

6. Yang H. et al. A survey of artificial immune system based intrusion detection. *The Scientific World Journal*, 2014, vol. 2014, no. 156790,
7. Dasgupta D. *Artificial Immune Systems and Their Applications*. Moscow: Fizmatlit, 2006, 344 p.
8. Astahova I.F., Ushakov S.A. Model and algorithm of artificial immune system. *Matematicheskoe modelirovanie*, 2016, vol. 28, no. 12, pp. 63–73. (In Russ.)
9. Farmer J.D., Packard N., Perelson A. The immune system, adaptation and machine learning. *Physica D: Nonlinear Phenomena*, 1986, vol. 2, pp. 187–204.
10. Kephart J.O. A biologically inspired immune system for computers. *Proceedings of Artificial Life IV: The Fourth International Workshop on the Synthesis and Simulation of Living Systems*, 1994, pp. 130–139.
11. Dasgupta D. *Artificial Immune Systems and Their Applications*. Berlin: SpringerVerlag, 1999, 320 p.
12. Skatkov A.V., Bryukhovetskiy A.A., Moiseev D.V. Adaptation of the Mechanisms of Artificial Immune Systems to Control Environmental Parameters. *Sistemy kontrolja okruzhajuschej sredy*, 2020, no. 2 (40), pp. 127–133. DOI: <https://doi.org/10.33075/2220-5861-2020-2-127-133> (In Russ.)
13. Skatkov A.V., Moiseev D.V., Bryukhovetskiy A.A. Model for vulnerabilities detection in unmanned vehicle interfaces based on artificial immune systems. *Journal of Physics: Conference Series*, 2020, no. 1515, pp. 022043. DOI: <https://doi.org/10.1088/1742-6596/1515/2/022043>
14. Skatkov A.V., Bryukhovetskiy A.A., Moiseev D.V. Adaptive vulnerability detection model for unmanned vehicles drugs based on artificial immune systems. *IOP Conference Series: Materials Science and Engineering*, 2020, no. 734, pp. 012028. DOI: <https://doi.org/10.1088/1757-899X/734/1/012028>
15. Skatkov A.V. et al. *Adaptive Vulnerability Detection of Unmanned Vehicle Interfaces: Monograph*. Simferopol': OOO «Izdatel'stvo Tipografija «Arial», 2020, 352 p. (In Russ.)
16. Myshkis A.D. *Linear Delay Differential Equations*. 2nd Ed. Moscow: Nauka, 1972, 352 p. (In Russ.)
17. Tsyplkin Ya.Z. *Theory of Impulse Systems*. Moscow: Gosudarstvennoe izdatel'stvo fiziko-matematiskoj literatury, 1958, 724 p. (In Russ.)
18. Kamenskij G.A. On the general theory of equations with deviating argument. *Dokl. AN SSSR*, 1958, vol. 120, no. 4, pp. 697–700. (In Russ.)

Received 16.12.2021

УДК 004.852

МНОГОШАГОВОЕ ПРОГНОЗИРОВАНИЕ ПРОПУСКНОЙ СПОСОБНОСТИ КАНАЛОВ МОБИЛЬНОЙ СВЯЗИ 5G FR2

Трошин А.В.

Поволжский государственный университет телекоммуникаций и информатики, Самара, РФ
E-mail: troshin-av@psuti.ru

Для использования всех возможностей мобильных сетей связи пятого поколения требуется освоение нового миллиметрового диапазона частот FR2, который ранее не применялся для мобильной связи. Его применение позволяет достигнуть максимальных скоростей доступа в сетях 5G, однако может приводить к сильным колебаниям пропускной способности каналов во времени. Для ряда мобильных приложений, таких как трансляция видео высокой четкости, может потребоваться адаптация к таким колебаниям на длительных временных интервалах. Такая адаптация возможна с использованием многошагового прогнозирования пропускной способности каналов 5G на основе предыдущих измерений и ряда других внешних факторов. Данная работа посвящена рассмотрению возможностей многошагового прогнозирования пропускной способности каналов 5G FR2 с использованием широкого круга моделей машинного обучения.

Ключевые слова: 5G, машинное обучение, многошаговое прогнозирование, нейронные сети

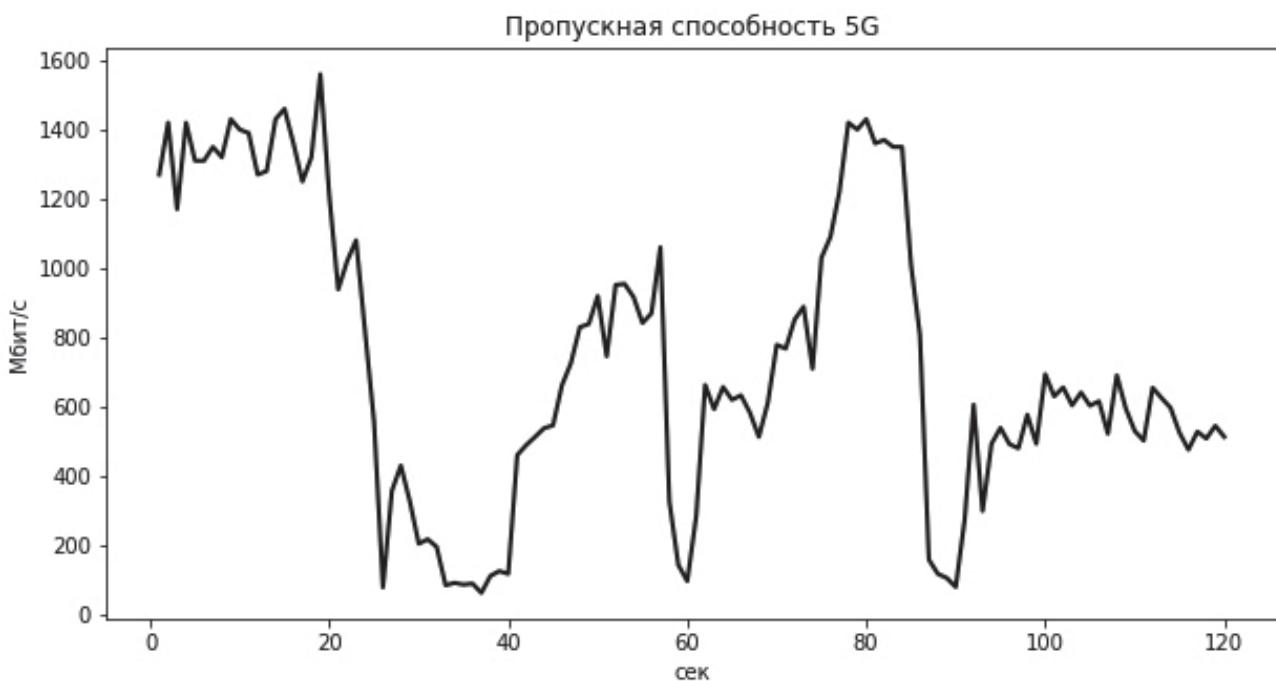


Рисунок 1. Изменение пропускной способности канала 5G FR2 во времени

Введение

По всему миру происходит активный переход к мобильным сетям связи пятого поколения (5G), предлагающим широкий спектр новых услуг и сервисов [1–3]:

- доступ к сети Интернет со скоростью до 2 Гбит/с;
- приложения дополненной и виртуальной реальности (AR/VR);
- поддержку инфраструктуры для беспилотного транспорта;
- интерактивные трансляции видео высокой четкости;
- приложения Интернета вещей (IoT).

Для обеспечения их работы в 5G используется новая технология радиодоступа NR (NewRadio) с двумя диапазонами: FR1 (традиционные частоты 450 МГц … 6 ГГц) и FR2 (частоты 24,24 ГГц … 52,6 ГГц) [4]. 5G-сети с каналами диапазона FR2 в коммерческих целях часто обозначают как 5G mmWave или HighSpeed 5G [3].

Именно использование диапазона частот FR2 позволяет обеспечить максимальную скорость доступа приложений к сети (теоретически до 20 Гбит/с). Однако использование диапазона FR2 приводит к ряду проблем, которые ранее не возникали в низкочастотных диапазонах. К наиболее значительным из них можно отнести: значительно меньшие зоны покрытия базовых станций (до нескольких сот метров), высокую чувствительность к препятствиям на пути распространения радиоволн. Данные проблемы ведут к сложности

установления и поддержания стабильных каналов связи между базовой станцией и пользовательскими устройствами.

С целью преодоления данных проблем в сетях 5G mmWave применяется ряд дополнительных технологий, таких как многоэлементные цифровые антенные решетки (Massive MIMO) и формирование луча (beamforming) [1–3]. Многоэлементные антенны позволяют осуществлять пространственное разделение сигналов от нескольких пользователей, тем самым увеличивая пропускную способность каналов 5G. Технология формирования луча дает возможность комбинировать сигналы от нескольких антенн таким образом, чтобы образовать узкую диаграмму направленности сигнала от базовой станции к пользовательскому устройству, тем самым увеличивая зону покрытия базовой станции и надежность поддержания каналов связи [2].

Практические измерения параметров каналов 5G диапазона FR2 на уже развернутых коммерческих сетях показывают значительные флуктуации пропускной способности как от времени, так и пространственного расположения пользовательских устройств. На рисунке 1 представлены результаты измерений пропускной способности 5G mmWave, проведенные учеными Миннесотского университета на сети оператора Verizon [1; 12].

Из представленных на рисунке 1 результатов измерений видно, что пропускная способность каналов 5G может испытывать значительные изменения во времени, от почти 2 Гбит/с до 0 Гбит/с. Причинами таких изменений являются

как физические препятствия на пути распространения сигнала, так и частый хэндовер между базовыми станциями вследствие их небольших зон покрытий. Данные колебания пропускной способности могут сильно сказываться на качестве работы пользовательских приложений, требующих для работы стабильных высокоскоростных каналов, например интерактивного видео высокой четкости [1–3].

Прогнозирование пропускной способности каналов 5G mmWave является одним из способов повышения качества работы пользовательских приложений за счет оценки и адаптации к возможным изменениям пропускной способности. Традиционные механизмы прогнозирования пропускной способности каналов приложениями основаны либо на текущем значении, либо на усреднении нескольких значений на предыдущем временном интервале работы приложений [1; 5; 9].

Вместе с тем все большее применение для прогнозирования трафика находят методы машинного обучения, в основе которых чаще всего лежат искусственные нейронные сети [5–9]. Однако в подавляющем числе работ, посвященных прогнозированию трафика с помощью методов машинного обучения, в основном рассматриваются модели краткосрочного одношагового прогнозирования. Одношаговые модели наиболее просты, имеют низкие требования к вычислительным ресурсам и объему данных для обучения, однако подходят только для краткосрочной динамической адаптации приложений. Многошаговые модели имеют значительно более высокие требования к вычислительным ресурсам и требуют значительно большего количества данных для обучения, но позволяют приложениям проводить оптимизацию работы на интервалах времени до нескольких десятков секунд [7–8].

Данная работа посвящена рассмотрению возможностей многошагового прогнозирования пропускной способности каналов 5G FR2 на основе широкого круга моделей машинного обучения.

Многошаговое прогнозирование

Многошаговое прогнозирование параметра на основе его предыдущих отсчетов во времени относится к задачам регрессионного анализа и прогнозирования временных рядов [9; 10]. Пусть известен набор предыдущих n -значений параметра x относительно текущего момента времени t : $\{x_t, x_{t-1}, \dots, x_{t-n}\}$, тогда задача многошагового прогнозирования сводится к предсказанию на их основе его последующих m -значений: $\{x_{t+1}, x_{t+2}, \dots, x_{t+m}\}$. Такое прогнозирование часто

называют от последовательности к последовательности и обозначают как *Seq2Seq* (sequence-to-sequence) [6].

Многошаговое прогнозирование временных рядов может выполняться на основе моделей машинного обучения с векторным выходом, которые способны сразу прогнозировать вектор m -значений [11]. Примерами моделей с векторным выходом являются k ближайших соседей (kNN), дерево решений, искусственные нейронные сети. Преимуществом моделей с векторным выходом считается непосредственное прогнозирование сразу всех значений временного ряда, однако данные модели имеют большое количество параметров, что требует больших вычислительных ресурсов и объемов данных для обучения.

Для многошагового прогнозирования также могут использоваться и одношаговые модели, способные непосредственно прогнозировать только одно последующее значение временного ряда. Примерами таких моделей являются автoregressионные модели, метод опорных векторов и градиентного бустинга. Поскольку одношаговые модели, как правило, проще в реализации и имеют меньшее количество параметров, то они предъявляют меньшие требования к вычислительным ресурсам и объемам данных для обучения.

Многошаговое прогнозирование на основе одношаговых моделей может выполняться тремя способами: рекурсивным, прямым многошаговым и гибридным рекурсивно-прямым [11].

При рекурсивном подходе используется единственная одношаговая модель, выполняющая m последовательных прогнозов, каждое значение, полученное на предыдущем шаге, используется для следующего прогноза. При рекурсивном способе на каждом шаге происходит накопление ошибки, что ограничивает данный способ только краткосрочными интервалами (на 2–3 шага).

В прямом пошаговом способе применяется m моделей, каждая из которых используется для прогнозирования своего отдельного шага. Данный способ позволяет избавиться от ограничений рекурсивного метода, однако требует больших вычислительных ресурсов и объемов данных при обучении. Помимо этого, данный способ не позволяет учитывать зависимости между разными прогнозируемыми шагами.

Отличие гибридного рекурсивно-прямого способа от прямого способа заключается в том, что каждая последовательная модель использует прогноз предыдущей модели. Такой подход по-

зволяет учитывать зависимости между шагами, как в моделях непосредственного прогнозирования, однако такой способ является и наиболее сложным для практической реализации.

Выбор того или иного способа многошагового прогнозирования определяется характером задачи, вычислительными ресурсами и объемом данных для обучения. При наличии значительной корреляции между значениями соседних шагов необходимо использование модели с векторным выходом или гибридного прогнозирования с помощью одношаговых моделей. В случаях когда такой взаимосвязью можно пренебречь, можно использовать прямое многошаговое прогнозирование. При необходимости только краткосрочного прогнозирования может быть использован рекурсивный способ. Также необходимо определить наличие зависимости прогнозируемого параметра от каких-либо внешних факторов, например координат пользователя мобильной связи. Такие факторы в виде независимых переменных могут учитываться или не учитываться моделью [11].

Описание исходных данных

Исходные данные, использованные в работе, представляют собой набор измерений пропускной способности каналов 5G mmWave на сети оператора Verizon с помощью утилиты iperf, проведенные с периодом в 1 секунду [12]. Кроме пропускной способности (Throughput) в Мбит/с данные включают ряд дополнительных внешних факторов, таких как:

- координаты местоположения пользовательского устройства: широту (*latitude*) и долготу (*longitude*);
 - скорость движения (*movingSpeed*): данные, измеренные устройством с ОС Android;
 - направление движения (*compassDirection*): угол расположения пользовательского устройства относительно Северного полюса;
 - показатели подключения к сети 5G NR: *nrStatus*, *nr_ssRsrp*, *nr_ssRsrq*, *nr_ssSinr*;
 - показатели сигнала мобильной сети на прием: *lte_rssi*, *lte_rsrp*, *lte_rsrq*, *lte_rssnr*;
 - тип мобильности пользователя (*mobility_mode*): ходьба (*walking*) или вождение (*driving*);
 - траектория движения (*trajectory_direction*): по часовой стрелке (CW) или против часовой стрелки (ACW);
 - идентификатор базовой станции (*tower_id*).
- Для удобства исследования влияния внешних факторов на пропускную способность каналов их можно объединить в следующие группы [1]:
- местоположение (L): широта и долгота;

- движение (M): скорость, вид и направление;
- параметры подключения к 5G (C): показатели подключения и сигнала, идентификатор базовой станции.

Данные группы параметров можно также комбинировать для сравнения их общего влияния:

- местоположения и движения (L+M);
- местоположения и подключения (L+C);
- движения и подключения (M+C);
- местоположения, движения и подключения (L+M+C).

Результаты прогнозирования

Для многошагового прогнозирования были использованы следующие классические и ансамблевые модели машинного обучения:

- k ближайших соседей (kNN);
- дерево решений (DTree);
- леса случайных деревьев (RForest);
- экстремальные деревья (ExTree);
- градиентного бустинга (GBoost).

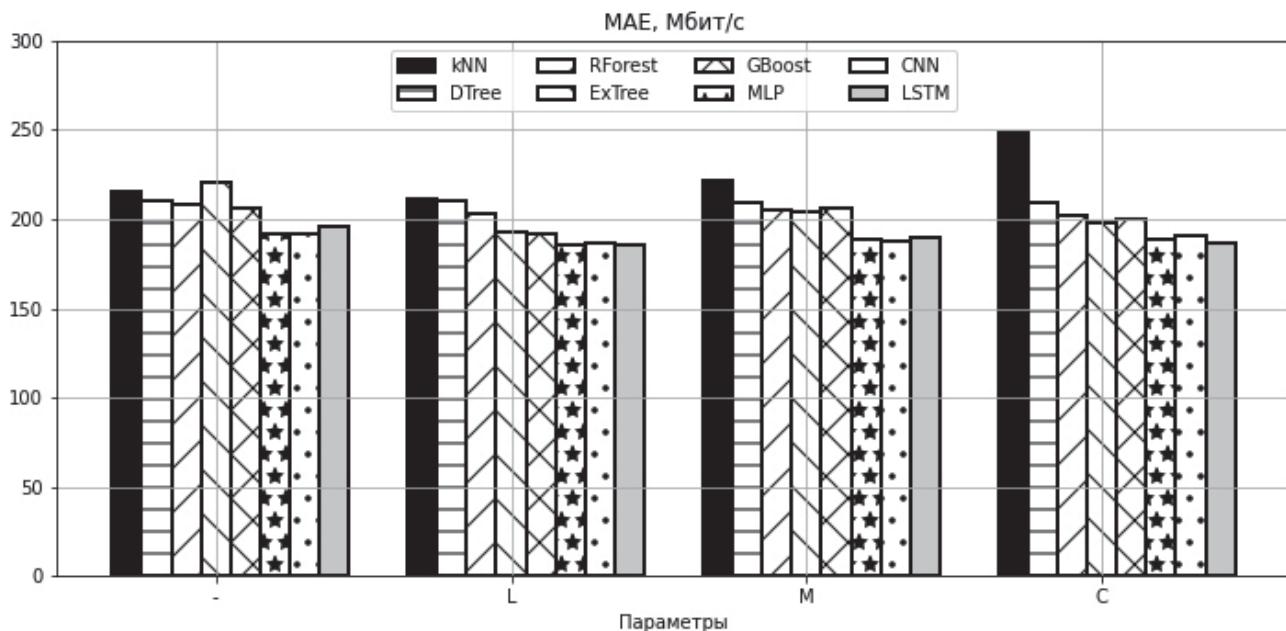
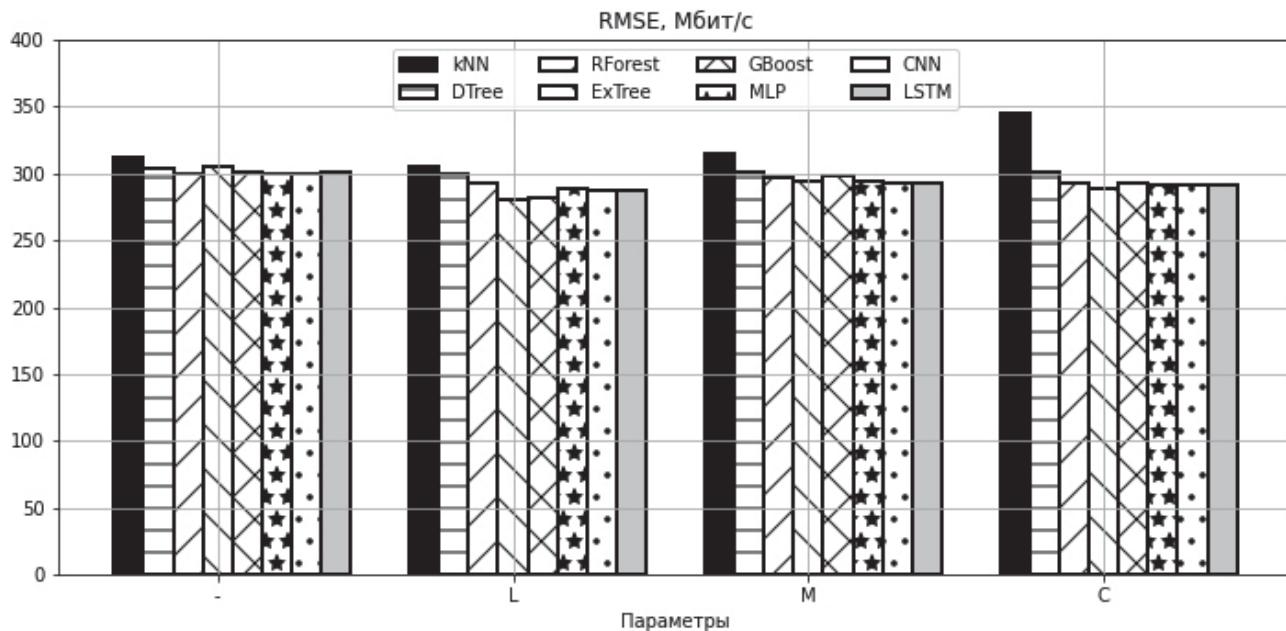
Также применялись модели, основанные на искусственных нейронных сетях:

- многослойный персептрон (MLP);
- сверточная нейросеть (CNN);
- рекуррентная нейросеть с LSTM-памятью (LSTM).

Для расчетов применялись модели kNN, DTrees и ExTree, реализованные в пакете Scikit-Learn. При реализации прогнозирования моделями RFoest и GBoost применялись их реализации из пакета XGBoost с использованием прямого многошагового прогнозирования из пакета Sklear-Learn. Для нейросетевых моделей применялся пакет TensorFlow. Исходные коды всех использованных моделей в формате Jupyter Notebook представлены в репозитории [13].

Для обучения моделей использовались 80 % данных, оставшиеся 20 % применялись для оценки точности прогнозирования. Прогнозирование осуществлялось для интервала в 10 секунд с шагом в 1 секунду. Прогноз выполнялся на основе данных за предыдущие 20 секунд с шагом в 1 секунду. Такие значения были выбраны, поскольку по результатам ряда исследований они обеспечивают наибольшую точность прогнозирования для каналов мобильной связи [6].

В качестве метрик оценки точности прогнозирования применялись средняя абсолютная ошибка (*MAE* – MeanAbsoluteError) и квадратный корень среднеквадратической ошибки (*RMSE* – Root Mean Squared Error), поскольку данные показатели имеют одинаковую размерность с прогнозируемой величиной [6–8].

Рисунок 2. *MAE* для групп параметровРисунок 3. *RMSE* для групп параметров

Показатель *MAE* оценивает среднюю величину ошибки прогнозирования относительно истинного значения без учета ее знака для тестовых данных:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i|, \quad (1)$$

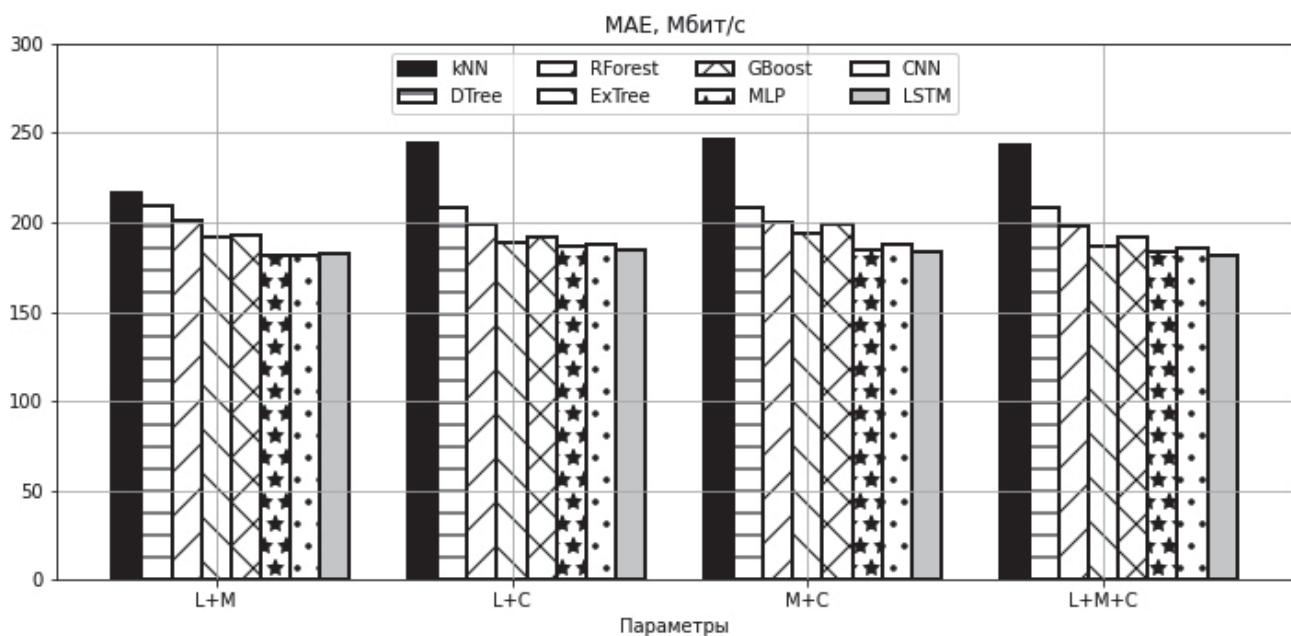
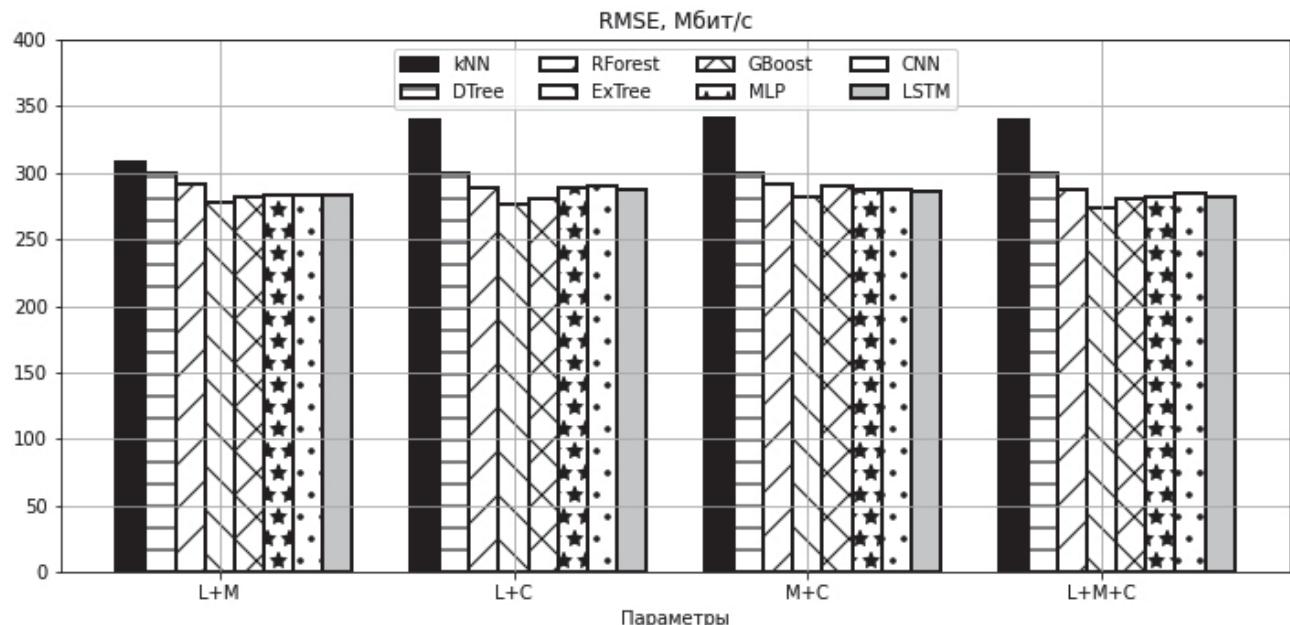
где n – количество данных в teste; y_i – истинное значение; y'_i – спрогнозированное значение.

Показатель *RMSE* определяется как корень квадратный из среднеквадратической ошибки:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2}. \quad (2)$$

Оба показателя по-разному характеризуют ошибку прогнозирования: *MAE* в основном зависит от среднего значения ошибки, в то время как для *RMSE* значительный вклад имеет дисперсия ошибки (рисунки 2, 3).

В качестве базовых критериев оценки точности моделей машинного обучения применялись: наивное прогнозирование (Naive), при котором для прогноза использовались исходные данные, а также прогнозирование на основе среднего значения (Average), при котором прогнозирование выполнялось путем усреднения исходных данных. Для наивного прогнозирования были получены $MAE = 270,6$ Мбит/с; $RMSE = 415,5$ Мбит/с.

Рисунок 4. *MAE* для комбинаций групп параметровРисунок 5. *RMSE* для комбинаций групп параметров

Для прогнозирования путем усреднения получены значения $MAE = 237,3$ Мбит/с; $RMSE = 359$ Мбит/с.

Результаты оценки точности прогнозирования без и с учетом отдельных внешних факторов представлены для удобства восприятия в виде столбчатых диаграмм на рисунках 2 и 3.

Как видно из представленных результатов, все модели имеют меньшие значения ошибок в сравнении с наивным и усредненным прогнозированием. Наименьшие значения MAE обеспечивают модели, основанные на искусственных нейронных сетях. Для показателя $RMSE$ модели градиентного бустинга и экстремальных деревьев

показывают сравнимые результаты с нейросетевыми моделями. Из внешних факторов практически для всех методов наибольшее влияние на снижение ошибки прогнозирования оказывает местоположение, далее следуют группы параметров движения и подключения к сети 5G.

Результаты оценки точности прогнозирования при учете различных комбинаций групп внешних параметров представлены в виде столбчатых диаграмм на рисунках 4 и 5.

Как видно из представленных на рисунках 4 и 5 результатов, для комбинаций групп внешних факторов наблюдается аналогичная картина, что и для отдельных факторов. Нейросетевые модели

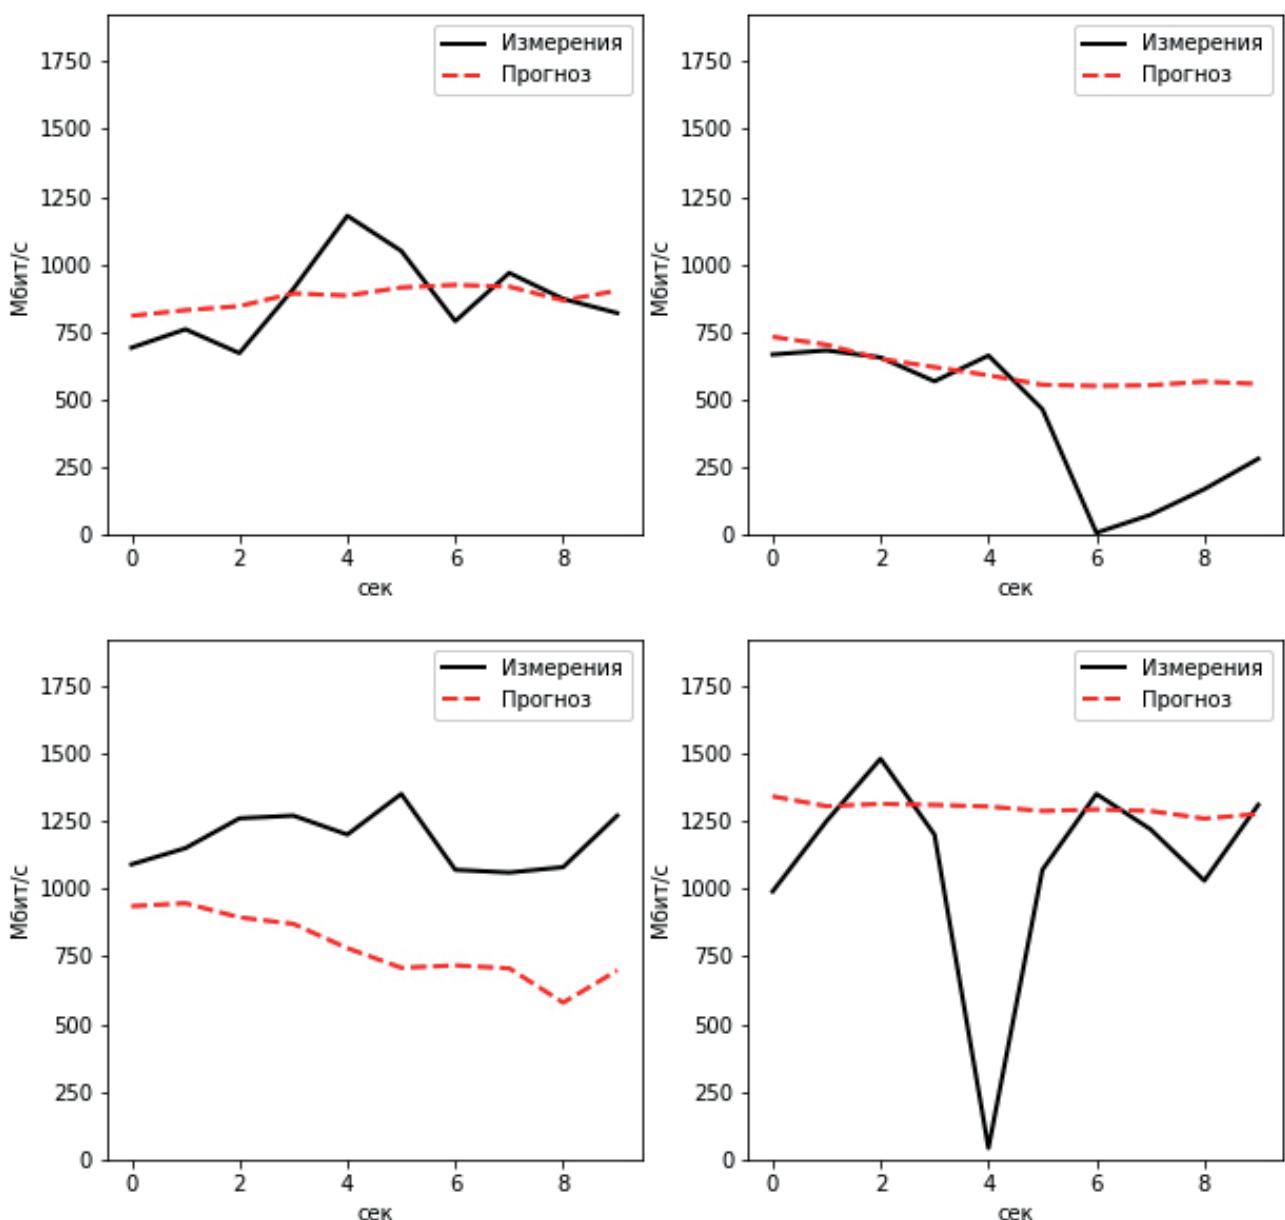


Рисунок 6. Пример сравнения измеренных и спрогнозированных значений

обеспечивают наименьшее значение MAE , в то время как наименьшее значение $RMSE$ обеспечивают нейросетевые модели с моделями градиентного бустинга и экстремальных деревьев. Наименьшие значения MAE и $RMSE$ обеспечивают сочетания L+M и L+M+C.

Примеры сравнения измеренных значений пропускной способности каналов с прогнозируемыми представлены на рисунке 6. Прогнозирование выполнено с помощью сверточной нейросети при учете всех внешних факторов.

Заключение

В данной статье были рассмотрены основные способы многошагового прогнозирования временных рядов с использованием наиболее распространенных моделей машинного обучения.

Данные способы были использованы для прогнозирования пропускной способности каналов 5G FR2.

На основании результатов прогнозирования можно сделать вывод о том, что наименьшую среднюю абсолютную ошибку многошагового прогнозирования MAE обеспечивают нейросетевые модели. Поскольку различия в величинах ошибок разных моделей весьма незначительны, то для практического применения можно рекомендовать модель сверточной нейросети, поскольку данная модель требует наименьших вычислительных ресурсов при реализации.

Близкие значения квадратного корня из среднеквадратической ошибки многошагового прогнозирования $RMSE$ обеспечивают нейросетевые и ансамбльные модели. В связи с этим для

практического использования можно рекомендовать ансамбльные модели, так как они требуют значительно меньших вычислительных ресурсов при реализации и обучении.

Литература

1. Lumos5G: Mapping and predicting commercial MmWave 5G throughput / A. Narayanan [et al.] // Proceedings of the ACM Internet Measurement Conference. 2020. P. 176–193.
2. 5G. URL: <https://ru.wikipedia.org/wiki/5G> (дата обращения: 20.11.2021).
3. Что такое sub-6GHz, mmWave? Зачем нужен 5G? URL: <https://habr.com/ru/post/524854> (дата обращения: 20.11.2021).
4. 5G NR frequency bands. URL: https://en.wikipedia.org/wiki/5G_NR_frequency_bands (дата обращения: 20.11.2021).
5. Efficient prediction of network traffic for real-time applications / Z. Xu [et al.] // Journal of Computer Networks and Communications. 2019. Vol. 2019. DOI: <https://doi.org/10.1155/2019/4067135>
6. DeepChannel: Wireless channel quality prediction using deep learning / A. Kulkarni [et al.] // IEEE Transactions on Vehicular Technology. 2020. Vol. 69, no. 1. P. 443–456. DOI: <https://doi.org/10.1109/TVT.2019.2949954>
7. Chandra R., Goyal S., Gupta R. Evaluation of deep learning models for multi-step ahead time series prediction // IEEE Access. 2021. Vol. 9. P. 83105–83123. DOI: <https://doi.org/10.1109/ACCESS.2021.3085085>
8. Huang C., Chiang C., Li Q. A study of deep learning networks on mobile traffic forecasting // IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC). 2017. P. 1–6. DOI: <https://doi.org/10.1109/PIMRC.2017.8292737>
9. Трошин А.В. Машинное обучение для прогнозирования трафика в сети LTE // Инфокоммуникационные технологии. 2019. Т. 17, № 4. С. 400–407. DOI: <https://doi.org/10.18469/ikt.2019.17.4.06>
10. Brownlee J. Taxonomy of Time Series Forecasting Problems. URL: <https://machinelearningmastery.com/taxonomy-of-time-series-forecasting-problems/> (дата обращения: 20.11.2021).
11. Brownlee J. 4 Strategies for Multi-Step Time Series Forecasting. URL: <https://machinelearningmastery.com/multi-step-time-series-forecasting/> (дата обращения: 20.11.2021).
12. Lumos5G: Mapping and Predicting Commercial MmWave 5G Throughput / A. Narayanan [et al.]. URL: <https://lumos5g.umn.edu/> (дата обращения: 20.11.2021).
13. Troshin A. 5G Throughput Prediction. URL: <https://github.com/av-troshin77/5gthroughput> (дата обращения: 20.11.2021).

Получено 20.12.2021

Трошин Александр Викторович, к.т.н., доцент кафедры сетей и систем связи Поволжского государственного университета телекоммуникаций и информатики. 443010, Российская Федерация, г. Самара, ул. Л. Толстого, 23. Тел. +7 846 339-11-26. E-mail: troshin-av@psuti.ru

MULTI-STEP THROUGHPUT PREDICTION OF 5G FR2 MOBILE CHANNELS

Troshin A.V.

Povelzhskiy State University of Telecommunications and Informatics, Samara, Russian Federation
E-mail: a.v.troshin77@yandex.ru

For all advantages of 5G mobile networks the new millimeter frequency band FR2 needs to be deployed. It has not yet been used for mobile services. The deployment of the FR2 band allows for the maximum speeds of 5G mobile channels but their throughput can wildly fluctuate over time. Some mobile applications, such as ultra high-definition video streaming, need to adapt for varying channel speeds on long time intervals. This adaptation can be realized with a multi-step throughput prediction of 5G mobile channels based on the previous measurements and some external factors. This paper explores the multi-step throughput prediction of 5G FR2 channels with an application of a wide range of machine learning methods.

Keywords: 5G, machine learning, multi-step prediction, neural networks

DOI: 10.18469/ikt.2021.19.4.05

Troshin Alexander Victorovich, Povolzhskiy State University of Telecommunications and Informatics, 23, L. Tolstoy Street, Samara, 443010, Russian Federation; Assistant Professor of Networks and Systems of Telecommunication Department, PhD in Technical Science. Tel. +7 846 339-11-26. E-mail: troshin-av@psuti.ru

References

1. Narayanan A. et al. Lumos5G: Mapping and predicting commercial MmWave 5G throughput. *Proceedings of the ACM Internet Measurement Conference*, 2020, pp. 176–193.
2. 5G. URL: <https://ru.wikipedia.org/wiki/5G> (accessed: 20.11.2021).
3. What is sub-6GHz, mmWave? Why is 5G needed? URL: <https://habr.com/ru/post/524854> (accessed: 20.11.2021). (In Russ.)
4. 5G NR frequency bands. URL: https://en.wikipedia.org/wiki/5G_NR_frequency_bands (accessed: 20.11.2021).
5. Xu Z. et al. Efficient prediction of network traffic for real-time applications. *Journal of Computer Networks and Communications*, 2019, vol. 2019. DOI: <https://doi.org/10.1155/2019/4067135>
6. Kulkarni A. et al. DeepChannel: Wireless channel quality prediction using deep learning. *IEEE Transactions on Vehicular Technology*, 2020, vol. 69, no. 1, pp. 443–456. DOI: <https://doi.org/10.1109/TVT.2019.2949954>
7. Chandra R., Goyal S., Gupta R. Evaluation of deep learning models for multi-step ahead time series prediction. *IEEE Access*, 2021, vol. 9, pp. 83105–83123. DOI: <https://doi.org/10.1109/ACCESS.2021.3085085>
8. Huang C., Chiang C., Li Q. A study of deep learning networks on mobile traffic forecasting. *IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, 2017, pp. 1–6. DOI: <https://doi.org/10.1109/PIMRC.2017.8292737>
9. Troshin A.V. Machine learning for traffic prediction in LTE network. *Infokommunikacionnye tehnologii*, 2019, vol. 17, no. 4, pp. 400–407. DOI: <https://doi.org/10.18469/ikt.2019.17.4.06> (In Russ.)
10. Brownlee J. Taxonomy of Time Series Forecasting Problems. URL: <https://machinelearningmastery.com/taxonomy-of-time-series-forecasting-problems/> (accessed: 20.11.2021).
11. Brownlee J. 4 Strategies for Multi-Step Time Series Forecasting. URL: <https://machinelearningmastery.com/multi-step-time-series-forecasting/> (accessed: 20.11.2021).
12. Lumos5G: Mapping and Predicting Commercial MmWave 5G Throughput / A. Narayanan [et al.]. URL: <https://lumos5g.umn.edu/> (accessed: 20.11.2021).
13. Troshin A. 5G Throughput Prediction. URL: <https://github.com/av-troshin77/5gthroughput> (accessed: 20.11.2021).

Received 20.12.2021

ТЕХНОЛОГИИ КОМПЬЮТЕРНЫХ СИСТЕМ И СЕТЕЙ

УДК 004.057.4

ОСОБЕННОСТИ КОММУНИКАЦИИ МИКРОСЕРВИСОВ ПРИ ИСПОЛЬЗОВАНИИ ШАБЛОНА САГА

Малюга К.В., Перл И.А.

Национальный исследовательский университет ИТМО, Санкт-Петербург, РФ

E-mail: konstantin.malyuga@gmail.com

Сегодняшние облачные решения очень часто строятся на основе микросервисной архитектуры. При таком подходе система реализуется в виде набора слабо связанных сервисов, которые не разделяют общего хранилища и обмениваются данными и командами по сети. Наряду с преимуществами такая структура системы привносит