

Проблема конвергенции федеративного машинного обучения, туманных вычислений и автономных сетей в архитектуре сетей 6G

Ван Тханг Данг, Артем Волков, Май Конг Хыонг, Нгуен Дык Ту

*Санкт-Петербургский государственный университет телекоммуникаций
им. проф. М.А. Бонч-Бруевича*

thangdang.251196@gmail.com, artemanv.work@gmail.com, mai.kkh@sut.ru

Аннотация. Развитие сетей шестого поколения (6G/IMT-2030) создаёт импульс для перехода архитектуры от централизованных сетевых моделей к распределённым, интеллектуальным и автономным архитектурам. В данной статье представлен систематический обзор трёх базовых технологий, объединённых в экосистеме 6G: федеративного машинного обучения (Federated Learning — FL), туманных вычислений (Fog Computing — FC) и автономных сетей (Autonomous Networks — AN). В работе рассматриваются принципы, архитектура и роль каждой технологии на основе рекомендаций и стандартов ITU. Также анализируются основные технические возможности и проблемы при объединении этих трёх технологий. На этой основе статья определяет направления дальнейших исследований. Результаты показывают, что конвергенция FL-FC-AN является архитектурной основой с большим потенциалом для развития сетей связи следующего поколения.

Ключевые слова: федеративное машинное обучение, туманные вычисления, автономные сети, 6G, IMT-2030, конвергенция технологий, распределённая сетевая архитектура

I. ВВЕДЕНИЕ

Сети будущего поколения (IMT-2030/6G) призваны превзойти 5G не только по техническим характеристикам, но и по концепции архитектуры [1]. Согласно рекомендации МСЭ-R М.2160 [2], IMT-2030 определяет шесть основных сценариев использования. Среди них выделяются приложения с минимальной задержкой, высокой надёжностью и способностью к самоуправлению в зависимости от контекста. Для выполнения этих требований МСЭ предлагает новую архитектурную модель, в которой сетевые функции распределены, решения принимаются локально, а вся система работает автономно без постоянного участия человека.

В этих условиях три технологии выступают в роли опорных элементов будущей сети 6G. Во-первых, федеративное обучение (FL) обеспечивает распределённый механизм обучения: модели ИИ (искусственного интеллекта) обучаются непосредственно там, где генерируются данные, без их централизованной передачи. Этот подход полностью совместим с архитектурой сетей на основе машинного обучения, определённой в рекомендации МСЭ-T Y.3172 [3]. Во-вторых, туманные вычисления (FC) переносят вычислительные ресурсы ближе к краю сети и создают распределённый слой обработки данных в реальном времени. В рекомендации МСЭ-T Y.3513 [4] они

признаны важным инфраструктурным компонентом для IoT и сетей следующего поколения. В-третьих, автономные сети (AN) отражают видение будущей сети, способной к самовосприятию, самостоятельному принятию решений и эволюции в соответствии с целями обслуживания. Это снижает зависимость от человека в процессе управления и эксплуатации. Концепция автономных сетей стандартизирована в рекомендации МСЭ-T Y.3061 [5]. Конвергенция этих трёх технологий отражает не просто техническую тенденцию, но и стратегическое направление МСЭ в построении архитектурной основы для сетей 6G.

II. АВТОНОМНЫЕ СЕТИ В КОНТЕКСТЕ IMT-2030

Согласно рекомендации МСЭ-T Y.3061 (2023), автономная сеть определяется как сетевая система, обладающая возможностями самомониторинга, самооптимизации и самоадаптации к сложным изменениям среды. Ключевыми особенностями, описанными в этой рекомендации, являются способность к «генерации» и «эволюции». Благодаря им система может самостоятельно разрабатывать, тестировать и внедрять новые решения управления для задач, которые не были заранее запрограммированы.

Архитектура Y.3061 построена на основе замкнутого взаимодействия между инфраструктурным уровнем и уровнем интеллекта сети. Она включает четыре ключевые подсистемы:

Движок автономии (Autonomy Engine): Включает подсистему исследования и эволюции систем, использующую ИИ для автоматического создания новых контроллеров, и испытательную подсистему, предоставляющую среду-песочницу ИИ (AN sandbox) для проверки перед реальным развёртыванием.

Подсистема динамической адаптации (Dynamic Adaptation): Встраивает проверенные контроллеры в сетевую инфраструктуру и корректирует рабочие параметры в реальном времени без прерывания обслуживания.

База знаний (Knowledge Base): Управляет жизненным циклом данных, метаданных, моделей машинного обучения и логических выводов. Она предоставляет обучающие данные и контекстную информацию для алгоритмов ИИ.

Оркестратор (AN Orchestrator): Управляет внутренними рабочими процессами и координирует

объекты управления по всей сети, включая сегментацию сети (network slicing) по показателям QoS.

Автономные сети в контексте ИМТ-2030 ориентированы на модель эксплуатации «Zero-touch». Эта модель опирается на четыре ключевые возможности, определённые в Y.3061: самоконфигурация, самооптимизация, самовосстановление и самозащита. Все они поддерживаются замкнутым циклом обратной связи MAPE-K: мониторинг, анализ, планирование, выполнение и обновление базы знаний.

Согласно МСЭ-Т Y.3172, в сетях следующего поколения распределённые циклы MAPE-K не основываются на статических порогах. Вместо этого они управляются моделями машинного обучения. Это позволяет сети гибко распределять ресурсы и прогнозировать балансировку нагрузки. Такой подход создаёт естественную основу для конвергенции с туманными вычислениями и федеративным обучением.

III. Туманные вычисления: ТЕОРИЯ И АРХИТЕКТУРА

Концепция туманных вычислений была впервые предложена Бономи и соавторами из Cisco в 2012 году [6]. Ключевая идея состоит в расширении облачной модели вычислений к краю сети с целью создания промежуточного слоя обработки данных, подходящего для IoT-приложений с низкой задержкой. С тех пор туманные вычисления рассматриваются как важный распределённый слой обработки, обеспечивающий вычислительные ресурсы, хранение данных и связь в диапазоне от облака до конечных устройств. В отличие от чисто облачных вычислений, Туманные вычисления делают акцент на многоуровневой распределённой архитектуре, где узлы тумана располагаются на различных позициях сети – ближе к источникам данных. Недавние исследования показывают, что туманные вычисления играют важную роль в поддержке новых сервисов реального времени, включая услуги телеприсутствия и иммерсивные приложения следующего поколения [7].

Типичная архитектура туманных вычислений организована по трёхуровневой иерархической модели: уровень устройств, включающий IoT-устройства, датчики и исполнительные механизмы; уровень тумана, включающий узлы тумана, шлюзы и граничные процессоры; и облачный уровень – инфраструктура центров обработки данных. Интеграция SDN и NFV в архитектуру тумана формирует модель с двумя контурами управления: быстрым на границе сети и медленным в центре. Это отражает принцип иерархической архитектуры, который МСЭ-Т определил необходимым свойством инфраструктуры ИМТ-2030.

В архитектуре сетей 6G туманные вычисления могут играть роль «активатора интеллекта» по трём ключевым причинам. Во-первых, локальная обработка данных позволяет выполнять требования по низкой задержке. Во-вторых, распределённая архитектура решает задачу масштабирования в среде массового IoT. В-третьих, возможность работы независимо от облачного соединения обеспечивает непрерывность обслуживания критически важных приложений.

IV. ФЕДЕРАТИВНОЕ ОБУЧЕНИЕ: ТЕОРИЯ, КЛАССИФИКАЦИЯ И ПРИМЕНЕНИЕ В СЕТЯХ

Федеративное обучение – это метод обучения моделей машинного обучения в распределённом режиме, при котором обучающие данные остаются на устройствах-источниках. Алгоритм FedAvg, предложенный Макмаханом и соавторами в 2017 году [8], заложил основу этого подхода: вместо централизованной передачи данных FL обменивается информацией о модели (градиентами или весами) и агрегирует её для улучшения глобальной модели. Эти свойства делают федеративное обучение одним из наиболее подходящих механизмов машинного обучения с точки зрения требований ИМТ-2030 к распределённости, безопасности и эффективному использованию ресурсов.

Фундаментальная сложность FL – проблема неоднородных данных (non-IID): когда данные на разных устройствах существенно различаются по распределению, возникает эффект «смещения клиента». Это замедляет сходимость и снижает качество модели. Ли и соавторы [9] систематизировали эти проблемы и показали, что решение задачи non-IID в условиях реальных телекоммуникационных сетей остаётся открытой исследовательской проблемой.

В литературе FL классифицируется по пространству данных: горизонтальное FL применяется, когда у устройств общее пространство признаков, но разные выборки данных; вертикальное FL – когда общие выборки, но разные признаки; федеративное обучение с переносом охватывает случаи, когда различаются и выборки, и признаки. По топологии связи FL бывает централизованным, децентрализованным или иерархическим.

Иерархическое федеративное обучение особенно важно в телекоммуникациях благодаря естественной совместимости с иерархической архитектурой тумана. Хоссейналипур и соавторы [10] показали, что промежуточные уровни агрегации, соответствующие узлам тумана, выполняют локальную агрегацию перед передачей результатов на вышестоящий уровень. Это существенно снижает нагрузку на магистральные каналы связи. Данная модель также рекомендована в МСЭ-Т Y.3172 для систем машинного обучения в сетях будущего.

Распределённость FL органично сочетается с распределённостью сетевой инфраструктуры, что создаёт естественную архитектурную совместимость. МСЭ-Т Y.3172 рассматривает FL как один из подходящих механизмов для распределённого управления радиоресурсами, прогнозирования качества канала и обнаружения сетевых аномалий в архитектуре ИМТ-2030. Сирохи и соавторы [11] подтвердили это в своём обширном обзоре, указав, что FL не только обеспечивает конфиденциальность данных, но и повышает безопасность коммуникационных систем 6G. Тем не менее, практическое развёртывание по-прежнему сопряжено с трудностями управления ресурсами в процессе обучения и обеспечением сходимости в динамичной сетевой среде.

V. КОНВЕРГЕНЦИЯ FL-FC-AN: ВОЗМОЖНОСТИ И ПРОБЛЕМЫ

Туманные вычисления, федеративное обучение и автономные сети открывают возможность для кардинального сдвига в проектировании сетей 6G: от пассивных централизованных вычислительных моделей к распределённым, самоуправляемым экосистемам с нативной архитектурой ИИ. Согласно архитектурным ориентирам от МСЭ-Т, эти три технологии совместно формируют реализуемое видение: Туманные вычисления обеспечивают распределённую вычислительную инфраструктуру для эффективной работы FL; FL предоставляет механизм непрерывного адаптивного и распределённого обучения, обогащающего знания автономной сети; а автономная сеть координирует общую архитектуру и оптимизирует ресурсы всей экосистемы.

Потенциальные возможности: Конвергенция этих технологий даёт три группы архитектурных преимуществ. Первое – перенос обработки данных ближе к их источнику данных, что снижает нагрузку на ядро сети, что соответствует требованиям ИМТ-2030 по эффективному использованию полосы пропускания. Второе – механизм FL гарантирует, что необработанные данные не покидают локальную среду, создавая естественный уровень защиты конфиденциальности. Это требование МСЭ-Т подчёркивается в рамках Рекомендаций по управлению ИИ. Третье – автономные сети обеспечивают интеллектуальный уровень координации через цикл MAPE-K, позволяя всей архитектуре работать в режиме zero-touch без «ручного» вмешательства.

Технические проблемы: Конвергенция порождает три группы ключевых проблем. Первая – неоднородность данных в реальных сетях вызывает смещение модели, что снижает качество и надёжность системы распределённого обучения ИИ. Вторая – выделение вычислительных ресурсов тумана для задач FL порождает сложную задачу многокритериальной оптимизации с трудноразрешимым компромиссом между задержкой, энергопотреблением и точностью модели. Третья – в распределённой архитектуре создаются новые уязвимости в системе безопасности, особенно угрозы так называемого отравления модели ИИ и проблему обеспечения «справедливого участия» узлов в FL сети.

VI. БУДУЩИЕ НАПРАВЛЕНИЯ ИССЛЕДОВАНИЙ

На основе выявленных возможностей и проблем предлагаются следующие пять приоритетных направлений исследований для поэтапной реализации конвергентной архитектуры в экосистеме ИМТ-2030. Стандартизация интегрированной эталонной архитектуры: необходимо разработать стандартизованную эталонную архитектурную модель, соответствующую текущим рамкам МСЭ-Т. В ней должны быть чётко определены функциональные блоки, интерфейсы и механизмы координации между уровнями FL-FC-AN. Это создаст общую основу для последовательного сравнения и оценки будущих исследований и разработок.

Адаптивные алгоритмы FL для динамичных сетевых сред: необходимо разработать алгоритмы FL, специально для телекоммуникационной среды. Они должны справляться с неоднородностью данных, отключением

устройств и непрерывными временными потоками данных. Федеративное обучение с подкреплением также является перспективным направлением, совместимым с механизмом цикла MAPE-K в автономных сетях.

Интеллектуальное управление ресурсами тумана: необходимо решить задачу многокритериального распределения ресурсов многофункционального узла тумана, где вычислительные ресурсы, память и полоса пропускания динамически делятся между агрегацией FL, обработкой в реальном времени и выполнением политики автономии. Это актуальная прикладная задача, особенно в условиях ограниченных граничных ресурсов.

Распределённая безопасность и доверенный ИИ: Нужны механизмы обнаружения и предотвращения атак типа «отравление модели», стимулирования равноправного участия, а также разработка распределённого объяснимого ИИ в реальном времени. Последнее является обязательным требованием для критически важных автономных систем согласно принципам управления ИИ МСЭ-Т.

Интеграция с новыми технологиями 6G: Конвергентная архитектура должна быть расширена для интеграции с реконфигурируемыми интеллектуальными логическими «поверхностями», негеостационарными сетями и интегрированным зондированием. Эти технологии определены в МСЭ-Р М.2160 как важные компоненты экосистемы ИМТ-2030. Такое расширение требует комплексного архитектурного мышления и углублённых междисциплинарных исследований.

СПИСОК ЛИТЕРАТУРЫ

- [1] A.N. Volkov, A.S. Muthanna, and A.E. Koucheryavy, "Communication networks of the fifth generation: on the way to networks 2030," *Information Technologies and Telecommunications*, vol. 78, no. 2, pp. 32–43, 2020.
- [2] ITU-R, "Framework and overall objectives of the future development of IMT for 2030 and beyond," Recommendation ITU-R M.2160, Geneva, Switzerland, 2023.
- [3] ITU-T, "Architectural framework for machine learning in future networks including IMT-2020," Recommendation ITU-T Y.3172, Geneva, Switzerland, 2019.
- [4] ITU-T, "Cloud computing – Functional requirements of Network as a Service," Recommendation ITU-T Y.3513, Geneva, Switzerland, 2016.
- [5] ITU-T, "Framework for Autonomous Networks," Recommendation ITU-T Y.3061, Geneva, Switzerland, 2023.
- [6] Bonomi, F., Milito, R., Zhu, J., & Addepalli, S. (2012, August). Fog computing and its role in the internet of things. In *Proceedings of the first edition of the MCC workshop on Mobile cloud computing* (pp. 13-16).
- [7] D. V. Thang, A. Volkov, A. Muthanna, A. Koucheryavy, A. A. Ateya et al., "Future of telepresence services in the evolving fog computing environment: A survey on research and use cases," *Sensors*, vol. 25, no. 11, 2025.
- [8] McMahan, B., Moore, E., Ramage, D., Hampson, S., & y Arcas, B. A. (2017, April). Communication-efficient learning of deep networks from decentralized data. In *Artificial intelligence and statistics Fort Lauderdale, 20-22 April 2017* (pp. 1273-1282). Pmlr.
- [9] Li, T., Sahu, A. K., Talwalkar, A., & Smith, V. (2020). Federated learning: Challenges, methods, and future directions. *IEEE signal processing magazine*, 37(3), 50-60.
- [10] S. Hosseinalipour, S.S. Azam, C.G. Brinton, N. Michelusi, V. Aggarwal, D.J. Love, and H. Dai, "Multi-stage hybrid federated learning over large-scale D2D-enabled fog networks," *IEEE/ACM Trans. Netw.*, vol. 30, no. 4, pp. 1569–1584, Aug. 2022, doi: 10.1109/TNET.2022.3143495
- [11] Sirohi, D., Kumar, N., Rana, P.S. et al. Federated learning for 6G-enabled secure communication systems: a comprehensive survey. *Artif Intell Rev* 56, 11297–11389 (2023). <https://doi.org/10.1007/s10462-023-10417-3>