



ОПТИМИЗАЦИЯ МОБИЛЬНОГО ТРАФИКА МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

Д. Д. Алексеева^{1*}, А. В. Марочкина², А. И. Парамонов²

¹Университет Тампере, г. Тампере, 33720, Финляндия

²Санкт-Петербургский государственный университет телекоммуникаций
им. проф. М. А. Бонч-Бруевича,
Санкт-Петербург, 193232, Российская Федерация

*Адрес для переписки: daria.d.alekseeva@gmail.com

Аннотация—Будущие сети предъявляют высокие требования к задержкам, скорости вычисления, качеству передачи данных, и т. д. Внимание к различным проблемам в сетевой области благодаря достижениям Искусственного Интеллекта (ИИ), Машинного обучения (МО) и анализа больших данных (*Big Data*) растет. **Предмет исследования.** Предметом исследования в данной работе является мобильный трафик 4G, собранный в течение одного года. Объем данных, полученных с устройств, и управление сетью мотивируют тенденцию к подходам, основанным на машинном обучении. **Метод.** Методом исследования является сравнение моделей МО для лучшего предсказания трафика. В терминах МО – решение регрессионной задачи с использованием ансамблевых моделей Случайный лес, Boosting, Gradient Boosting и Adaptive Boosting (*AdaBoost*). Сравнение происходило на основе показателей качества RMSE, MAE, и коэффициента детерминации. **Основные результаты.** В результате Gradient Boosting показал наиболее точный прогноз. **Практическая значимость.** Использование данной модели МО для оптимизации мобильного трафика может улучшить показатели сети.

Ключевые слова—машинное обучение, оптимизация, Интернет, трафик.

Информация о статье

УДК 004.725.5

Язык статьи – русский.

Поступила в редакцию 09.03.2021, принята к печати 24.03.2021.

Ссылка для цитирования: Алексеева Д. Д., Марочкина А. В., Парамонов А. И. Оптимизация мобильного трафика методами машинного обучения // Информационные технологии и телекоммуникации. 2021. Том 9. № 1. С. 1–12. DOI 10.31854/2307-1303-2021-9-1-1-12.



TRAFFIC OPTIMIZATION APPLYING MACHINE LEARNING METHODS

D. Alekseeva^{1*}, A. Marochkina², A. Paramonov²

¹Tampere University, Tampere, 33720, Finland

²The Bonch-Bruевич Saint-Petersburg State University of Telecommunications,
St. Petersburg, 193232, Russian Federation

*Corresponding author: daria.d.alekseeva@gmail.com

Abstract—Future networks bring higher communication requirements in latency, computations, data quality, etc. The attention to various challenges in the network field through the advances of Artificial Intelligence (AI), Machine Learning (ML) and Big Data analysis is growing. The subject of research in this paper is 4G mobile traffic collected during one year. The amount of data retrieved from devices and network management are motivating the trend toward learning-based approaches. The research method is to compare various ML methods for traffic prediction. In terms of ML, to find a solution for a regression problem using the ensemble models Random Forest, Boosting, Gradient Boosting, and Adaptive Boosting (AdaBoost). The comparison was based on the quality indicators RMSE, MAE, and coefficient of determination. In the result Gradient Boosting showed the most accurate prediction. Using this ML model for mobile traffic optimization could improve network performance.

Keywords—machine learning, optimization, Internet, traffic.

Article info

Article in Russian.

Received 09.03.2021, accepted 24.03.2021.

For citation: Alekseeva D., Marochkina A., Paramonov A.: Traffic optimization applying machine learning methods // Telecom IT. 2021. Vol. 9. Iss. 1. pp. 1–12 (in Russian). DOI 10.31854/2307-1303-2021-9-1-1-12.



Введение

В настоящее время методы машинного обучения (МО) с успехом применяются в разных сферах [1]. К примеру, в работе [2] при использовании алгоритмов МО для прогнозирования аварий в системах теплоснабжения. В другой работе представлено применение МО для уменьшения количества опасных событий (таких как, например, дефект рельс на железнодорожном пути) за счет прогнозирования редких опасных отказов на основе обработки больших массивов данных [3]. Также алгоритмы МО применяются для решения задач антивирусного сканирования [4], при поиске залежей углеводородов [5], в бизнесе [6], и т. д. Такой интерес к МО связан с его высокими показателями эффективности при анализе больших данных (*Big Data*).

Что касается сферы телекоммуникаций, то будущие сети, сети шестого поколения и сети 2030, представляют высокие требования к задержкам, безопасности, надежности соединения и т. д. Также, в связи с увеличением количества устройств в телекоммуникационной сети и, как следствие, экстремальным ростом информационных потоков, стоит задача найти более эффективные способы управления и контроля сети. Одним из решений этой задачи является применение МО для прогнозирования трафика с целью дальнейшей оптимизации. Алгоритмы МО способны обрабатывать большой объем данных и находить зависимости, которые человеку сложно найти вручную. Также, такие алгоритмы находят лучшее решение конкретной проблемы благодаря статистическому анализу большого объема данных.

В данной работе представлено сравнение нескольких ансамблевых алгоритмов МО – Случайный лес, Bagging, Gradient Boosting, и Adaptive Boosting. Алгоритмы обучались на статистических данных, взятых с сайта [kaggle.com](https://www.kaggle.com). В данных содержится информация о трафике из 57 ячеек сети связи 4G, которые собирались в течение одного года.

Статья состоит из трех частей. В первой части говорится о способах машинного обучения, об используемых в работе алгоритмах, а также о показателях качества модели. Во второй части представлен обзор статей. Третья часть описывает работу по предсказанию трафика.

1 Технология машинного обучения

1.1 Способы обучения

Существует несколько способов машинного обучения – это обучение с учителем (*Supervised Learning*), без учителя (*Unsupervised Learning*), а также обучение с подкреплением (*Reinforcement Learning*). Стоит отметить, что также существуют смешанные способы обучения, которые образуются соединением обучения с учителем и без него. К примеру, к такому способу относится обучение с частичным привлечением учителя (*Semi-supervised learning*), которое наследует характеристики у способов, лежащих в основе. В данной работе мы не будем подробно останавливаться на данном способе, далее представлены определения трех основных способов обучения.

Обучение с учителем. Данный способ подразумевает, что в качестве данных для обучения применяются данные, в которых уже определены зависимости



между входящими и выходящими значениями. Другими словами, алгоритм дает прогноз на основе анализа данных. Обучение с учителем применяется в задачах классификации и регрессии.

Обучение без учителя. В данном способе обучения модель использует немаркированные данные, из которых алгоритм пытается извлечь зависимости. Нейронная сеть самостоятельно находит корреляции в данных и анализирует их. Обучение с учителем применяется в задачах кластеризации и оценки плотности.

Обучение с подкреплением. В обучение с подкреплением входящие данные предоставляются системе из окружающей среды при помощи так называемых агентов. В качестве агентов могут служить разнообразные датчики и сенсоры. Алгоритм находится во взаимодействии с агентом, получая от него данные, а также обратную связь. Примером использования такого способа является анализ данных в YouTube. YouTube анализирует запросы каждого пользователя, и предлагает персональный список потенциально интересного конкретному пользователю контента. Обучение с подкреплением применяется в задачах классификации и регрессии.

1.2 Модели и алгоритмы машинного обучения

МО можно разделить на две группы – классическое и глубокое. Классические методы включают в себя линейные модели, такие как Линейная Регрессия, Логистическая Регрессия, Метод Опорных Векторов, и т. д. Линейные алгоритмы построены на основе линейных функций, где команды выполняются последовательно друг за другом. Также к классическим методам можно отнести ансамблевые модели, которые состоят их нескольких более слабых алгоритмов совершенствуя тем самым точность предсказания. К ансамблевым моделям относят: Случайный лес, Bootstrap Aggregating (сокращенно *Bagging*), Adaptive Boosting (*AdaBoost*) и Gradient Boosting.

В глубоком обучении используются нейронные сети, которые могут находить сложные взаимосвязи в данных [7]. Примерами алгоритмов глубокого метода обучения являются Свёрточная нейронная сеть (CNN), Рекуррентная нейронная сеть (RNN) и др.

В данной работе для моделирования были взяты четыре ансамблевые модели: Случайный лес, Bootstrap Aggregation (*Bagging*), Gradient Boosting и Adaptive Boosting (*AdaBoost*). В таблице 1 представлено сравнение данных алгоритмов.

Таблица 1.

Сравнение алгоритмов

Алгоритм МО	Достоинства	Недостатки
Случайный лес	высокий уровень интерпретации; не требует подготовки входящих данных	подвержен переобучению
Bootstrap Aggregation (<i>Bagging</i>)	не подвержен переобучению; устраняет дисперсию в наборах данных с высокой дисперсией	низкий уровень интерпретации; высокие вычислительные требования



Алгоритм МО	Достоинства	Недостатки
Gradient Boosting	высокие показатели точности	высокие вычислительные требования
Adaptive Boosting (<i>AdaBoost</i>)	не подвержен переобучению	чувствителен к нелинейностям в данных

Случайный лес – это ансамблевая модель для задач классификации и регрессии. Алгоритм работает путем построения множества Деревьев Решений во время обучения и вывода класса.

Bootstrap Aggregation (*Bagging*) – метод, разработанный для повышения стабильности и точности алгоритмов машинного обучения, используемых в статистической классификации и регрессии. Это также снижает дисперсию и помогает избежать переобучения. Хотя он обычно применяется к методам Деревья Решений, его можно использовать с методом любого типа.

Gradient Boosting – это ансамблевый метод, который состоит из нескольких алгоритмов Деревьев Решений. Он строит модель поэтапно, как и другие методы повышения, и обобщает их, позволяя оптимизировать произвольную дифференцируемую функцию потерь. Данная модель решает задачи регрессии и классификации. Несмотря на хорошие показатели, недостатком данной модели является долгое время обучения, что напрямую связано с высокими вычислительными требованиями.

Adaptive Boosting (*AdaBoost*) является классификатором. Он может использоваться в сочетании с несколькими алгоритмами классификации для улучшения их эффективности. *AdaBoost* менее подвержен переобучению по сравнению с другими алгоритмами, однако чувствителен к нелинейностям данных.

1.3 Показатели для оценивания работы алгоритма

Для оценки алгоритмов и их сравнения используются метрики. Другими словами, это такие показатели качества, которые отражают информацию о работе алгоритма. Поэтому важно правильно выбрать метрики исходя из основной задачи исследования. В таблице 2 собраны основные показатели качества для задач классификации и регрессии.

Таблица 2.

Основные показатели качества работы алгоритма для задач классификации и регрессии

Название задачи	Метрика	Определение
Классификация	Точность (<i>accuracy</i>)	отношение количества правильных решений к размеру выборки
	Прецизионность (<i>precision</i>)	степень близости друг к другу независимых результатов измерений, которое вычисляется как стандартное отклонение результатов измерений



Название задачи	Метрика	Определение
	Полнота (<i>recall</i>)	доля значений, правильно отнесенных к определенному классу, относительно всех значений класса в выборке
Регрессии	Среднеквадратическая ошибка (<i>Mean Squared Error</i>)	среднее квадрата разности между прогнозируемым и наблюдаемым значениями
	Средняя абсолютная ошибка (<i>Mean Absolute Error</i>)	разность по модулю между прогнозируемым и наблюдаемым значениями

В таблице 2 перечислены только основные показатели, так как их количество возрастает с разработкой новых алгоритмов. В следующей секции представлен анализ существующей литературы.

2 Обзор литературы

Современные сети имеют сложную архитектуру, которая будет только усложняться с развитием будущих поколений. Прогнозирование трафика – это один из способов оптимизации сети. Это объясняет высокий интерес среди исследователей к применению в инфокоммуникационных сетях алгоритмов МО. Статьи, включенные в данную секцию, сведены в таблице 3.

В работе [8] авторы описывают динамическую модель среза трафика, построенную на основе алгоритма ML-TADS. Предложенная модель равномерно распределяет трафик среди базовых станций для того чтобы исключить перегрузки. Объем передаваемых данных постоянно изменяется, так как зависит от времени суток. Помимо этого, объем трафика увеличивается, если рядом с пользователем происходит какое-то масштабное событие (например, концерт). Если учесть все условия, прогнозировать трафик будет легче. К сожалению, авторы не упоминают методы предварительной обработки данных, без которых алгоритм не станет работать.

В другой работе [9] используется алгоритм глубокого обучения DCRNN, CNN, LSTM, чтобы разгрузить магистральную сеть. С помощью алгоритмов МО для прогнозирования трафика сетевой оператор может эффективно распределять ресурсы. Результаты показали, что DCRNN превосходит другие методы с точки зрения точности прогнозов.

В работе [10] авторы исследуют эффективность различных моделей с точки зрения точности прогнозов и затрат времени на вычисления. Авторы используют SVR, ANN, DNN и LSTM. Наилучший результат по точности прогнозов для предложенных сценариев показал алгоритм SVR. Реальная транспортная инфраструктура состоит из множества участков дорог с разной схемой движения. Поэтому авторы статьи предлагают использовать в будущем алгоритмы обучения с подкреплением, которые позволят более эффективно управлять быстро меняющимися данными в транспортной системе.



В работе [11] авторы предлагают метод повышения точности прогнозирования трафика в ячейках с помощью алгоритмов МО. Модель состоит из наивного байесовского классификатора и алгоритма Хольта-Винтерса.

В работе [12] авторы сравнивают алгоритмы обучения с учителем для оценки трафика в концепции интеллектуальной транспортной системы (ITS). В работе приведено сравнение несколько различных классических алгоритмов регрессии, в том числе метод опорных векторов (SVR), Kernel Ridge, Дерево Решений, Случайный лес и LSTM на данных, собранных из шести разных точек Стокгольма. Результаты продемонстрировали отличную производительность при использовании как алгоритма Случайный лес, так и более сложного алгоритма LSTM. Одним из недостатков этого исследования является то, что исследователи имеют ограниченные достоверные данные, поскольку большее количество данных и большее количество местоположений только улучшат производительность алгоритма.

Таблица 3.

Анализ существующей литературы

Ссылка	Год	Суть работы	Предложенная модель МО	Проблематика
[7]	2018	предложена динамическая модель, которая позволяет управлять трафиком	ML-TADS	в работе нет информации о методах предварительной обработки данных
[8]	2019	применены методы глубокого обучения для выполнения задачи прогнозирования сетевого трафика	DCRNN, CNN, LSTM	в работе нет информации о методах предварительной обработки данных
[9]	2020	приведено исследование эффективности различных моделей прогнозирования с точки зрения точности прогноза и времени вычислений	SVR, ANN, DNN и LSTM	необходимо правильное определение оптимальных параметров алгоритмов и выбор функции ядра
[10]	2019	предложена система, которая позволяет с высокой точностью прогнозировать использование ячеек	наивный байесовский классификатор, алгоритм Хольта-Винтерса	модель предполагает, что в данных признаки независимы
[11]	2021	приведено сравнения различных видов алгоритмов для предсказания трафика в концепции интеллектуальной транспортной системы (ITS)	SVR, Kernel Ridge, Decision Tree, Random Forest и LSTM	ограниченные данные, необходимо правильное определение оптимальных параметров алгоритмов и выбор функции ядра



3 Модель для прогнозирования трафика

Для работы взяты данные с сайта [kaggle.com](https://www.kaggle.com/naebolo/predict-traffic-of-lte-network) «Прогнозирование трафика сети LTE»¹. В данных содержится информация о трафике из каждой ячейки сети 4G. Под трафиком ячейки 4G понимается следующее: когда пользователь использует услугу мобильной передачи данных, мобильное устройство будет обслуживаться ближайшей ячейкой 4G. Общая емкость данных всех пользователей, обслуживаемых ячейкой в течение часа, называется трафиком этой ячейки в течение 1 часа. Например, ячейка 039872 обслуживает 50 абонентов, каждый абонент за 1 час использует в среднем 10 Мб. Таким образом, трафик этой ячейки $x = 50 * 10 = 500$ Мб. Сбор данных проходил в течение 1 года. В результате набор данных получает информацию из 57 ячеек.

Алгоритм работы модели для предсказания трафика представлен на рис.

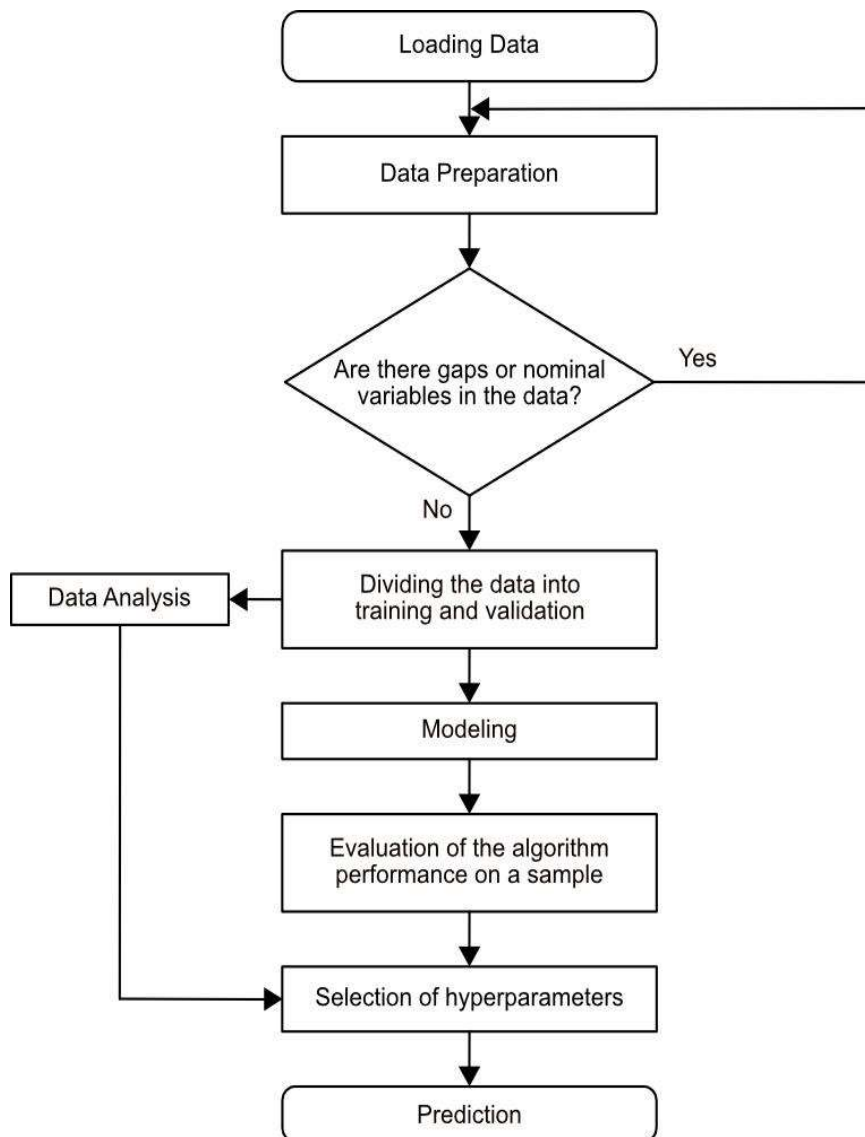


Рис. Алгоритм работы модели для предсказания трафика

¹ <https://www.kaggle.com/naebolo/predict-traffic-of-lte-network>



3.1 Предобработка данных

Первым шагом работы с данными является анализ структуры данных. Чаще всего, собранные данные не идеальны и содержат, например, пропуски в строках. Также они могут содержать ненужную для решения задачи информацию, либо информацию, записанную в категориальном типе. Чтобы не загружать алгоритм, необходима предварительная обработка данных: изменение типа данных (числовой), масштабирование характеристик, заполнение пропусков, или удаление ненужных строк.

Для изменения типа данных из категориального в числовой применяется техника унитарного кодирования. Она предполагает присвоение каждой категории уникального двоичного кода и последующей замены категории на код в базе данных.

Для масштабирования характеристик, другими словами – нормализации диапазона характеристик данных, используется метод минимум-максимум, который заключается в изменении масштаба диапазона характеристик для масштабирования диапазона в $[0, 1]$ или $[-1, 1]$.

Пропуски в данных вызывают различные причины. Это могут быть системные проблемы, потеря пакетов, помехи и т. д. В используемой в работе базе данных пропусков данных нет, либо они были уже удалены до того, как база данных появилась в открытом доступе.

3.2 Анализ зависимостей

На данном этапе необходимо изучить зависимости переменной от признаков, оценить эту зависимость, выяснить, есть ли корреляция между признаками, так как от этого зависит работа алгоритма. В используемой базе данных характер трафика меняется от часа к часу (например, с 10 до 12 часов и с 19 до 23 часов трафик будет очень высоким, с 0 до 6 часов – очень низким). Наблюдается расхождение между днями недели (большой трафик в рабочие дни и низкий в субботу и воскресенье). Также, характер трафика меняется в определенные дни при проведении мероприятий (фестивалей, праздников и т. д.).

3.3 Полученный результат

В данной работе продемонстрировано сравнение трех ансамблевых моделей МО для прогнозирования трафика – Случайный лес, Bagging, Gradient Boosting, и Adaptive Boosting. Результаты представлены в таблице 4 (см. ниже).

Алгоритмы сравниваются на основе показателей RMSE, MAE, и коэффициента детерминации. RMSE представляет собой среднее значение квадрата разницы между реальным и прогнозируемым выходными значениями. Это означает, что чем больше ошибка в прогнозе, тем больше значение показателя RMSE.

Показатель MAE показывает среднее абсолютное значение разницы между реальным и прогнозируемым значениями, и оно может варьироваться от 0 до бесконечности. Чем ниже значение показателя MAE, тем точнее прогноз.



Таблица 4.

Результаты предсказания трафика

Алгоритм	RMSE (Мбит)	MAE (Мбит)	Коэффициент детерминации (%)
Случайный лес	1,478	1,160	34
Bagging	1,278	0,979	51
Gradient Boosting	1,149	0,882	60
AdaBoost	1,607	1,382	22

Коэффициент детерминации показывает корреляцию между значениями. Коэффициент детерминации варьируется от 0 до 100 %, где 100 % означает, что модель наилучшим образом объясняет все расхождения в данных.

Gradient Boosting показал наиболее точный прогноз. При этом Bagging также имеет хорошие показатели, немного отличающиеся от Gradient Boosting. AdaBoost и Случайный лес показали наихудший результат по всем показателям. Низкий процент коэффициента детерминации означает, что данные алгоритмы плохо объясняют зависимости между значениями, следовательно, не подходят для поставленной задачи регрессии.

Заключение

Достоинство применения алгоритмов МО состоит в том, что алгоритмы могут находить зависимости в большом количестве данных. Использование МО для оптимизации сети – перспективное направление для решения проблемы управления потоками данных.

В работе продемонстрировано, что алгоритмы МО могут быть использованы в задачах прогнозирования трафика. Представлено сравнение трех ансамблевых моделей МО для прогнозирования трафика – Bagging, Gradient Boosting, и Adaptive Boosting (*AdaBoost*) на основе метрик RMSE, MAE и коэффициента детерминации. Gradient Boosting показал наиболее точный результат, при этом Adaptive Boosting показал худшие результаты. Это объясняется тем, что данные алгоритмы не подходят для предсказания трафика. Недостатком Gradient Boosting является долгое время обучения модели.

Литература

1. Алемасов Е. П., Зарипова Р. С. Перспективы применения технологий машинного обучения // Информационные технологии в строительных, социальных и экономических системах. 2020. № 2 (20). С. 32–34.
2. Ахваев А. А., Шуршев В. Ф. Применение машинного обучения в прогнозировании предаварийных ситуаций в системах теплоснабжения // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. 2020. № 3. С. 74–81. DOI 10.24143/2072-9502-2020-3-74-81.



3. Шубинский И. Б., Замышляев А. М., Проневич О. Б., Игнатов А. Н., Платонов Е. Н. Применение методов машинного обучения для прогнозирования опасных отказов объектов железнодорожного пути // *Надежность*. 2020. Т. 20. № 2. С. 43–53. DOI 10.21683/1729-2646-2020-20-2-43-53.
4. Пидченко ИА, Выборнова ОН. Применение машинного обучения совместно с эвристическим анализом для задач антивирусного сканирования // *Математические методы в технике и технологиях-ММТТ*. 2020. № 5. С. 96–99.
5. Зарипов БФ, Рыжов ВА. Применение машинного обучения для оценки качества полевого материала пассивных сейсмических наблюдений при поиске и разведке залежей углеводородов по технологии НСЗ // *Нефть. Газ. Новации*. 2020. № 3. С. 11–15.
6. Павлюк М. И. Применение машинного обучения в бизнесе // *Конкурентоспособность территорий : материалы XXIII Всерос. экон. форума молодых ученых и студентов (Екатеринбург, 27–30 апреля 2020 г.) : в 4 ч. / отв. за вып. : Я. П. Силин, Е. Б. Дворядкина. Екатеринбург : Изд-во Урал. гос. экон. ун-та, 2020. Ч. 3. 259 с. С. 95–96.*
7. Ma J. et al. Deep neural nets as a method for quantitative structure–activity relationships // *Journal of chemical information and modeling*. 2015. Vol. 55. Iss. 2. pp. 263–274.
8. Song C. et al. Machine learning enabling traffic-aware dynamic slicing for 5G optical transport networks // *CLEO: Science and Innovations. Optical Society of America*, 2018. pp. JTU2A. 44.
9. Andreoletti D. et al. Network traffic prediction based on diffusion convolutional recurrent neural networks // *IEEE INFOCOM 2019-IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS)*. IEEE, 2019. pp. 246–251.
10. Sun P., Aljeri N., Boukerche A. Machine learning-based models for real-time traffic flow prediction in vehicular networks // *IEEE Network*. 2020. Vol. 34. Iss. 3. pp. 178–185.
11. Clemente D. et al. Traffic forecast in mobile networks: Classification system using machine learning // *2019 IEEE 90th Vehicular Technology Conference (VTC2019-Fall)*. IEEE, 2019. pp. 1–5.
12. Yaghoubi F. et al. Traffic Flow Estimation using LTE Radio Frequency Counters and Machine Learning. arXiv e-prints. 2021. arXiv: 2101.09143.

References

1. Aлемасов Е. Р., Зарипова Р. С. Machine learning perspectives // *Information technologies in construction, social and economic systems*. 2020. Iss. 2 (20). pp. 32–34 (in Russian).
2. Ahvaev A. A., Shurshev V. F. Application of machine training for forecasting emergencies in heat supply systems // *Vestnik of Astrakhan State Technical University. Series: management, computer science and informatics*. 2020. Iss. 3. pp. 74–81 (in Russian). DOI 10.24143/2072-9502-2020-3-74-81.
3. Shubinsky I. B., Zamyshliaev A. M., Pronevich O. B., Platonov E. N., Ignatov A. N. Application of machine learning methods for predicting hazardous failures of railway track assets // *Dependability*. 2020. Vol. 20. Iss. 2. pp. 43–53 (in Russian). DOI 10.21683/1729-2646-2020-20-2-43-53.
4. Pidchenko I. A., Vybornova O. N. Application of machine learning in together with heuristic analysis for anti-virus scanning tasks // 2020. Iss. 5. pp. 96–99 (in Russian).
5. Zaripov B. F., Ryzhov V. A. The application of machine learning for quality assessment of raw field data of passive seismic surveys during the hydrocarbon deposit exploration by LFS technology // *Neft. Gas. Novacii*. 2020. Iss. 3. pp. 11–15 (in Russian).
6. Pavlyuk M. I. Primenenie mashinnogo obucheniya v biznese // *Konkurentosposobnost' territorij : materialy XXIII Vseros. ekon. foruma molodyh uchenyh i studentov (Ekatereburg, 27–30 aprelya 2020 g.) : v 4 ch. / otv. za vyp. : Ya. P. Silin, E. B. Dvoryadkina. Ekaterinburg : Izd-vo Ural. gos. ekon. un-ta, 2020. CH. 3. 259 s. S. 95–96 (in Russian)*.
7. Ma J. et al. Deep neural nets as a method for quantitative structure–activity relationships // *Journal of chemical information and modeling*. 2015. Vol. 55. Iss. 2. pp. 263–274.
8. Song C. et al. Machine learning enabling traffic-aware dynamic slicing for 5G optical transport networks // *CLEO: Science and Innovations. Optical Society of America*, 2018. PP. JTU2A. 44.
9. Andreoletti D. et al. Network traffic prediction based on diffusion convolutional recurrent neural networks // *IEEE INFOCOM 2019-IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS)*. IEEE, 2019. pp. 246–251.
10. Sun P., Aljeri N., Boukerche A. Machine learning-based models for real-time traffic flow prediction in vehicular networks // *IEEE Network*. 2020. Vol. 34. Iss. 3. pp. 178–185.



11. Clemente D. et al. Traffic forecast in mobile networks: Classification system using machine learning // 2019 IEEE 90th Vehicular Technology Conference (VTC2019-Fall). IEEE, 2019. pp. 1–5.
12. Yaghoubi F. et al. Traffic Flow Estimation using LTE Radio Frequency Counters and Machine Learning. arXiv e-prints. 2021. arXiv: 2101.09143.

Алексеева Дарья Денисовна

аспирантка, Университет Тампере, Финляндия,
daria.d.alekseeva@gmail.com

Alekseeva Daria D.

postgraduate, Tampere University,
daria.d.alekseeva@gmail.com

Марочкина Анастасия Вячеславовна

аспирантка Санкт-Петербургского государственного
университета телекоммуникаций
им. проф. М. А. Бонч-Бруевича, anastasiy1996@mail.ru

Marochkina Anastasia V.

postgraduate, The Bonch-Bruevich Saint-Petersburg
State University of Telecommunications,
anastasiy1996@mail.ru

Парамонов Александр Иванович

доктор технических наук, доцент, профессор
кафедры Санкт-Петербургского государственного
университета телекоммуникаций им. проф.
М. А. Бонч-Бруевича, alex-in-spb@yandex.ru

Paramonov Alexander I.

doctor of engineering sciences, docent, professor at the
department, The Bonch-Bruevich Saint-Petersburg State
University of Telecommunications,
alex-in-spb@yandex.ru