выполнения научно-исследовательской работы получены следующие основные результаты:

1. Разработана классификация задач анализа и управления трафиком, которая дает возможность определить рекомендации по использованию технологий искусственного интеллекта для решения этих задач.

Задачи в области анализа и управления трафиком можно условно классифицировать на три группы: задачи анализа трафика, задачи управления трафиком и задачи генерации трафика.

Задачи анализа трафика включают в себя разнообразные задачи сбора статистических данных и их анализа. Целью могут быть: построение аналитической или имитационной модели трафика, оценка параметров трафика, исследование периодичности или долговременных изменений трафика (тренда).

Задачи управления трафиком включают в себя задачи ограничения трафика с целью предотвращения перегрузок элементов сети, задачи маршрутизации трафика, т.е. распределение трафика по возможным маршрутам доставки данных и задачи модификации трафика.

Модификация трафика предполагает некоторое воздействие на трафик с целью изменения свойств потока. Такое воздействие, например, может обеспечить получение требуемых свойств потока для приложений, чувствительных к таким свойствам, например, изменение разброса задержки доставки данных.

Задачи генерации трафика возникают в случае, например, тестирование производительности оборудования или пропускной способности линий

связи. Аналогичные задачи могут возникнуть при построении имитационных моделей, реализуемых в виде компьютерных программ или комбинированных систем моделирования, включающих в себя натурные и имитационные модели.

Задачи моделирования трафика предполагают возможность создания случайного потока с заданными свойствами. Перечень таких свойств может быть различен, набор этих свойств должен быть достаточно широк, чтобы он мог обеспечить получение потока со свойствами, близким к свойствам реального потока, либо некоторого критического (предполагаемого) потока, для которого исследуется функционирование сети связи.

2. Методом экспертных оценок для различных задач по анализу и управлению трафиком была определена степень применимости технологий искусственного интеллекта для тех или иных задач:

N	Задача	Степень применимость ИИ (0-5)
1	Анализ трафика	5
2	Ограничение трафика	3
3	Распределение трафика	5
4	Генерация трафика	4

Как видно из экспертных оценок, в наибольшей степени технологии ИИ применимы в задачах анализа и распределения трафика.

3. Задачи, решаемые с помощью технологий ИИ в области анализа и управления трафиком можно классифицировать следующим образом.

-Задачи классификации – это наиболее востребованный класс задач, при использовании ИИ. Решение задачи заключается в получении ответа о принадлежности к определенному классу на основе на основе набора признаков (в технологиях ИИ описывается как обучение с учителем).

-Задачи регрессии – это задачи прогнозирования на основе выборки некоторых исходных (чаще всего статистических) данных. Решением является вещественное число, представляющее собой прогнозируемое значение некоторого признака.

-Задачи кластеризации – распределение данных на группы по некоторым признакам (в технологиях ИИ описывается как обучение без учителя).

-Задачи понижения размерности – сведение исходного количества признаков к меньшему количеству.

-Задачи выявления выбросов – выделение данных, отличающихся от нормальных случаев. Задача схожа с задачей классификации, разница заключается в малом объеме обучающих данных, содержащих выбросы (аномальные значения).

4. Рассмотрены следующие алгоритмы машинного обучения:

- искусственные нейронные сети,
- деревья решений,
- машины опорных векторов,
- регрессионный анализ,
- байесовские сети,
- генетические алгоритмы,
- федеративное обучение,
- биоинспирированные алгоритмы.

Приведены примеры применения машинного обучения для прогнозирования задержки с использованием нелинейной авторегрессионной рекуррентной нейронной сети с внешними входами NARX и алгоритма обучения Левенберга-Марквардта с обратным распространением, устойчивого алгоритма обучения нейронной сети с обратным распространением) и алгоритма сопряженных градиентов Флетчера-Ривса для обучения нейронной сети с обратным распространением и обновлениями. Для глубокого обучения рассмотрен пример применения

нейронной сети долговременной краткосрочной памяти LSTM (Long Short-Term Memory) с числом скрытых нейронов 50, 200, 500.

5. Робастные оценки широко используются для обработки данных, применяемых для обучения систем ИИ. В задачах контроля данных, предназначенных для обучения систем ИИ, могут быть использованы винзоризованные, усеченные оценки и кусочно-линейные М-оценки в зависимости от вида и формы представления исходных данных.

Наряду с этим робастные оценки могут быть использованы совместно с технологиями ИИ в задачах контроля статистических данных как дополнительный инструмент, позволяющий оценить эффективность работы ИИ, и являющийся дополнительной защитой от грубых ошибок исходных данных в задачах принятия ответственных решений.

6. Разработана методика и получены прогнозы доли оказываемых услуг и доли обслуживаемого трафика с использованием технологий ИИ для сетей связи в мире и в Российской Федерации на горизонте планирования до 2030 года на основе ассоциативного метода. Данный метод заключается в предположении, что динамика развития ИИ, как одного из наиболее перспективных направлений сегодня и в будущем, будет происходить по сценарию близкому к известным сценариям развития наиболее востребованных технологий телекоммуникаций в прошлом. За прототип при этом выбирается статистика развития сетей подвижной связи, как наиболее яркий пример динамики проникновения инноваций. При этом прогноз формируется на базе широко используемой для долгосрочного прогнозирования логистической кривой. Получены корректирующие коэффициенты для точек полуперегиба и наклона логистических кривых в мире и в Российской Федерации.

7. В таблице приведен прогноз доли оказываемых услуг сетями связи с использованием технологий искусственного интеллекта на горизонте планирования до 2030 года включительно для Российской Федерации.

Год	Доля %		
	Оптимистический прогноз	Пессимистический прогноз	Прагматический прогноз
2020	18,16	10,89	14,52
2021	28,83	17,30	23,07
2022	42,53	25,52	34,02
2023	57,47	34,48	45,98
2024	71,17	42,70	56,93
2025	81,84	49,11	65,48
2026	89,17	53,50	71,34
2027	93,76	56,26	75,01
2028	96,49	57,89	77,19
2029	98,05	58,83	78,44
2030	98,92	59,35	79,14

Прагматический прогноз получен при величине предельного проникновения равной 80%, такая величина характерна для проникновения различных услуг, в частности услуг сетей подвижной связи.

Оптимистический прогноз получен при величине предельного проникновения равной 100%, такая величина характерна является предельно достижимой, данный прогноз можно рассматривать как верхнюю границу.

Пессимистический прогноз получен при величине предельного проникновения равной 80% и меньшей скорости проникновения технологий, которая выбрана равной среднемировой.

8. Разработанные в МСЭ-Т рекомендации направлены на систематизацию понятий, определений, моделей и методов использования технологий ИИ в сетях связи. Основной задачей использования технологий ИИ, определенной в рекомендациях серии Y.3170, является обеспечение требований к качеству обслуживания QoS, что непосредственно связано с

задачами анализа и управления обслуживанием трафика в перспективных сетях связи. Вместе с тем, анализ рекомендаций показал, что целесообразна разработка новой рекомендации МСЭ-Т по использованию технологий искусственного интеллекта для анализа и управления трафиком на сетях связи.

9. В процессе научно-исследовательской работы разработан комплекс рекомендаций по применению технологий искусственного интеллекта для задач анализа и управления трафиком на сетях связи, приведенный в разделе 6.3 отчета.

Литература

1. ITU-T Y.1540 IP packet transfer and availability performance parameters. 12/2019.
2. ITU-T Network performance objectives for IP-based services. 12/2011.
3. ITU-T Quality of service regulation manual. URL: https://www.itu.int/dms_pub/itu-d/opb/pref/D-PREF-BB.QOS_REG01-2017-PDF-E.pdf (дата обращения 09.09.2021).
4. ITU-T E.802 Framework and methodologies for the determination and application of QoS parameters. 02/2007.
5. Бесекерский В.А., Попов Е.П. Теория систем автоматического управления. «Профессия», СПб, 752с.
6. Ким Дж.-О., Мьюллер Ч.У., Клекка У.Р. Факторный, дискриминантный и кластерный анализ. М. Финансы и статистика. 1989. 215с.
7. McCulloch, W.S., Pitts, W. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics 5, 115–133 (1943). https://doi.org/10.1007/BF02478259.
8. P M D Tumer and P B Key, A New Call Gapping Algorithm for Network Traffic Management. Elsevier Science Publishers B.V. (North-Holland) © lAC, 1991.
9. Кристофидес Н., Теория графов - Алгоритмический подход. М. Мир. 1978. 249с.
10. Лохмотко В. В., Пирогов К. И. Анализ и оптимизация цифровых сетей интегрального обслуживания. Минск. Наука и техника. 1991. 192с.
11. Шелухин О.И. Фрактальные процессы в телекоммуникациях. М. Радиотехника. 2003.
12. Афифи А., Эйзен С. Статистический анализ: Подход с использованием ЭВМ. М.: Мир, 1982. — 488 с.

13 Ericsson Mobility Report. URL: https://www.ericsson.com/4a03c2/assets/ local/ mobility-report/documents/2021/june-2021-ericsson-mobility-report.pdf (дата обращения 09.09.2021).

14. IDC Forecasts Improved Growth for Global AI Market in 2021. URL: https://www.idc.com/getdoc.jsp?containerId=prUS47482321 (дата обращения 09.09.2021).

15. Cisco Visual Networking Index: Forecast and Trends, 2017–2022. URL: https://twiki.cern.ch/twiki/pub/HEPIX/TechwatchNetwork/HtwNetworkDocuments/white-paper-c11-741490.pdf (дата обращения 09.09.2021).

16. Cisco Annual Internet Report (2018–2023). URL: https://www.cisco.com/c/en/us/solutions/executive-perspectives/annual-internet-report/infographic-c82-741491.html (дата обращения 09.09.2021).

17. Статистика ITU-T. URL: https://www.itu.int/en/ITU-D/Statistics/Documents/facts/ITU_regional_global_Key_ICT_indicator_aggregates_Nov_2020.xlsx (дата обращения 09.09.2021).

18. Статистика ITU-T. URL: https://www.itu.int/en/ITU-D/Statistics/Documents/statistics/2020/MobileBroadbandSubscriptions_2007-2019.xlsx (дата обращения 09.09.2021).

19. Статистика ITU-T. URL: https://www.itu.int/en/ITU-D/Statistics/Documents/statistics/2020/MobileCellularSubscriptions_2000-2019.xlsx (дата обращения 09.09.2021).

20. ITU-T Y.3172, Architectural framework for machine learning in future networks including IMT-2020, June 2019.

21. Supplement 55 to Y.3170 Series, Machine learning in future networks including IMT-2020: use cases. October 2019.

22. ITU-T Y.3173, Framework for evaluating intelligence levels of future networks including IMT-2020., February 2020.

23. ITU-T Y.3174, Framework for data handling to enable machine learning in future networks including IMT-2020, February 2020.

24. ITU-T Y.3176, Machine learning marketplace integration in future networks including IMT-2020, September 2020.

25. ITU-T Focus Group on Machine Learning for Future Networks including 5G. URL: https://www.itu.int/en/ITU-T/focusgroups/ml5g/Pages/default.aspx (дата обращения 10.09.2021)

26. ITU-T Y.1370 Requirements for machine learning-based quality of service assurance for the IMT-2020 network. 09/2018.

27. The 5G Guidea Reference For Operators. URL: https://www.gsma.com/ wp-content/uploads/2019/04/The-5G-Guide_GSMA_2019 04_29_compressed.pdf april 2019 (дата обращения 09.09.2021).

28. Stuart J. Russell and Peter Norvig Artificial Intelligence. A Modern Approach. 1995 by Prentice-Hall, Inc. A Simon & Schuster Company Englewood Cliffs, New Jersey 07632.

29. Ali Zilouchian and Mohammad Jamshidi, Intelligent Control Systems Using Soft Computing Methodologies. Library of Congress Cataloging-in-Publication Data, International Standard Book Number 0-8493-1875-0, Library of Congress Card Number 2001016189.

30. Adrian A. Hopgood, Intelligent Systems for Engineers and Scientists. © 2001 by CRC Press LLC, No claim to original U.S. Government works, International Standard Book Number 0-8493-0456-3, Library of Congress Card Number 00-010341.

31. Абделлах А.Р. Прогнозирование задержки в сетях интернета вещей и тактильного интернета с использованием машинного обучения // Абделлах А.Р., Махмуд О.А., Парамонов А.И., Кучерявый А.Е. / Электросвязь - №1 – 2021 – с.26-30.

32. Abdellah A.R. Delay prediction in IoT using Machine Learning Approach //Abdellah, A.R., Abdulkareem Mahmood, O., Koucheryavy, A. / International Congress on Ultra Modern Telecommunications and Control Systems and Workshops 2020, с. 275-279.

33. Бородин А.С. Метод построения сети связи на базе D2D-технологий с использованием дополнительных маршрутизаторов / А.С.Бородин, А.Е.Кучерявый, А.И.Парамонов // Электросвязь, №4, 2019, с.86-92.

34. Бородин А.С. Маршрутизация трафика в сети беспроводной связи, построенной на базе D2D-технологий / Бородин А.С., Парамонов А.И. // Электросвязь, №2, 2019, с. 38-44.

35. Абделлах А.Р., Кучерявый А.Е. Исследование методов прогнозирования трафика в сетях 5G на основе глубокого обучения. СПбНТОРЭС, Труды ежегодной НТК, №1 (75), 2020, с.155-156.

36. А.С.Бородин, А.Р.Абделлах, А.Е.Кучерявый. Глубокое обучение с долговременной краткосрочной памятью для прогнозирования трафика Интернета Вещей. Электросвязь №2, 2021, с. 48-52.

37. Dixon W.J., Tukey J.W. Approximate Behavior of the Distribution of Winsorized t (trimming/Winsorization 2). Technometrics, 10, 1968, pp.83-98.

38. Huber P.J. Robust Estimation of Location Parameter. The Annals of Mathematical Statistics, v.35, N1, March 1964, pp.73-101.