

# Концепция применения объяснимого искусственного интеллекта для решения задачи распределения трафика

The concept of using explainable artificial intelligence to solve the problem of traffic distribution



**А. В. Морозов,**  
д. т. н., профессор, зам. начальника  
технополиса по научной и образовательной  
деятельности  
✉ era\_otd4@mil.ru

**A. V. Morozov,**  
dr. sci. (tech.), professor, deputy  
head of technopolis for scientific  
and educational activities



**Д. Ю. Пономарев,**  
д. т. н., доцент, с. н. с.,  
научно-исследовательский отдел  
✉ era\_otd4@mil.ru

**D. Yu. Ponomarev,**  
dr. sci. (tech.), docent, senior researcher  
of research department

ФГАУ «Военный инновационный технополис «ЭРА», Анапа, Российская Федерация  
Military innovative technopolis «ERA», Anapa, Russia

Современные инфокоммуникационные сети представляют собой набор значительного числа узлов и каналов связи между ними, что усложняет процесс анализа характеристик таких сетей. Аналитические методы содержат большое число допущений и не могут в полной мере отразить все нюансы процедур обслуживания. Имитационное моделирование позволяет учесть множество составляющих процедур обслуживания, но требует для оценки характеристик реальных сетей больших временных и вычислительных затрат.

В настоящее время существуют методы машинного обучения, использование которых позволяет решать задачи распределения трафика путем оценки характеристик качества обслуживания. Применение методов объяснимого искусственного интеллекта к полученному решению позволяет получить информацию о наиболее влияющих факторах с целью их дальнейшего использования для задачи распределения трафика. Поэтому целью данной работы является разработка концепции применения объяснимого искусственного интеллекта для решения задачи распределения трафика в инфокоммуникационной сети при обеспечении заданного уровня качества обслуживания. Предполагается, что использование данной концепции в перспективных инфокоммуникационных сетях позволит решать задачи управления распределением трафика с целью повышения надежности доставки информации и удовлетворенности пользователей.

Modern infocommunication networks are a set of a significant number of nodes and communication channels between them, which complicates the process of analyzing the characteristics of such networks. Analytical methods contain a large number of assumptions and cannot fully reflect all the nuances of maintenance procedures. Simulation allows you to take into account many components of maintenance procedures, but requires a lot of time and computing costs to assess the characteristics of real networks.

Currently, there are machine learning methods that can be used to solve traffic distribution problems by evaluating service quality characteristics. The methods of explainable artificial intelligence allow us to obtain information about the most influential factors in order to use them further in solving the problem of traffic distribution. Therefore, the purpose of this work is to develop the concept of using explainable artificial intelligence to solve the problem of traffic distribution in an infocommunication network.

**Ключевые слова:** распределение трафика, качество обслуживания, объяснимый искусственный интеллект, инфокоммуникационные сети, время задержки.

**Keywords:** traffic distribution, quality of service, explainable artificial intelligence, infocommunications networks, time delay.

## Введение

Современные инфокоммуникации уже перестали быть просто средой для передачи и обработки информации и сейчас играют роль основного системообразующего пространства для реализации информационных услуг различного вида: от облачных и стримсервисов до тактильного интернета и беспилотных технологий. Охват сфер использования современными инфокоммуникационными сетями также затрагивает целый спектр технологий: от сухопутных и подводных проводных наземных сетей до беспроводных спутниковых (космические аппараты), мобильных (сотовые сети связи), воздушных (использование летательных аппаратов в пределах атмосферы) сетей.

В независимости от вида инфокоммуникационной сети и способа ее построения одним из важнейших элементов при предоставлении услуг является обеспечение заданного качества обслуживания (QoS — Quality of Service) [1]. В зависимости от обслуживаемого потока набор характеристик QoS и пределы их изменения могут быть различны, но в любом случае при оценке качества обслуживания используются такие показате-

тели, как [2-5]: время задержки (среднее, дисперсия и разброс времени задержки) и вероятность потерь (пакетов, кадров, сегментов). При этом характеристики качества обслуживания определяются загрузкой сетевых систем и устройств, участвующих в формировании маршрутов передачи. Загрузка, в свою очередь, зависит от распределения трафика в исследуемой сети. Таким образом, распределение трафика напрямую влияет на качественные показатели инфокоммуникационной сети [2, 4, 6].

Аналитические методы для оценки вышеуказанных характеристик QoS в основном базируются на методах теории массового обслуживания. Однако, в связи с допущениями, используемыми при аналитическом подходе, оценки качества обслуживания для реальных сетей могут иметь отклонения, в некоторых случаях значительные. Ситуация усложняется ростом масштаба сети и увеличением количества маршрутов, используемых для обработки и передачи информационных потоков [1, 2, 5, 7].

В отличие от аналитического подхода применение имитационного моделирования позволяет учесть достаточно большое число факторов, которые при

аналитическом исследовании обычно не рассматриваются, но применение моделирования иногда требует больших временных затрат и не позволяет получить универсального решения [3-5]. В связи с тем, что в современных инфокоммуникациях необходимо обеспечить достаточно быструю реакцию на изменения, происходящие в сети, актуальной задачей является применение методов, позволяющих производить учет большого числа факторов в модели сети с приемлемыми временными затратами.

В некоторых случаях можно использовать интегральный подход, основанный на методах машинного обучения с целью прогнозирования исследуемой характеристики (времени задержки или вероятности потерь). Под интегральным понимается такой подход, который позволяет оценить требуемую характеристику без получения информации о других влияющих факторах: топологии сети, вероятностях переходов и др. [8, 9]. В таком случае, для оценки показателя качества достаточно получить информацию об интенсивности генераторов трафика или матрице распределения трафика [10, 11]. Такой подход, в зависимости от модели машинного обучения, позволяет в приемлемые интервалы времени получить результат оценки требуемой характеристики с учетом реального состояния сети, как по распределению трафика, так и по ее структуре [12-15].

Однако, большое число моделей машинного обучения представляют собой «черный ящик», решение которого сложно оценить с точки зрения достоверности, интерпретируемости и надежности. В таком случае в дополнение к модели машинного обучения необходимо рассматривать методы объяснимого интеллекта (XAI — explainable artificial intelligence), позволяющие оценить насколько корректно получено решение [16, 17]. Более того, модель объяснимого интеллекта позволяет сформировать систему решений, основанную на результатах машинного обучения, но с использованием вычислительных средств меньшей мощности. Полученную систему можно использовать для оценки качества обслуживания информационных потоков и с целью обеспечения оптимального значения качественного показателя производить распределение трафика таким образом, чтобы обеспечить, с заданными ограничениями, например, минимальное время задержки или минимальную вероятность потерь.

Исходя из вышесказанного, целью данной работы является разработка концепции применения объяснимого искусственного интеллекта для решения задачи распределения трафика в инфокоммуникационной сети при обеспечении заданного качества обслуживания.

### Общая постановка задачи

Объектом исследования является инфокоммуникационная сеть, имеющая в своем составе  $N$  узлов, связанных между собой по определенной топологии каналами связи. В граничных узлах сети (на уровне сети доступа) формируется трафик пакетов (сегментов, кадров и т. п.) интенсивностью  $Y$ , который

распределяется по сети, создавая загрузки узлов, что вызывает формирование очередей в соответствующих элементах узлов. Нахождение в очередях приводит к возникновению задержек пакетов при обслуживании, а при ограниченности буфера и к потерям пакетов. Таким образом, для каждого потока можно определить качественные показатели обслуживания, например, в виде среднего времени задержки или вероятности потерь.

Обработка и передача трафика производится путем распределения его по узлам сети в соответствии с определенными маршрутами, сформированными на каналах связи в рамках заданной топологии сети. Интенсивность трафика, создаваемого на сети доступа и в дальнейшем передаваемого по узлам сети, можно представить в виде вектора

$$\Lambda = \begin{pmatrix} \lambda_1 \\ \lambda_2 \\ \dots \\ \lambda_k \end{pmatrix},$$

значения элементов которого определяются интенсивностями генераторов от источников трафика. Вероятности переходов между узлами представляют собой матрицу  $\mathbf{P}$  в виде:

$$\mathbf{P} = \begin{pmatrix} p_{11} & p_{12} & \dots & p_{1n} \\ p_{21} & p_{22} & \dots & p_{2n} \\ \dots & \dots & \dots & \dots \\ p_{n1} & p_{n2} & \dots & p_{nn} \end{pmatrix},$$

где  $p_{ij}$  — доля трафика, передаваемого из узла  $i$  в узел  $j$  (вероятность перехода пакета из узла  $i$  в узел  $j$ ).

Абстрагируясь от физического уровня обработки, задержки в узлах будем рассматривать, как возникающие на участках передачи между узлами. Таким образом, на каждом участке сети пакеты будут получать среднюю задержку, равную:

$$\mathbf{T} = \begin{pmatrix} T_{11} & T_{12} & \dots & T_{1n} \\ T_{21} & T_{22} & \dots & T_{2n} \\ \dots & \dots & \dots & \dots \\ T_{n1} & T_{n2} & \dots & T_{nn} \end{pmatrix},$$

где  $T_{ij}$  — среднее время задержки на участке передачи от узла  $i$  к узлу  $j$ . При ограниченности условных мест ожидания аналогичную матрицу можно записать и для вероятности потерь.

С точки зрения аналитического подхода необходимо найти распределение трафика для каждого участка сети

$$\mathbf{Y} = \begin{pmatrix} y_{11} & y_{12} & \dots & y_{1n} \\ y_{21} & y_{22} & \dots & y_{2n} \\ \dots & \dots & \dots & \dots \\ y_{n1} & y_{n2} & \dots & y_{nn} \end{pmatrix},$$

что позволит определить загрузку систем  $\rho_{ij}$  для заданных значений интенсивностей обслуживания  $\mu_{ij}$  и оценить среднее время задержки, как:  $T_{ij} = f(\rho_{ij})$ . Однако, для реальных систем не всегда можно получить функциональную зависимость среднего времени задержки от загрузки в аналитическом виде.

В таком случае целесообразнее рассматривать методы, позволяющие получить оценку среднего времени задержки при отсутствии аналитического выражения для  $T=f(\rho)$ .

В качестве одного из таких методов можно рассматривать оценку среднего времени задержки с использованием машинного обучения [8, 9, 11-15]. Тогда оценка исследуемой характеристики качества обслуживания будет производиться путем обучения определенной модели на основе набора признаков, в качестве которых могут выступать: размер пакета, длительность сеанса передачи, используемый протокол, идентификатор потока и др. [11-15, 17].

Однако, в процессе обучения модель может некорректно выбрать в качестве наиболее влияющих факторов второстепенные признаки, что приведет к неадекватному решению. С целью оценки достоверности принятого решения при оценке качественных показателей инфокоммуникационной сети в данной работе предлагается в отличие от известных работ использовать методы объяснимого искусственного интеллекта.

### Предлагаемые методы решения

При формировании модели сети необходимо учитывать уровень обработки/передачи и задать уровень абстракции.

В первом случае требуется определить уровень, для которого формируется модель сети: физический, канальный, сетевой, транспортный и т. д., что связано с отличиями в задании генераторов трафика и их интенсивностей, распределении трафика по системам модели, числе элементов модели и т. п.

Для уровня абстракции необходимо оценить какие процессы вносят основной вклад в обслуживание информационных потоков в исследуемой сети и сильно влияют на изучаемые характеристики, а какие процессы могут рассматриваться, как дополнительные. Таким образом, можно уменьшить число элементов и сложность модели сети [1-6].

Исходя из постановки задачи основными признаками (features) для модели машинного обучения являются интенсивности генераторов  $\Lambda$ , интенсивности обслуживания  $\mathbf{M}$ , где

$$\mathbf{M} = \begin{pmatrix} \mu_{11} & \mu_{12} & \dots & \mu_{1n} \\ \mu_{21} & \mu_{22} & \dots & \mu_{2n} \\ \dots & \dots & \dots & \dots \\ \mu_{n1} & \mu_{n2} & \dots & \mu_{nm} \end{pmatrix},$$

и матрица перехода  $\mathbf{P}$ , а целью (target) обучения — среднее время задержки для каждого участка сети или ее модели. Для реальной сети могут рассматриваться и другие признаки, позволяющие более точно сформировать модель машинного обучения [17]: от адресов источников/получателей до среднего размера передаваемых данных за сеанс связи.

На сегодняшний день существует большое количество моделей машинного обучения, которые можно было бы применить к поставленной задаче, но с точки зрения объяснимого искусственного интеллекта все

методы можно разделить на две большие группы: прозрачные методы и методы «черного ящика». К прозрачным относятся такие методы, как линейная регрессия, дерево решений, случайный лес, т. е. такие, где можно достаточно легко выделить наиболее влияющие на цель обучения признаки. Во вторую группу входят методы, основанные на нейрподходах, и использующие глубокое обучение [16, 17].

Линейную регрессию можно использовать в качестве контрольного метода с целью оценки минимального значения целевого признака. Кроме того, обучение модели линейной регрессии не требует больших вычислительных и временных затрат поэтому позволяет провести предварительную оценку используемых признаков. Оценка производится по известным метрикам: среднеквадратичная ошибка (MSE — mean squared error), средняя абсолютная ошибка (MAE — mean absolute error), коэффициент детерминации  $R^2$  и др. [15-17].

Более сложными моделями являются дерево решений и случайный лес. Дерево решений позволяет наглядно представить результат обучения в связи с определенной графовой структурой, но при использовании такой модели необходимо учитывать вероятность переобучения и чувствительность к зашумленным входным данным. Случайный лес позволяет повысить устойчивость к переобучению и шуму, но требует больших по сравнению с деревом решений, вычислительных затрат. С целью оптимизации моделей дерева решений и случайного леса необходимо решать задачи подбора параметров модели.

С целью увеличения точности обучения часто используют различные модели градиентного бустинга (Gradient Boosting), которые обеспечивают более точное обучение за счет применения ансамблевого подхода с уменьшением ошибки предсказания для алгоритма ансамбля на следующем шаге. Сформированная модель градиентного бустинга требует подбора параметров модели для получения наилучшего результата, но позволяет повысить производительность за счет распараллеливания процесса обучения [15-17].

Если при использовании рассмотренных выше моделей можно достаточно просто оценить вклад того или иного признака в целевую функцию обучения, то нейрподходы не обеспечивают прозрачности полученного решения в связи с особенностями структуры нейросетей [12, 13, 16, 17]. В таком случае с целью объяснения решений используются подходы ХАИ, основными методами которого на сегодняшний день являются методы LIME (Local Interpretable Model-agnostic Explanations) и SHAP (Shapley Additive exPlanations). LIME позволяет получить локальное объяснение в окрестностях заданного примера с достаточно низкими вычислительными затратами; а метод SHAP используется как для локального, так и для глобального (для всего набора данных) объяснения решений. Естественно, что SHAP в связи с глобальным подходом обладает большей вычислительной сложностью по сравнению с LIME. При этом оба метода являются независимыми от вида интерпретируемой модели машинного обучения [16].

## Основные положения концепции

В рамках разрабатываемой концепции предполагается, что методы ХАИ позволят повысить эффективность управления распределением трафика в инфокоммуникационных сетях за счет выявления факторов, которые оказывают наибольшее влияние на качественные показатели исследуемых сетей, и использовании этой информации при оптимизации распределения трафика.

Задача оптимизации распределения трафика напрямую связана с задачей управления распределением, которая заключается в том, чтобы путем изменения переходных вероятностей, содержащихся в матрице  $\mathbf{P}$ , привести к такому изменению нагрузки систем  $\mathbf{Y}$  которое либо обеспечит предотвращение перегрузки, либо приведет к повышению качества обслуживания путем минимизации, например, среднего времени задержки.

Предотвращение перегрузки заключается в обеспечении поступления такой нагрузки  $u$  в системы сети, при которой их загрузка  $\rho$  не превысит заданного значения (в предельном случае:  $\rho < 1$ ).

При оптимизации распределения трафика определяется целевая функция, которая отражает цель оптимизации, например, минимизация среднего времени задержки. Далее, вводятся ограничения на целевую функцию, и, любым доступным методом, определяются значения матрицы переходов  $\mathbf{P}$ , позволяющие получить минимальную величину целевой функции при заданных ограничениях. В связи с нелинейностью целевой функции обычно используются различные методы нелинейной оптимизации, например, метод множителей Лагранжа [4-6].

С учетом возможностей машинного обучения кроме переходных вероятностей при анализе реальных сетей необходимо использовать и другие признаки, влияющие на качественные показатели исследуемой сети. В таком случае методы Data Science позволят выявить дополнительные неявные взаимосвязи между параметрами элементов сети или признаками информационных потоков [8, 9, 13, 15].

Процесс машинного обучения с интерпретацией результата (объяснением решения) в общем случае можно представить в виде следующей последовательности этапов (рис. 1).

На первом этапе производится загрузка данных заданной структуры в соответствующем формате. С целью устранения ошибок структурирования данных (пропуски, дублирование, несоответствие типов и т. д.) производится предобработка или подготовка данных.

Исследовательский анализ данных (EDA — exploratory data analysis) посвящен общим вопросам анализа данных: оценка статистических характеристик, выявление аномалий, определение взаимосвязей и дисбаланса и т. д. В результате исследовательского анализа можно сделать вывод о необходимости применения той или иной модели машинного обучения.

Этап обучения модели машинного обучения является наиболее затратным по вычислительным ресурсам

и, соответственно, может занимать довольно продолжительное время. Для обучения модели формируются целевой и обучающие признаки. В процессе обучения должен быть проведен подбор параметров модели таким образом, чтобы обеспечить оптимальное значение заданной метрики обучения MSE, MAE или другой.

При достижении цели обучения и после проверки модели на тестовой выборке необходимо провести выбор модели для объяснения полученного решения. В данной работе предлагаются к применению базовые модели LIME и SHAP для интерпретации полученного в результате машинного обучения решения [16, 17]. С целью получения локального объяснения с относительно небольшими вычислительными затратами, либо для предварительной оценки целесообразнее использовать метод LIME. При необходимости повышения точности объяснения возможно применение метода SHAP, но с большими, относительно метода LIME, затратами.

Результатом интерпретации решения, полученного моделью машинного обучения, является вектор признаков  $\mathbf{Q}$  с указанием степени их вклада в качественные показатели инфокоммуникационной сети:

$$\mathbf{Q} = \begin{pmatrix} q_1 \\ q_2 \\ \dots \\ q_s \end{pmatrix},$$

где  $q_k$  — влияющий признак,  $s$  — общее число таких признаков. В общем случае вектор  $\mathbf{Q}$  включает в себя элементы векторов  $\mathbf{Y}$ ,  $\mathbf{P}$  и другие параметры сети и потоков [15, 17].

Элементы вектора  $\mathbf{Q}$ , которые оказывают наибольшее влияние на исследуемые характеристики качества обслуживания, позволяют определить параметры сети, модификация которых приведет к наибольшему изменению значений QoS при минимальном числе воздействия на элементы сети. В таком случае при небольшом, по числу элементов управления, управляющем воздействии на меньшем интервале времени можно добиться достижения необходимых

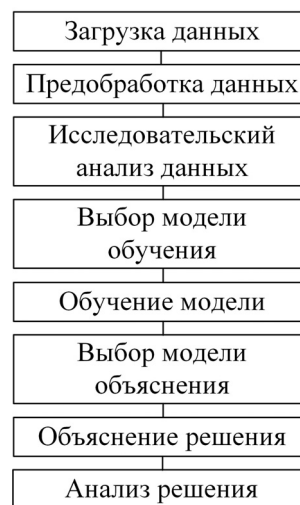


Рис. 1. Этапы процесса машинного обучения с объяснением решения

значений качественных показателей инфокоммуникационной сети.

Применение методов объяснимого искусственного интеллекта позволит выявить наиболее важные составляющие, влияющие на качественные показатели сети. При этом возможно выявление взаимосвязей между данными, которые классическими методами могут быть не обнаружены, что позволяет говорить о новом инструменте анализа распределения трафика в инфокоммуникационной сети.

В дальнейшем требуется провести оценку полученного в результате машинного обучения решения на достоверность о важности влияющих на качественные показатели инфокоммуникационной сети факторов и, при необходимости, произвести уточнение модели.

Полученный методами ХАИ результат интерпретации позволит определить в каком направлении необходимо производить перераспределение трафика с целью предотвращения перегрузки или для оптимизации распределения трафика с целью повышения качественных показателей инфокоммуникационной сети.

### Предлагаемая архитектура решения

С целью практического использования предложенной концепции применения объяснимого интеллекта для решения задачи распределения трафика в инфокоммуникационной сети архитектура системы может содержать следующие элементы (рис. 2): модуль исходных данных, модуль обучения и интерпретации и модуль оценки и управления распределением трафика.

Модуль исходных данных используется для получения информации о структуре, пропускных способностях каналов и узлов исследуемой инфокоммуникационной сети. Данный модуль также используется для формирования информации о действующих значениях загрузок узлов и каналов; значениях показателей качества обслуживания информационных потоков; других значащих параметрах. Таким образом, сформированный массив данных необходим для формирования целевого и обучающих признаков, которые будут использованы в процессе машинного обучения.

В модуле обучения и интерпретации обеспечивается проведение машинного обучения и интерпретация полученного в результате решения с целью анализа влияющих факторов и их степени влияния на качественные показатели инфокоммуникационной сети. Данный модуль формирует значения элементов вектора признаков  $Q$  для дальнейшего их использования

при оценке возможностей изменения распределения трафика в инфокоммуникационной сети.

Модуль оценки и управления распределением трафика обеспечивает формирование оценки интерпретации полученного решения по соответствующим метрикам (достоверность, устойчивость и т. д.) и определение вектора, значения которого позволяют достичь цели управления. В общем случае данный вектор необходим для получения матрицы  $P_{opt}$  с такими значениями переходных вероятностей, которые обеспечивают достижение поставленной цели: предотвращение перегрузки или повышение качества обслуживания.

### Заключение

Тенденции развития инфокоммуникационных технологий в настоящее время демонстрируют необходимость обслуживания множества разнородных информационных потоков, но с предъявлением требований к качеству обслуживания. Основными качественными показателями обработки информационных потоков являются вероятностно-временные характеристики, такие, как время задержки и вероятность потерь. Учитывая необходимость в дальнейшем развитии систем интернета вещей, в том числе и для управления беспилотными системами различного назначения, повышаются требования к снижению задержек и потерь.

В связи с тем, что указанные характеристики QoS в основном зависят от загрузки (нагрузки) обслуживаемых систем, то решение задачи распределения трафика позволит обеспечить процессы поддержки заданного уровня качества обслуживания инфокоммуникационных сетей необходимым механизмом управления. В связи с тем, что современные инфокоммуникационные сети обладают сложной структурой связи между значительным числом элементов и обслуживают большое количество разнородных информационных потоков задача распределения трафика связана с существенными вычислительными и временными затратами. При этом для реальной сети задача плохо формализуема, поэтому необходимо использовать нестандартные подходы.

В представленной работе рассмотрены основные положения концепции применения объяснимого интеллекта к задаче распределения трафика в инфокоммуникационной сети. Использование методов объяснимого интеллекта для решения поставленной задачи позволит выявить из большого количества данных наиболее влияющие на показатели качества обслуживания факторы, что приведет к сокращению



Рис. 2. Архитектура системы управления распределением трафика с использованием машинного обучения

затрат при управлении распределением трафика путем уменьшения участвующих в процессе параметров элементов сети.

С целью практического применения представленных положений концепции необходимо провести дополнительные исследования по определению частных

моделей машинного обучения и их интерпретации, которые можно использовать при решении задачи распределения трафика в инфокоммуникационной сети, и оценить необходимые при выполнении данной задачи вычислительные ресурсы и требования к аппаратным средствам.

#### Список использованных источников

1. В. С. Елагин, А. С. Васин. Анализ моделей управления сетевыми ресурсами в сетях 5G//T-Comm: телекоммуникации и транспорт. 2023. Т. 17. № 5. С. 32-41.
2. Н. М. Редругина. Модели и методы вычисления задержек при предоставлении услуг пользователем на сервисных платформах сеансовых инфокоммуникационных услуг//T-Comm: телекоммуникации и транспорт. 2023. Т. 17. № 4. С. 32-38.
3. М. Е. Сударева, В. Н. Яшин. Анализ граничных задержек в сети TSN Ethernet//Инфокоммуникационные технологии. 2023. Т. 21. № 2 (82). С. 37-43.
4. Д. Ю. Пономарев. Оценка среднего времени задержки в инфокоммуникационных сетях с использованием методов тензорного анализа//Моделирование, оптимизация и информационные технологии. Научный журнал. 2018. Т. 6. № 4. С. 155-167.
5. Д. Ю. Пономарев, А. А. Лацинник. Оценка характеристик процессов передачи информации в комбинированной спутниковой сети//Системы связи и радионавигации. Сб. тезисов. Красноярск: АО «НПП «Радиосвязь», 2023. С. 127-130.
6. А. В. Морозов, Д. Ю. Пономарев. Модель оптимизации распределения информационных потоков в сети Интернета вещей//Известия Российской академии ракетных и артиллерийских наук. 2023. № 3 (128). С. 125-132.
7. R. M. Shukla, S. Sengupta, A. N. Patra. Software-defined network based resource allocation in distributed servers for unmanned aerial vehicles//IEEE 8th Annual Computing and Communication Workshop and Conference. 2018. P. 796-802.
8. T. Springer, E. Linstead, P. Zhao, C. Parlett-Pelleriti. Towards QoS-Based Embedded Machine Learning//Electronics. 2022. 11. P. 3204-3221.
9. P. Larrenie, J. F. Bercher, I. Lahsen-Cherif, O. Venard. Low Complexity Adaptive ML Approaches for End-to-End Latency Prediction//Machine Learning for Networking. MLN 2022. Lecture Notes in Computer Science. Vol. 13767. Cham: Springer, 2023.
10. И. С. Лебедев, И. А. Сикарев, М. Е. Сухопаров, Б. Т. Рзаев. Повышение качественных показателей методов машинного обучения при обработке сетевого трафика на основе сегментирования выборки данных//T-Comm: телекоммуникации и транспорт. 2023. Т. 17. № 9. С. 48-54.
11. F. Krasniqi, J. Elias, J. Leguay, A. E. C. Redondi. End-to-end Delay Prediction Based on Traffic Matrix Sampling//IEEE Infocom 2020 — IEEE Conference on Computer Communications Workshops. 2020. P. 774-779.
12. A. Palaïos, Ch. Vielhaus, D. F. Külzer et al. Machine Learning for QoS Prediction in Vehicular Communication: Challenges and Solution Approaches//IEEE Access. 2023. Vol. 11. P. 92459-92477.
13. M. Farreras, P. Soto, M. Camelo et al. Improving Network Delay Predictions Using GNNs//Journal Network System Management. 2023. 31. P. 65-101.
14. K.-C. Tsai, Z. Zhuang, R. Lent et al. Tensor-Based Reinforcement Learning for Network Routing//IEEE Journal of Selected Topics in Signal Processing. 2021. 15 (3). P. 617-629.
15. А. В. Морозов, Д. Ю. Пономарев. Использование методов Data Science с целью прогнозирования среднего времени задержки в инфокоммуникационных сетях//Известия Российской академии ракетных и артиллерийских наук. 2023. № 4 (129). С. 96-103.
16. M. Mehta, V. Palade, I. Chatterjee. Explainable AI: Foundations, Methodologies and Applications. Intelligent Systems Reference Library. Vol. 232. Cham: Springer, 2023.
17. G. Wassie, J. Ding, Y. Wondie. Traffic prediction in SDN for explainable QoS using deep learning approach//Scientific Reports. 2023. № 13. P. 20607-20623.

#### References

1. V. S. Elagin, A. S. Vasin. Analiz modelej upravleniya setevymi resursami v setyah 5G [Analysis of network resource management models in 5G networks]//T-Comm: Telekommunikacii i transport [T-Comm: Telecommunications and transport]. 2023. Vol. 17. № 5. P. 32-41.
2. N. M. Redrugina. Modeli i metody vychisleniya zaderzhki pri predostavlenii uslug pol'zovatelem na servisnykh platformah seansovykh infokommunikacionnykh uslug [Models and methods for calculating delays in the provision of services by the user on the service platforms of session infocommunication services]//T-Comm: Telekommunikacii i transport [T-Comm: Telecommunications and transport]. 2023. Vol. 17. № 4. P. 32-38.
3. M. E. Sudareva, V. N. Yashin. Analiz granichnykh zaderzhki v seti TSN Ethernet [Analysis of boundary delays in the TSN Ethernet network]//Infokommunikacionnye tekhnologii [Information and communication technologies]. 2023. Vol. 21. № 2 (82). P. 37-43.
4. D. Yu. Ponomarev. Otsenka srednego vremeni zaderzhki v infokommunikacionnykh setyakh s ispol'zovaniem metodov tenzornogo analiza//Modelirovanie, optimizatsiya i informacionnye tekhnologii. Nauchny zhurnal. 2018. T. 6. # 4. S. 155-167.
5. D. Yu. Ponomarev, A. A. Lacinnik. Otsenka harakteristik processov peredachi informacii v kombinirovannoy sputnikovoy seti [Assessment of the characteristics of information transmission processes in a combined satellite network]//Sistemy svyazi i radionavigacii. Sb. tezisov [Communication and radio navigation systems: collection of abstracts]. Krasnoyarsk: AO «NPP «Radiosvyaz», 2023. P. 127-130.
6. A. V. Morozov, D. Yu. Ponomarev. Model' optimizacii raspredeleniya informacionnykh potokov v seti interneta veshchej [A model for optimizing the distribution of information flows in the Internet of Things network]//Izvestiya Rossijskoj akademii raketnykh i artillerijskikh nauk [Proceedings of the Russian Academy of Rocket and Artillery Sciences]. 2023. № 3 (128). P. 125-132.
7. R. M. Shukla, S. Sengupta, A. N. Patra. Software-defined network based resource allocation in distributed servers for unmanned aerial vehicles//IEEE 8th Annual Computing and Communication Workshop and Conference. 2018. P. 796-802.
8. T. Springer, E. Linstead, P. Zhao, C. Parlett-Pelleriti. Towards QoS-Based Embedded Machine Learning//Electronics. 2022. 11. P. 3204-3221.
9. P. Larrenie, J. F. Bercher, I. Lahsen-Cherif, O. Venard. Low Complexity Adaptive ML Approaches for End-to-End Latency Prediction//Machine Learning for Networking. MLN 2022. Lecture Notes in Computer Science. Vol. 13767. Cham: Springer, 2023.
10. I. S. Lebedev, I. A. Sikarev, M. E. Suhoparov, B. T. Rzaev. Povyshenie kachestvennykh pokazatelej metodov mashinnogo obucheniya pri obrabotke setevogo trafika na osnove segmentirovaniya vyborke dannykh [Improving the quality indicators of machine learning methods in processing network traffic based on segmentation of a data sample]//T-Comm: telekommunikacii i transport. [T-Comm: telecommunications and transport]. 2023. Vol. 17. № 9. P. 48-54.
11. F. Krasniqi, J. Elias, J. Leguay, A. E. C. Redondi. End-to-end Delay Prediction Based on Traffic Matrix Sampling//IEEE Infocom 2020 — IEEE Conference on Computer Communications Workshops. 2020. P. 774-779.
12. A. Palaïos, Ch. Vielhaus, D. F. Külzer et al. Machine Learning for QoS Prediction in Vehicular Communication: Challenges and Solution Approaches//IEEE Access. 2023. Vol. 11. P. 92459-92477.
13. M. Farreras, P. Soto, M. Camelo et al. Improving Network Delay Predictions Using GNNs//Journal Network System Management. 2023. 31. P. 65-101.
14. K.-C. Tsai, Z. Zhuang, R. Lent et al. Tensor-Based Reinforcement Learning for Network Routing//IEEE Journal of Selected Topics in Signal Processing. 2021. 15 (3). P. 617-629.
15. А. В. Морозов, Д. Ю. Пономарев. Ispol'zovanie metodov Data Science s cel'yu prognozirovaniya srednego vremeni zaderzhki v infokommunikacionnykh setyah [Using Data Science methods to predict the average delay time in infocommunication networks]//Izvestiya Rossijskoj akademii raketnykh i artillerijskikh nauk. [Proceedings of the Russian Academy of Rocket and Artillery Sciences]. 2023. № 4 (129). P. 96-103.
16. M. Mehta, V. Palade, I. Chatterjee. Explainable AI: Foundations, Methodologies and Applications. Intelligent Systems Reference Library. Vol. 232. Cham: Springer, 2023.
17. G. Wassie, J. Ding, Y. Wondie. Traffic prediction in SDN for explainable QoS using deep learning approach//Scientific Reports. 2023. № 13. P. 20607-20623.