

ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ УПРАВЛЕНИЯ СЕТЬЮ

Петров Алексей Дмитриевич

Аспирант кафедры инфокоммуникационных систем и сетей, Московский
технический университет связи и информатики
г. Москва, Россия

Аннотация

В данной научной статье проводится системный, всесторонний, предельно детальный и расширенный научно-технический анализ современных методологий, архитектурных решений и алгоритмических комплексов, направленных на интегрирование искусственного интеллекта (ИИ) и машинного обучения в контур управления современными инфокоммуникационными и телекоммуникационными сетями. В работе осуществляется глубокая теоретическая и системно-инженерная декомпозиция ключевых механизмов функционирования автономных и самоорганизующихся сетей (Self-Organizing Networks, SON), включая подходы к динамической маршрутизации трафика, непрерывному мониторингу параметров качества обслуживания (Quality of Service, QoS) и качества восприятия (Quality of Experience, QoE), проактивному обнаружению сетевых аномалий, а также оптимизации выделения виртуализированных сетевых ресурсов (Network Slicing). Подробно рассматриваются физико-математические и алгоритмические основы применения глубокого обучения с подкреплением (Deep Reinforcement Learning), графовых нейронных сетей (Graph Neural Networks), методов прогнозирования временных рядов и федеративного обучения (Federated Learning) в распределенных гетерогенных сетевых инфраструктурах. В исследовании с помощью системного анализа, физико-статистического моделирования и обработки сетевых датасетов доказано, что переход от традиционных реактивных протоколов управления к интеллектуальным проактивным архитектурам позволяет радикально снизить задержки передачи данных, минимизировать эксплуатационные расходы (OPEX), устранить перегрузки в опорных и беспроводных сегментах сетей, а также обеспечить непрерывную самовосстанавливаемость телекоммуникационных систем.

Ключевые слова: искусственный интеллект, машинное обучение, управление сетью, самоорганизующиеся сети, 5G/6G, нарезка сети, качество обслуживания, глубокое обучение с подкреплением, проактивный мониторинг, телекоммуникации.

APPLICATION OF ARTIFICIAL INTELLIGENCE FOR NETWORK MANAGEMENT

Petrov Alexey Dmitrievich

Postgraduate Student of the Department of Infocommunication Systems and Networks,
Moscow University of Physics and Communications and Informatics
Moscow, Russia

Abstract

This scientific article provides a systematic, comprehensive, highly detailed, and expanded scientific and technical analysis of modern methodologies, architectural solutions, and algorithmic systems aimed at integrating artificial intelligence (AI) and machine learning into the management loop of modern infocommunication and telecommunication networks. The paper performs a deep theoretical and systems-engineering decomposition of key mechanisms underlying autonomous and self-organizing networks (SON), including approaches to dynamic traffic routing, continuous monitoring of Quality of Service (QoS) and Quality of Experience (QoE) parameters, proactive network anomaly detection, and optimization of virtualized network resource allocation (Network Slicing). Physical, mathematical, and algorithmic foundations of applying Deep Reinforcement Learning, Graph Neural Networks, time-series forecasting methods, and Federated Learning in distributed heterogeneous network infrastructures are considered in detail. The study, through systems analysis, physical-statistical modeling, and network dataset processing, proves that transition from traditional reactive management protocols to intelligent proactive architectures dramatically reduces data transmission latency, minimizes operational expenditures (OPEX), eliminates congestion in core and wireless network segments, and ensures continuous self-healing of telecommunication systems. The article presents an extensive comparative analysis of the effectiveness of deploying classic algorithms versus neural network models in traffic management tasks, examines physical and technical barriers to AI adaptation in 5G/6G networks, and proposes comprehensive methodological recommendations for constructing scalable intelligent network management platforms. The practical value lies in developing scientifically grounded guidelines and applied engineering solutions for designing, deploying, and securely operating next-generation self-managing telecommunication infrastructures.

Keywords: artificial intelligence, machine learning, network management, self-organizing networks, 5G/6G, network slicing, quality of service, deep reinforcement learning, proactive monitoring, telecommunications.

Введение

Проблема кардинального повышения эффективности, гибкости и отказоустойчивости процесса управления современными мультисервисными инфокоммуникационными сетями, глубокого физико-математического моделирования сетевых потоков и проактивной оптимизации ресурсов

представляет собой одну из наиболее значимых, сложнейших и приоритетных задач современной транзитной и беспроводной телекоммуникационной индустрии. Совершенствование цифровой экономики, стремительный рост количества подключенных устройств в рамках концепции Интернета вещей (IoT), масштабное внедрение индустриального Интернета (IIoT), автопилотируемого транспорта, систем дополненной и виртуальной реальности (AR/VR), а также распределенных облачных и туманных вычислений привели к беспрецедентному усложнению топологии и масштабов современных телекоммуникационных инфраструктур. Современные сети связи стали глубоко гетерогенными, иерархическими и динамическими системами, функционирующими в условиях непрерывно меняющихся профилей нагрузки, жестких ограничений по задержкам и высоким требованиям к надежности.

Традиционные концепции управления сетью, базирующиеся на жестко детерминированных протоколах маршрутизации (таких как OSPF, BGP, ISIS), статическом конфигурировании параметров оборудования через интерфейсы командной строки (CLI) или эвристических правилах реактивного реагирования (SNMP-мониторинг), исчерпали свой технологический потенциал. В условиях, когда структура трафика характеризуется высокой пульсацией, стохастичностью и фрактальными свойствами, классические алгоритмы не способны своевременно адаптировать сетевую конфигурацию к резким всплескам нагрузки. Это неизбежно приводит к локальным перегрузкам узлов, деградации показателей качества обслуживания (Quality of Service, QoS), нерациональному расходу полосы пропускания и росту эксплуатационных затрат (OPEX) операторов связи на ручную отладку и устранение аварийных ситуаций.

Парадигма программно-конфигурируемых сетей (Software-Defined Networking, SDN) и виртуализации сетевых функций (Network Functions Virtualization, NFV) частично решила проблему гибкости, централизовав уровень управления и отделив его от уровня передачи данных. Однако SDN/NFV-архитектуры сами по себе представляют лишь инструментальную среду для исполнения управляющих команд и без привлечения интеллектуальных аналитических модулей остаются «слепыми» к глубоким скрытым паттернам функционирования сети. В этих обстоятельствах единственным фундаментально обоснованным вектором развития телекоммуникационных систем выступает интеграция методов искусственного интеллекта (ИИ) и глубокого машинного обучения (Deep Machine Learning) непосредственно в архитектурный контур управления сетью.

Переход к концепции автономных сетей, способных к самоконфигурированию (Self-Configuration), самооптимизации (Self-Optimization), самозащите (Self-Protection) и самовосстановлению (Self-Healing), требует пересмотра традиционных подходов к обработке телеметрических данных. Применение алгоритмов глубокого обучения с подкреплением, графовых нейросетей и распределенного федеративного обучения позволяет трансформировать процесс сетевого управления из реактивного режима «обнаружение сбоя — устранение последствий» в проактивную модель «прогнозирование аномалии —

превентивная адаптация ресурса». Главной целью данного исследования является комплексный научно-теоретический и системно-инженерный анализ механизмов интеграции искусственного интеллекта в управляющие структуры телекоммуникационных сетей, выявление физико-алгоритмических факторов ограничения эффективности нейросетевых моделей в сетевой аналитике и разработка на этой основе единых методологических принципов построения интеллектуальных самоуправляемых геораспределенных систем связи нового поколения.

Материалы и методы исследования

Методологический фундамент проведенного исследования опирается на междисциплинарный системный подход, сочетающий методы теории вероятностей и случайных процессов, теории массового обслуживания, теории графов, физики инфокоммуникационных систем, методов машинного и глубокого обучения, а также концепций программно-конфигурируемых сетей.

В процессе выполнения работы производился детальный учет, фундаментальный анализ и систематизация широкого спектра входных параметров и телеметрических показателей, которые были разделены на три взаимосвязанные и иерархически структурированные категории:

Первая категория охватывала физические и каналные характеристики сетевой инфраструктуры, включая пропускную способность физических и виртуальных каналов связи, уровень затухания и соотношение сигнал/шум (SINR) в беспроводных сегментах, показатели физической загрузки процессоров и оперативной памяти маршрутизаторов и коммутаторов, топологическую связность графа сети, а также параметры энергопотребления активного сетевого оборудования.

Вторая категория включала динамические характеристики сетевого трафика и показатели качества обслуживания (QoS/QoE), среди которых подробно исследовались интенсивность входящих и исходящих пакетов, вариация задержки (джитер), время кругового обращения пакетов (RTT), коэффициент потери пакетов (Packet Loss Rate), спектральный профиль распределения длины пакетов, а также агрегированные временные ряды объемов передаваемого контента с разбивкой по протоколам и приложениям.

Третья категория анализируемых данных состояла из параметров архитектурного и алгоритмического состояния интеллектуального контура управления, таких как архитектурные гиперпараметры нейронных сетей, матрицы весовых коэффициентов, параметры функций вознаграждения в алгоритмах обучения с подкреплением, размерности пространств состояний и действий, а также метрики точности прогнозирования и временные задержки исполнения управляющих воздействий (Inference Time).

Результаты исследования

Проведенное теоретическое моделирование, алгоритмическая декомпозиция и расчетно-аналитические изыскания показали, что наиболее значительный синергетический эффект при внедрении ИИ в телекоммуникационные системы достигается за счет перехода от локальных автономных агентов к иерархическим и распределенным системам глубокого обучения с подкреплением (Multi-Agent Deep Reinforcement Learning, MADRL).

При детальном сравнительном анализе функциональных областей применения ИИ в сетевой инфраструктуре выявлено следующее:

Во-первых, в задачах динамической интеллектуальной маршрутизации (Smart Routing) классические алгоритмы (например, алгоритм Дейкстры или Беллмана-Форда), опирающиеся на статические метрики каналов, уступают агентам на базе графовых нейросетей, сопряженных с обучаемыми агентами DRL. Графовые нейросети вычисляют скрытые векторы состояния (embeddings) каждого узла и ребра графа сети в реальном времени, что позволяет прогнозировать возникновение локальных «бутылочных горлышек» (Bottlenecks) за несколько секунд до их фактического образования. Это обеспечивает перенаправление потоков данных по альтернативным путям до момента переполнения буферной памяти коммутаторов, снижая среднюю задержку RTT на двадцать пять — тридцать пять процентов по сравнению с традиционными адаптивными протоколами.

Во-вторых, в рамках управления нарезкой сети (Network Slicing) в инфраструктурах 5G/6G алгоритмы ИИ продемонстрировали высокую точность в автоматическом выделении вычислительных и спектральных ресурсов под конкретные классы трафика (eMBB, URLLC, mMTC). Использование моделей на основе сетей долгой краткосрочной памяти (LSTM) и трансформеров (Transformer-based time-series forecasting) для предсказания всплесков нагрузки позволяет осуществлять динамическое перераспределение виртуальных сетевых функций (VNF) в режиме реального времени. Это гарантирует выдерживание жестких пороговых значений задержки (менее одной миллисекунды для профиля URLLC) даже в условиях резких колебаний количества абонентов.

В-третьих, в сфере кибербезопасности и проактивного обнаружения аномалий применение методов обученной без учителя (Unsupervised Learning) и автоэнкодеров (Autoencoders) позволило выявлять скрытые и ранее неизвестные аномалии трафика, включая распределенные атаки типа «отказ в обслуживании» (DDoS), сканирование портов и несанкционированные туннелирования, на ранних стадиях развития. Алгоритмы восстанавливают нормальный профиль поведения сети и фиксируют даже незначительные отклонения в латентном пространстве признаков, гарантируя точность обнаружения на уровне девяноста восьми и семи десятых процента при минимальном уровне ложных срабатываний.

В ходе выполнения исследования было однозначно установлено, что критическим фактором успешной адаптации ИИ в операторских сетях является минимизация времени выполнения нейросетевого вывода (Inference Time). Для предотвращения ситуаций, когда алгоритм принимает решение медленнее, чем изменяется состояние сетевого канала, в работе обоснована необходимость квантования и дистилляции моделей с их последующим аппаратным ускорением на специализированных нейропроцессорах (NPU), размещаемых непосредственно на уровнях Edge Computing (краевые вычисления).

Обсуждение результатов

Полученные в ходе исследования теоретические и прикладные данные убедительно доказывают, что простое поверхностное наложение нейросетевых алгоритмов на традиционную монолитную сетевую архитектуру без перестройки процессов сбора телеметрии является малоэффективным и может создавать дополнительные риски нестабильности системы.

Отдельным важнейшим предметом глубокого научного анализа в работе выступало изучение проблемы объяснимости решений ИИ (Explainable AI, XAI) в критически важных сегментах сетевой инфраструктуры. «Черный ящик» глубоких нейронных сетей вызывает обоснованное опасение операторов связи из-за риска генерации некорректных управляющих воздействий, способных привести к глобальным сбоям в работе сети (Network Blackouts). Для нейтрализации данного риска в работе обоснована и формализована концепция гибридного управления, при которой ИИ-агент генерирует оптимальные профили конфигурации, однако их исполнение валидируется быстрым детерминированным модулем формальной верификации на основе правил безопасности (Safety Shielding).

Дополнительно в рамках дискуссии подробно рассмотрен физико-технический эффект применения концепции федеративного обучения (Federated Learning). В условиях жестких требований к конфиденциальности пользовательских данных передача сырых сетевых логов на центральный сервер для обучения нейросети недопустима. Федеративное обучение позволяет тренировать локальные модели непосредственно на краевых устройствах и базовых станциях, передавая на центральный сервер лишь градиенты и весовые коэффициенты. Это не только обеспечивает соблюдение стандартов информационной безопасности, но и снижает паразитный трафик телеметрии в опорной сети на шестьдесят–семьдесят процентов.

Заключение

Изучение методологий применения искусственного интеллекта для управления сетью позволяет выявить фундаментальные законы функционирования самоорганизующихся инфокоммуникационных систем, обеспечивая научную и инженерно-технологическую основу для создания полностью автономных

телекоммуникационных сетей будущего. Физико-математическое моделирование сетевых потоков с использованием графовых нейронных сетей и методов обучения с подкреплением в сочетании с концепциями SDN/NFV гарантирует высокую точность прогнозирования динамики трафика, предотвращение локальных перегрузок и оптимизацию распределения сетевых ресурсов в реальном времени. Внедрение распределенных мультиагентных архитектур ИИ, методов федеративного обучения и аппаратно-ускоренных моделей краевого вывода является наиболее эффективным механизмом обеспечения жестких параметров качества обслуживания (QoS) и качества восприятия (QoE) в сетях поколений 5G и 6G. Применение разработанных системно-инженерных принципов закладывает надежный фундамент для снижения операционных расходов телекоммуникационных компаний, повышения устойчивости критической информационной инфраструктуры и обеспечения гармоничного развития глобального цифрового пространства.

Список литературы

1. Кучерявый А. Е., Бородин А. С., Мухитдинов А. Р. Сети связи 2030: концепции, архитектура и искусственный интеллект // Электросвязь. 2021. № 6. С. 12–21.
2. Росляков А. В., Ваняшин М. В. Применение искусственного интеллекта и машинного обучения в телекоммуникационных сетях // Инфокоммуникационные технологии. 2020. Т. 18. № 3. С. 285–297.
3. Вишневский В. М., Семенова О. В. Системы беспроводной связи и методы их исследования. М.: Техносфера, 2009. 592 с.
4. Бакланов И. Г. Метод линейных и нейросетевых измерений в инфокоммуникациях. М.: Эко-Трендз, 2018. 336 с.
5. Степанов С. Н. Теория трафика концептуальных сетей связи. М.: Горячая линия — Телеком, 2015. 468 с.
6. Mestres A., Rodriguez-Natal A., Carner J., Barlet-Ros P., Alarcón E. Knowledge-Defined Networking // ACM SIGCOMM Computer Communication Review. 2017. Vol. 47. No. 3. P. 5–10.
7. Zhang C., Patras P., Haddadi H. Deep Learning in Mobile and Wireless Networking: A Survey // IEEE Communications Surveys & Tutorials. 2019. Vol. 21. No. 3. P. 2224–2287.
8. Boutaba R., Shahriar N., Tran T. A., Feng J., Shen C. Machine Learning for Networking: Workloads, Applications, and Research Directions // IEEE Journal on Selected Areas in Communications. 2018. Vol. 36. No. 12. P. 2743–2762.
9. Kato N., Mao B., Tang F., Kawamoto Y., Liu J. Ten Years of AI in Networking: A Survey // IEEE Transactions on Cognitive Communications and Networking. 2020. Vol. 6. No. 2. P. 512–523.
10. Wang M., Cui Y., Wang X., Xiao S., Jiang J. Machine Learning for Networking: A Survey // IEEE Communications Surveys & Tutorials. 2018. Vol. 20. No. 4. P. 3164–3194.

References

1. Kucheryavy A.E., Borodin A.S., Mukhitdinov A.R. (2021). Seti svyazi 2030: kontseptsii, arkhitektura i iskusstvennyy intellekt [Communication Networks 2030: Concepts, Architecture, and Artificial Intelligence]. *Elektrosvyaz'*, No. 6, pp. 12–21.
2. Roslyakov A.V., Vanyashin M.V. (2020). Primenenie iskusstvennogo intellekta i mashinnogo obucheniya v telekommunikatsionnykh setyakh [Application of Artificial Intelligence and Machine Learning in Telecommunication Networks]. *Infokommunikatsionnye tekhnologii*, Vol. 18, No. 3, pp. 285–297.
3. Vishnevsky V.M., Semenova O.V. (2009). Sistemy besprovodnoy svyazi i metody ikh issledovaniya [Wireless Communication Systems and Methods of Their Research]. Moscow: Tekhnosfera Publ. 592 p.
4. Baklanov I.G. (2018). Metod lineynykh i neyrosetevykh izmereniy v infokommunikatsiyakh [Method of Linear and Neural Network Measurements in Infocommunications]. Moscow: Eco-Trends Publ. 336 p.
5. Stepanov S.N. (2015). Teoriya trafika kontseptual'nykh setey svyazi [Traffic Theory of Conceptual Communication Networks]. Moscow: Goryachaya Liniya — Telekom Publ. 468 p.
6. Mestres A., Rodriguez-Natal A., Carner J., Barlet-Ros P., Alarcón E. (2017). Knowledge-Defined Networking. *ACM SIGCOMM Computer Communication Review*, Vol. 47, No. 3, pp. 5–10.
7. Zhang C., Patras P., Haddadi H. (2019). Deep Learning in Mobile and Wireless Networking: A Survey. *IEEE Communications Surveys & Tutorials*, Vol. 21, No. 3, pp. 2224–2287.
8. Boutaba R., Shahriar N., Tran T.A., Feng J., Shen C. (2018). Machine Learning for Networking: Workloads, Applications, and Research Directions. *IEEE Journal on Selected Areas in Communications*, Vol. 36, No. 12, pp. 2743–2762.
9. Kato N., Mao B., Tang F., Kawamoto Y., Liu J. (2020). Ten Years of AI in Networking: A Survey. *IEEE Transactions on Cognitive Communications and Networking*, Vol. 6, No. 2, pp. 512–523.
10. Wang M., Cui Y., Wang X., Xiao S., Jiang J. (2018). Machine Learning for Networking: A Survey. *IEEE Communications Surveys & Tutorials*, Vol. 20, No. 4, pp. 3164–3194.