

## Анализ применения машинного обучения в системах 5G

Ерназар Нуржамиевич Рейпназаров

Салтанат Кудайбергенова

Ташкентский университет информационных технологий

**Аннотация:** В статье предусматривается анализ существующих методов и алгоритмов машинного обучения, применяемых в системах 5G, а также определение перспектив их дальнейшего развития и интеграции в будущие поколения сетей связи (6G), об инфраструктуре сети и ее качественных характеристиках, например о пропускной способности, задержке распространения сигнала в сети, фазовых дрожаниях сигнала (джиттере), режиме передачи, длительности сеанса связи и др. Эти данные динамически формируют пространственно-временной профиль каждого пользователя в сети. Данные пользователя представляют собой его собственный информационный поток данных, которые он создает.

**Ключевые слова:** беспроводные сети, система 5G, метод машинного обучения, однопользовательская система, многопользовательская система, помех между сотами, многоуровневый персептрон, сигмоидальную функцию передачи, оптимальное распределение ресурсов

## Analysis of the application of machine learning in 5G systems

Ernazar Nurjamiyevich Reypnazarov

Saltanat Kudaybergenova

Tashkent University of Information Technologies

**Abstract:** The article provides an analysis of existing methods and algorithms of machine learning used in 5G systems, as well as determining the prospects for their further development and integration into future generations of communication networks (6G), about the network infrastructure and its quality characteristics, such as bandwidth, signal propagation delay in the network, signal jitter, transmission mode, communication session duration, etc. This data dynamically forms a spatiotemporal profile of each user on the network. A user's data represents their own information flow, the data they create.

**Keywords:** wireless networks, 5G system, machine learning method, single-user system, multi-user system, inter-cell interference, multilayer perceptron, sigmoid transfer function, optimal resource allocation

**Введение.** Развитие технологий мобильной связи пятого поколения (5G) стало ключевым этапом в эволюции телекоммуникационных систем, обеспечивая высокую пропускную способность, минимальные задержки и массовое подключение устройств в рамках концепции Интернета вещей (IoT). Однако столь высокая сложность архитектуры сетей 5G, включающей гетерогенные узлы, динамическое распределение ресурсов и необходимость адаптации к быстро изменяющимся условиям, требует внедрения интеллектуальных методов управления и оптимизации. Одним из наиболее перспективных направлений в решении данных задач является применение методов машинного обучения (ML). Алгоритмы машинного обучения позволяют анализировать большие объемы сетевых данных, прогнозировать нагрузку, оптимизировать маршрутизацию, распределение спектра и управление энергопотреблением, а также повышать уровень безопасности и надежности сети. В отличие от традиционных детерминированных подходов, ML-системы способны к самообучению и адаптации, что особенно важно для динамичных и распределённых сетевых структур 5G.

Актуальность исследования обусловлена необходимостью разработки интеллектуальных механизмов управления сетями нового поколения, которые смогут обеспечивать оптимальное использование ресурсов при одновременном повышении качества обслуживания (QoS) и пользовательского опыта (QoE). В рамках данного исследования рассматриваются основные направления применения машинного обучения в сетях 5G, включая оптимизацию радиоресурсов, управление трафиком, предсказание состояния каналов связи и обеспечение кибербезопасности.

Целью работы является анализ существующих методов и алгоритмов машинного обучения, применяемых в системах 5G, а также определение перспектив их дальнейшего развития и интеграции в будущие поколения сетей связи (6G).

5G - это унифицированный, более производительный беспроводной интерфейс. Он разработан с расширенной пропускной способностью для обеспечения пользовательского опыта нового поколения, поддержки новых моделей развертывания и предоставления новых услуг. Благодаря высокой скорости, превосходной надежности и минимальной задержке 5G расширит возможности мобильной экосистемы, освоив новые сферы. 5G повлияет на все отрасли, сделав реальностью более безопасные перевозки, удаленное здравоохранение, точное земледелие, цифровую логистику и многое другое.

Предыдущие поколения мобильных сетей - это 1G, 2G, 3G и 4G.

Первое поколение - 1G.

1980-е годы: 1G обеспечивал аналоговую голосовую связь.

Второе поколение - 2G.

Начало 1990-х годов: 2G внедрило цифровую голосовую связь (например, CDMA - множественный доступ с кодовым разделением).

Третье поколение - 3G.

Начало 2000-х: технология 3G принесла с собой мобильные данные (например, CDMA2000).

Четвертое поколение - 4G LTE

2010-е годы: 4G LTE ознаменовало начало эры мобильной широкополосной связи.

1G, 2G, 3G и 4G - все они привели к появлению 5G, который призван обеспечить больше возможностей подключения, чем когда-либо ранее.

5G - это мобильная сеть пятого поколения. Это новый глобальный стандарт беспроводной связи, который придёт на смену сетям 1G, 2G, 3G и 4G. 5G создаёт новый тип сетей, предназначенных для соединения практически всех и вся, включая машины, объекты и устройства. Беспроводная технология 5G обеспечивает более высокую пиковую скорость передачи данных (в несколько Гбит/с), сверхнизкую задержку, повышенную надёжность, огромную ёмкость сети, повышенную доступность и более единообразный пользовательский интерфейс для большего числа пользователей. Более высокая производительность и улучшенная эффективность открывают новые возможности для пользователей и объединяют новые отрасли.[1]

Методы. Данные в системах 5G могут быть разделены на следующие две категории:

- данные сетевого уровня;
- данные уровня приложений.

Существуют следующие четыре задачи, которые могут быть решены на сетевом уровне с помощью методов машинного обучения:

- 1) предсказание состояния сети;
- 2) классификация трафика;
- 3) подробные записи вызовов;
- 4) анализ канала.

Как известно, сеть подвижной связи не всегда бывает полностью загружена, т. е. не всегда задействованы все ее ресурсы. Есть часы наибольшей нагрузки, когда используются все ресурсы сети, а есть часы наименьшей нагрузки, когда используется только небольшая часть ресурсов сети. Предсказание состояния сети основано на предсказании параметров сетевого трафика, которое, в свою очередь, основано на обработке ранее полученных данных. На рис.1. показаны обобщенные структуры следующих систем MIMO:

- однопользовательская система MIMO (single-user MIMO - SU-MIMO);

- многопользовательская система MIMO (multi-user MIMO - MU-MIMO).

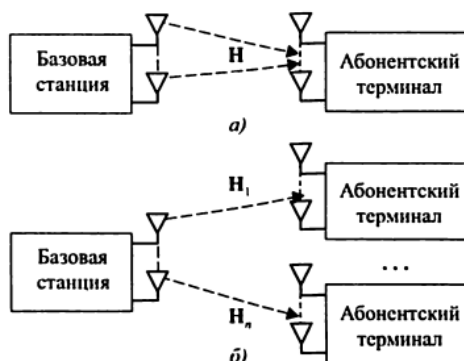


Рис.1. Системы SU-MIMO (а) и MU-MIMO (б)

Система SU-MIMO включает одну базовую станцию и одну абонентскую станцию (абонентское устройство), которые взаимодействуют через канал связи MIMO с матрицей  $H$ . Система MU-MIMO также включает одну базовую станцию, которая взаимодействует с несколькими абонентскими станциями через каналы связи MIMO с матрицами  $H_1, H_2, \dots, H_n$ . В системе MU-MIMO на передающей стороне осуществляется прекодирование, позволяющее сделать так, чтобы каждый абонент «не видел» помех со стороны других абонентов [2-7]. На приемной стороне характеристики канала связи MIMO предполагаются известными, а приемник демодулирует предназначенный только ему сигнал, рассматривая сигналы остальных абонентов как помехи. Быстрый рост числа абонентских устройств привел к необходимости осуществлять передачу сигналов различных абонентов одновременно и на одной и той же частоте. Это приводит к возникновению существенных помех между сотами, что наглядно показано на рис.2.

В настоящее время известны следующие способы решения проблемы уменьшения помех между сотами [6]:

- 1) управление уровнем помех;
- 2) координация помех;
- 3) совместный прием сигналов.

В сети с управлением уровнем помех используется обратная связь от пользовательских устройств к базовым станциям соседних сот.




Рис.2. Помехи между сотами

Эти соседние базовые станции выбирают мощность излучения, исходя из максимизации некоторого критерия, например максимизации пропускной способности. В сети с координацией помех обмен данными между соседними базовыми станциями минимизируется и формируется направленная в сторону назначенного пользователя диаграмма направленности антенны базовой станции. В сети с совместным приемом сигналов для демодуляции используется информация о пространственном расположении пользователей, а предназначенный конкретному пользователю поток данных распределяется между базовыми станциями. Большой объем данных пользователей позволяет выделить из них скрытую информацию о качестве восприятия (Quality of Experience - QoE) для пользователей.[4-9]

Результаты. Для обработки данных с целью определения фрагментов сети с низким QoE используется многоуровневый персептрон (Multilayer Perceptron - MLP) [9]. В процессе такой обработки определяется средняя пропускная способность пользователя, число активных пользователей в соте, средний объем данных, приходящихся на одного пользователя, а также показатели качества каналов связи. Каждый нейрон в MLP использует сигмоидальную функцию передачи, которая описывается следующим выражением:

$$S(x) = \frac{e^x}{(e^x + 1)},$$

где,  $x$  - отсчет входного сигнала. Нейрон начинает быть активным, когда входной сигнал превышает некоторый порог.

Беспроводные сети обычно снижают свою производительность из-за наличия узких мест. В исследованы алгоритмы предсказания трафика, позволяющие увеличить производительность сети связи. Более подробно методы предсказания трафика в сетях связи 5G изложены в [5]. На сетевом уровне данные содержат информацию о местоположении. Расположение пользователей является важным фактором, влияющим на качество обслуживания. Сведения о текущем расположении пользователей в пространстве помогают определить перегруженные и недогруженные соты, а также позволяют сделать прогноз на будущее изменения расположения пользователей. В системах 5G имеется механизм минимизации потерь вызовов в перегруженных сотах за счет некоторого снижения качества обслуживания (Quality of Service - QoS) в недогруженных сотах. В большинстве современных пользовательских устройствах имеется приемник одной или сразу нескольких глобальных спутниковых навигационных систем (например, GPS и ГЛОНАСС), который используется для точного определения местоположения [10-11]. Однако такой приемник отсутствует в оконечных устройствах Интернета вещей, что затрудняет определение местоположения.

Обсуждение. Как известно, сети 5G работают на основе пакетной передачи. Поэтому маршрутизация пакетов является важной задачей при оптимизации сети. Сетевая инфраструктура может быть представлена в виде большого графа, который может быть описан своей матрицей смежности [14]. Используя свойства этой матрицы, можно построить различные алгоритмы маршрутизации пакетов. Глубокое обучение с подкреплением позволяет учитывать изменения трафика во времени, а также его пространственную корреляцию, что обеспечивает достижение требуемых показателей качества обслуживания QoS [12]. Оптимальная маршрутизация трафика позволяет увеличить пропускную способность сети при сохранении требуемого уровня качества обслуживания QoS. Нужно отметить, что при передаче пакетов для достижения нужного уровня QoS иногда требуется их повторная передача (переспрос). Число переспросов должно быть минимизировано. Однако при этом также должна быть минимизирована вероятность потери пакета. В сетях 5G также используется оптимизация распределения мощностей, излучаемых базовыми станциями. В качестве критерия при этом используется отношение сигнал/(шум + помеха) [8]. Распределение спектра между пользователями также осуществляется адаптивно, чтобы получить максимальную суммарную пропускную способность сети. Такое адаптивное распределение спектра организуется на основе предсказания уровня трафика [9]. С помощью методов глубокого обучения можно осуществлять предсказание скоростей передачи данных пользователями, что может дать дополнительный выигрыш в качестве обслуживания QoS за счет анализа доступной полосы частот и управления буфером данных [13-15]. Как известно, безопасность сети является одной из самых важных характеристик современных сетей связи. Понятие безопасности беспроводной сети включает следующие элементы:

- безопасность пользователей;
- безопасность данных;
- возможность несанкционированного доступа к инфраструктуре.

Адаптивные алгоритмы, основанные на моделях глубокого обучения, могут повысить безопасность беспроводной сети путем идентификации угроз на основе предыдущего опыта. Неожиданные изменения трафика анализируются с помощью этих алгоритмов с целью поиска и изучения аномалий. При выполнении правильной классификации угрозы могут быть на ранней стадии блокированы и таким образом может быть обеспечена безопасность инфраструктуры сети [7].

*В заключение можно сказать следующее:* Многие проблемы планирования сети могут быть решены на основе имеющейся в сети пространственно-временной информации как на уровне пользователя, так и на уровне всей сети.



Путем анализа трафика в сети можно осуществлять довольно точное его предсказание. Это, в свою очередь, позволяет обеспечить оптимальное распределение ресурсов в сети, что особенно важно для обслуживания сильно загруженных ее участков.

### **Использованная литература**

1. Mandloi M., Gurjar D., Pattanayak P., Nguyen N. 5G and Beyond Wireless Systems PHY Layer Perspective, Singapore, Springer Nature Singapore, 2021, 425 p.
2. Крейнделин В.Б., Вен Режеб Т.Б.К. Нелинейный итерационный алгоритм прекодирования для многопользовательских систем MIMO // Известия высших учебных заведений. Радиоэлектроника. - 2017. - Т. 60, № 10(664). - С. 581-591.
3. Effective precoding and demodulation techniques for 5G communication systems / V. Kreyndelin, A. Smirnov, T. Ben Rejeb // 2018 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, 14-15 march 2018. - Moscow: Institute of Electrical and Electronics Engineers Inc., 2018. - P. 8350608-6.
4. Ben Rejeb T.B.K., Kreyndelin V.B., Smirnov A.E. Precoding and Detection Techniques for Large Scale Multiuser MIMO TDD Systems // 2018 Wave Electronics and its Application in Information and Telecommunication Systems, WECONF 2018, St. Petersburg, 26-30 nov. 2018. - St. Petersburg, 2018. - P. 8604455.
5. Вен Режеб Т.Б.К. Анализ эффективности методов дискретного прекодирования в многопользовательских системах связи с технологией MIMO // DSPA: Вопросы применения цифровой обработки сигналов. - 2017. - Т. 7, № 1. - С. 223-228.
6. Kwon D., Kim H., Kim J., Suh S., Kim I., Kim K.J. A survey of deep learning-based network anomaly detection // Cluster Comput. - 2019. - 22(Suppl 1). - P. 949-961.
7. Thing V.L.L. IEEE 802.11 Network Anomaly Detection and Attack Classification: A Deep Learning Approach // 2017 IEEE Wireless Communications and Networking Conference (WCNC), San Francisco, CA, USA, 2017. - P. 1-6.
8. Gwon Y.L., Kung H.T. (2014) Inferring origin flow patterns in Wi-Fi with deep learning // 11th international conference on autonomic computing (ICAC 14). - 2014. - P. 73-83
9. Davidson P., Piché R. A Survey of Selected Indoor Positioning Methods for Smartphones // IEEE Communications Surveys & Tutorials, vol. 19, no. 2, pp. 1347-1370, Secondquarter 2017.

10. Xia S., Liu Y., Yuan G., Zhu M., and Wang Z. Indoor Fingerprint Positioning Based on Wi-Fi: An Overview // ISPRS International Journal of Geo-Information, 2017. 6, no. 5: 135.
11. Xiao J., Zhou Z., Yi Y., Ni L.M. A survey on wireless indoor localization from the device perspective // ACM Comput Surveys (CSUR), 2016, 49(2):25
12. Pierucci L. and Micheli D. A Neural Network for Quality of Experience Estimation in Mobile Communications // IEEE MultiMedia, vol. 23, no. 4, pp. 42-49, Oct.-Dec. 2016
13. Geyer F., Carle G. (2018) Learning and generating distributed routing protocols using graph-based deep learning // Proceedings of the 2018 workshop on big data analytics and machine learning for data communication networks. ACM, pp. 40-45.
14. Pham T.A.Q., Hadjadj-Aoul Y., Outtagarts A. Deep reinforcement learning based QOS-aware routing in knowledge-defined networking // International conference on heterogeneous networking for quality, reliability, security and robustness. Springer, 2018. pp. 14-26.
15. Yu Y., Wang T., Liew S.C. Deep-reinforcement learning multiple access for heterogeneous wireless networks // IEEE J Sel Areas Commun. 2019. 37(6): pp. 1277-1290.