

Научная статья

УДК 621.391

<https://doi.org/10.31854/1813-324X-2026-12-4-132-140>

EDN:ZDEIOQ



Миграция сервисов и распределение ресурсов для взаимодействия человека с аватаром

✉ Хуссейн Али Я. Ясир ✉, yasir.hay@sut.ru

Аммар Салех А. Мутханна, muthanna.asa@sut.ru

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

Аннотация

Актуальность исследования. Системы телеприсутствия и взаимодействия с аватарами предъявляют жесткие требования к задержке передачи данных. Традиционные алгоритмы балансировки нагрузки, такие как Round-Robin, не обладают адаптивностью к изменяющимся условиям сети и вычислительной нагрузки, что приводит к росту латентности. С появлением сетей 6G и ростом объемов мультимодальных данных (видео-, аудио- и тактильная информация) возникает потребность в быстрой миграции сервисов для обеспечения иммерсивного взаимодействия. Отсутствие механизмов интеллектуального распределения ресурсов препятствует использованию приложений телеприсутствия в таких сферах, как телемедицина, дистанционное управление роботами и виртуальное сотрудничество.

Цель исследования: повышение эффективности миграции сервисов и распределения ресурсов в периферийных вычислительных сетях для систем взаимодействия «человек–аватар» за счет разработки алгоритма на основе многоагентного обучения с подкреплением (MARL). В данном исследовании рассматривается вопрос снижения общей задержки при распределении гетерогенных услуг телеприсутствия между вычислительными ресурсами с ограниченной мощностью.

Методы исследования: аналитическое моделирование, имитационное моделирование в MATLAB, сравнительный анализ разработанного алгоритма ML-MARL с эталонным алгоритмом Round-Robin.

Результаты исследования. Разработанный алгоритм ML-MARL, использующий Q-обучение, позволяет снизить общую задержку распределения сервисов на 60 % (с 66 до 26 мс) в сравнении с Round-Robin. Показана сходимость алгоритма за 500 эпизодов обучения.

Научная новизна: впервые предложено применение многоагентного Q-обучения с модифицированной стратегией для задачи оперативной миграции сервисов в системах телеприсутствия.

Теоретическая значимость: полученные результаты расширяют теоретические основы применения MARL в сетях 6G для задач с жесткими ограничениями на задержку.

Практическая значимость: предложенный алгоритм может быть использован при разработке систем удаленной телемедицины, виртуального присутствия, тактильного интернета и промышленной робототехники, где критична задержка менее 30 мс. Результаты данного исследования могут быть применены в перспективных системах оркестрации периферийных вычислений, которые будут работать в сетях 6G.

Ключевые слова: миграция сервисов, MARL, Round-Robin, телеприсутствие, аватар, распределение ресурсов, сети 6G

Ссылка для цитирования: Ясир Х.А.Я., Мутханна А.С.А. Миграция сервисов и распределение ресурсов для взаимодействия человека с аватаром // Труды учебных заведений связи. 2026. Т. 12. № 4. С. 132–140. DOI:10.31854/1813-324X-2026-12-4-132-140. EDN:ZDEIOQ

Original research

<https://doi.org/10.31854/1813-324X-2026-12-4-132-140>

EDN:ZDEIOQ

Service Migration and Resource Allocation for Human-to-Avatar Interaction

 **Hussein A.Ya. Yasir** ✉, yasir.hay@sut.ru

 **Ammar S.A. Muthanna**, muthanna.asa@sut.ru

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

Annotation

Relevance. Telepresence and human-avatar interaction systems impose strict requirements on data transmission latency. Traditional load-balancing algorithms, such as Round-Robin, lack adaptability to changing network conditions and computational loads, resulting in increased latency. With the advent of 6G networks and the growing volume of multimodal data (e. g., video, audio, and haptic information), there is a need for rapid service migration to ensure immersive interaction. The absence of intelligent resource allocation mechanisms hinders the deployment of telepresence applications in fields such as telemedicine, remote robot control, and virtual collaboration.

Purpose of the work. To improve the efficiency of service migration and resource allocation in edge computing networks for human-avatar interaction systems by developing an algorithm based on Multi-Agent Reinforcement Learning (MARL). This study addresses the challenge of reducing total latency when distributing heterogeneous telepresence services across computing resources with limited capacity.

Methods used. Analytical modeling, simulation in MATLAB, and a comparative analysis of the developed ML-MARL algorithm against the baseline Round-Robin algorithm.

The results. The developed ML-MARL algorithm, utilizing Q-learning, reduces total service allocation latency by 60% (from 66 ms to 26 ms) compared to Round-Robin. The algorithm is shown to converge within 500 training episodes.

Scientific Novelty. This study proposes, for the first time, the application of multi-agent Q-learning with a modified strategy to the problem of rapid service migration in telepresence systems.

Theoretical significance. The results obtained expand the theoretical foundations for applying MARL in 6G networks to tasks with strict latency constraints.

Practical significance. The proposed algorithm can be used in the development of systems for remote telemedicine, virtual presence, the Tactile Internet, and industrial robotics, where latency of less than 30 ms is critical.

Keywords: service migration, MARL, Round-Robin, telepresence, avatar, resource allocation, 6G networks

For citation: Yasir H.A.Ya., Muthanna A.S.A. Service Migration and Resource Allocation for Human-to-Avatar Interaction. *Proceedings of Telecommunication Universities*. 2026; 12(4):132–140. (in Russ.) DOI:10.31854/1813-324X-2026-12-4-132-140. EDN:ZDEIOQ

1. Введение

Современные системы телеприсутствия, обеспечивающие взаимодействие человека с аватаром в виртуальной и дополненной реальности, требуют передачи больших объемов мультимодальных данных – видео-, аудио-, тактильных сигналов, данных о движении. Согласно [1, 2], совокупная задержка (латентность) обработки и передачи информации в таких системах не должна превышать 30 мс для обеспечения эффекта погружения и безопасного взаимодействия. Ключевой проблемой является

динамический характер нагрузки: при изменении позы пользователя, перемещении аватара или подключении новых сервисов возникает необходимость оперативной миграции вычислительных задач между периферийными серверами. Традиционные алгоритмы балансировки нагрузки, в частности Round-Robin, распределяют сервисы равномерно, но не учитывают текущую загруженность серверов и задержки каналов связи [3]. Это приводит к перегрузке отдельных узлов и росту латентности.

В последние годы для решения задач адаптивного распределения ресурсов активно применяются методы обучения с подкреплением (RL, *аббр. от англ.* Reinforcement Learning) и многоагентного обучения с подкреплением (MARL, *аббр. от англ.* Multi-Agent RL) [4–6]. Однако их применение для миграции сервисов в системах телеприсутствия остается недостаточно изученным. Целью настоящей работы является повышение эффективности миграции сервисов и распределения ресурсов в периферийных вычислительных сетях для систем взаимодействия «человек-аватар» за счет разработки алгоритма на основе MARL.

Для достижения поставленной цели решены следующие задачи:

- 1) формализация задачи миграции сервисов в терминах марковского процесса принятия решений (MDP, *аббр. от англ.* Markov Decision Process);
- 2) разработка модификации алгоритма независимого Q -обучения (IQL, *аббр. от англ.* Independent Q-Learning) для группы агентов-сервисов;
- 3) проведение имитационного эксперимента и сравнительный анализ разработанного алгоритма с эталонным алгоритмом Round-Robin;
- 4) количественная оценка достигнутого снижения задержки.

2. Технология взаимодействия человека с аватаром с использованием костюма телеприсутствия

Одной из последних разработок в области интерактивных технологий взаимодействия человека и аватара является тактильный костюм телеприсутствия [7, 8]. Эта технология представляет собой аппаратное решение, интегрирующее элементы виртуальной и дополненной реальности (VR / AR, *аббр. от англ.* Virtual Reality / Augmented Reality), Internet of Skills (IoS), интернета вещей (IoT, *аббр. от англ.* Internet of Things) и тактильного интернета (Tactile Internet). Ключевыми элементами являются различные датчики, специально разработанные для сбора и анализа больших объемов данных о движении и взаимодействии [9].

Важными частями костюмов телеприсутствия являются [9]:

- система тактильной обратной связи (для воссоздания тактильных ощущений могут использоваться электрические или мягкие робототехнические приводы, создающие вибрацию, давление или другие физические воздействия [10, 11]);
- синхронизация в реальном времени и захват движений (акселерометры, гироскопы и инерциальные измерительные блоки воспринимают движения и передают информацию аватару, что обеспечивает координацию [12, 13]; система распознает движение по шести степеням свободы (x, y, z , тангаж, рыскание, крен) [14]);

- распознавание жестов и эмоций (технологии компьютерного зрения и ИИ распознают мимику, жесты и позы, которые затем передаются аватару [15, 16]).

Совокупный поток данных от одного пользователя может достигать 100 Мбит/с при частоте опроса датчиков до 1000 Гц [17]. Вычислительная нагрузка распределяется между периферийными серверами, облачными платформами и устройствами пользователя [18]. Неравномерность нагрузки возникает из-за различий в сложности обработки разных типов данных: тактильная обратная связь требует сверхнизкой задержки (<10 мс), в то время как видео может быть обработано с задержкой до 30 мс [19, 20]. Таким образом, системы телеприсутствия генерируют гетерогенный поток данных, требующий адаптивной миграции вычислительных задач между узлами сети. Формализация этой задачи представлена в следующем разделе.

3. Модель и алгоритм распределения ресурсов на основе MARL

Для применения методов обучения с подкреплением задача миграции сервисов представлена в виде MDP, задаваемого кортежем (S, A, R, P) [20].

Состояние среды в момент времени t описывается кортежем, включающим:

- текущую доступную емкость каждого сервера $C_a(t)$;
- матрицу задержек между сервисом i и сервером a , $d_{\{i,a\}}(t)$;
- вычислительную нагрузку, требуемую каждым сервисом $L_i(t)$.

Действием агента, соответствующего сервису i , является выбор сервера a из множества $A = \{1, 2, \dots, M\}$ для размещения или миграции сервиса.

Мгновенное вознаграждение определяется как отрицательная задержка, что побуждает агента минимизировать латентность:

$$R(s, a) = -d_{\{i,a\}}.$$

Переход в новое состояние детерминирован. Если выбранный сервер a обладает достаточной емкостью для размещения сервиса i , то есть $C_a \geq L_i$, то нагрузка назначается, и доступная емкость сервера уменьшается:

$$C_a \leftarrow C_a - L_i.$$

В противном случае назначение считается невозможным, и агент выбирает другой сервер.

Целью обучения является максимизация суммарного дисконтированного вознаграждения за эпизод:

$$J = E \left[\sum_{t=0..T} \gamma^t \cdot R(s_t, a_t) \right],$$

где $\gamma = 0,95$ – коэффициент дисконтирования; T – горизонт планирования (длина эпизода).

Для экспериментальной проверки предложенного алгоритма была разработана сетевая модель, включающая три уровня вычислительной инфраструктуры: устройства пользователя (клиенты), периферийные вычислительные узлы (edge-серверы) и облачную платформу. Сервисы телеприсутствия, связанные с обработкой тактильных данных, видеопотоков и движений аватара, могут быть размещены на любом из этих уровней. При изменении условий сети или перегрузке отдельных узлов возникает необходимость миграции сервисов – их переноса с одного вычислительного ресурса на другой. На рисунке 1 представлена обобщенная схема такой сети, демонстрирующая возможные пути перемещения сервисов между пользовательскими устройствами, периферийными серверами и облаком.




Рис. 1. Схема сети для миграции сервисов телеприсутствия

Fig. 1. Network Architecture for Telepresence Service Migration

Выбор целевого узла для миграции сервиса осуществляется на основе анализа текущего состояния сети. В данной работе сравниваются два подхода к принятию таких решений. Первый, Round-Robin, представляет собой статический алгоритм, при котором сервисы распределяются по серверам циклически, без учета их текущей загрузки и задержек каналов связи. Второй, разработанный алгоритм ML-MARL, использует многоагентное обучение с подкреплением: каждый сервис выступает в роли независимого агента, который на основе накопленного опыта выбирает сервер, минимизирующий задержку. На рисунке 2 схематично представлен процесс принятия решений обоими алгоритмами.

В экспериментальной постановке множество сервисов обозначается как $S = \{1, \dots, N\}$ при $N = 10$, а множество серверов – как $A = \{1, \dots, M\}$ при $M = 5$. Каждый сервис $i \in S$ имеет вычислительную нагрузку L_i (переменная serviceLoad), а каждый сервер $a \in A$ обладает доступной емкостью C_a (переменная serverCapacity). Задержка (латентность) при назначении сервиса i на сервер a обозначается как $d_{i,a}$ (переменная delayMatrix).




Рис. 2. Схема принятия решений алгоритмами Round-Robin и ML-MARL

Fig. 2. Decision-Making Process of the Round-Robin and ML-MARL Algorithms

Назначение по методу Round-Robin представляется бинарной матрицей $A^{RR} \in \{0,1\}^{N \times M}$, где $A_{i,a}^{RR} = 1$, если сервис i размещен на сервере a .

Суммарная задержка при использовании Round-Robin вычисляется как:

$$T_{RR} = \sum_{i=1}^N \sum_{a=1}^M A_{i,a}^{RR} d_{i,a}.$$

Алгоритм Round-Robin работает циклически: каждый следующий сервис назначается на следующий по порядку сервер независимо от текущей загрузки серверов и значений задержек.

В данной работе используется децентрализованный подход с независимыми Q -таблицами (IQL).

Выбор IQL обусловлен:

- меньшей вычислительной сложностью по сравнению с кооперативными алгоритмами (MADDPG, QMIX);
- возможностью работы в динамически меняющемся составе сервисов;
- отсутствием необходимости в централизованном сборе информации обо всех агентах.

В коллаборативном алгоритме ML-MARL каждый сервис i поддерживает строку Q -таблицы $Q_{i,:} \in \mathbb{R}^M$ (переменная $Q_table_ML_MARL$). Агент выбирает действие (сервер), либо исследуя случайный выбор с вероятностью ϵ , либо используя стратегию greedy (жадную стратегию выбора действия), т. е. решение задачи, когда на каждом шаге выбирается наиболее выгодный вариант без учета будущих последствий:

$$a_i = \begin{cases} \text{Uniform}(1, \dots, M), & \text{с вероятностью } \epsilon, \\ \arg\max_{a \in \mathcal{A}} Q_{i,a}, & \text{с вероятностью } 1 - \epsilon. \end{cases}$$

Если выбранный сервер способен обработать нагрузку L_i , его оставшаяся емкость обновляется по правилу:

$$C_a \geq L_i: C_a \leftarrow C_a - L_i.$$

Мгновенное вознаграждение определяется как отрицательная задержка:

$$r_{i,a} = -d_{i,a}.$$

Обновление Q -таблицы производится по стандартному правилу обучения с параметрами скорости обучения $\alpha = 0,1$ и коэффициентом дисконтирования $\gamma = 0,95$:

$$Q_{i,a} \leftarrow Q_{i,a} + \alpha (r_{i,a} + \gamma \max_{a'} Q_{i,a'} - Q_{i,a}).$$

Параметр ϵ уменьшается по геометрическому закону:

$$\epsilon_{t+1} = \max(\epsilon_{\min}, \epsilon_t \cdot \rho),$$

где $\rho = 0,995$, $\epsilon_{\min} = 0,01$.

Суммарная задержка за эпизод для ML-MARL вычисляется как:

$$T_{ML}^{(e)} = \sum_{i \in \mathcal{S}_{\text{assigned}}} d_{i,a_i^{(e)}},$$

А итоговое назначение после обучения задается жадной стратегией, при которой всегда выбирает действие с наивысшей ожидаемой отдачей:

$$a_i^* = \arg\max_a Q_{i,a}, \quad T_{ML} = \sum_{i=1}^N d_{i,a_i^*}.$$

Наконец, относительное улучшение ML-MARL по сравнению с Round-Robin выражается как:

$$\Delta\% = 100 \times \frac{T_{RR} - T_{ML}}{T_{RR}}$$

ТАБЛИЦА 1. Параметры вычислительного эксперимента

TABLE 1. Simulation Parameters

Параметр	Обозначение	Значение
Количество сервисов	N	10
Количество серверов	M	5
Нагрузка сервиса i	L_i	случайное целое от 1 до 10 у. е.
Емкость сервера a	C_a	20 у. е. (для всех серверов)
Матрица задержек	$d_{\{i,a\}}$	случайное целое от 10 до 100 мс
Количество эпизодов обучения	эпизоды	500
Скорость обучения	α	0,1
Коэффициент дисконтирования	γ	0,95
Начальное значение ϵ	ϵ_0	0,9
Минимальное значение ϵ	$\epsilon_{\min}$	0,01
Коэффициент уменьшения ϵ	ρ	0,995

В отличие от разработанного ML-MARL (IQL), в литературе известны более сложные многоагентные алгоритмы, которые могут быть применены к задаче миграции сервисов:

– MADDPG (аббр. от англ. Multi-Agent Deep Deterministic Policy Gradient) [11] предназначен для сред с непрерывным пространством действий, использует централизованное обучение с децентрализованным исполнением;

– QMIX [12] (кооперативный алгоритм, использующий смешивающую сеть для аппроксимации общей функции ценности);

– IQL [10] (базовый децентрализованный алгоритм, использованный в данной работе).

Применение MADDPG и QMIX в контексте миграции сервисов ограничено высокой вычислительной сложностью и необходимостью централизованного сбора информации, что не всегда выполнимо в распределенных периферийных сетях. Срав-

нение предложенного ML-MARL с MADDPG и QMIX является перспективным направлением дальнейших исследований.

На рисунке 3 показана производительность обоих алгоритмов в течение нескольких эпизодов, оценивающая общую задержку распределения сервисов. Алгоритм Round-Robin, хотя и эффективен для равномерного распределения сервисов на начальном этапе, испытывает увеличение задержек при изменении нагрузки на серверы из-за его недостаточной адаптивности. Напротив, алгоритм ML-MARL демонстрирует заметное улучшение по мере того, как агенты обучаются оптимальным стратегиям распределения, значительно снижая общую задержку по сравнению со статическим подходом Round-Robin.




Рис. 3. Работа различных алгоритмов миграции сервисов

Fig. 3. Performance Comparison of Service Migration Algorithms

На рисунке 4 показана сходимость обоих алгоритмов. Подход Round-Robin поддерживает производительность на одном уровне, поскольку он не может реагировать на изменения в системе. Алгоритм ML-MARL совершенствуется со временем по мере приближения к субоптимальному решению в процессе обучения.




Рис. 4. Сравнение сходимости алгоритмов Round-Robin и ML-MARL

Fig. 4. Convergence Comparison of the Round-Robin and ML-MARL Algorithms

При сравнении двух подходов итоговая задержка составила: $T_{RR} = 66$ мс для алгоритма Round-Robin и $T_{ML} = 26$ мс для алгоритма ML-MARL.

Относительное улучшение:

$$\Delta \% = 100 \times (66 - 26) / 66 \approx 60,6 \%$$

Таким образом, алгоритм ML-MARL работает примерно на 60 % быстрее (с меньшей задержкой), чем алгоритм Round-Robin.

4. Заключение

Достигнутое снижение задержки на 60 % убедительно подтверждает потенциал многоагентного обучения с подкреплением в области распределения ресурсов при взаимодействии человека с аватаром. Перспективы дальнейших исследований связаны с переходом к динамической среде, где задержки могут меняться во времени, со сравнительным анализом с алгоритмами MADDPG и QMIX, а также с включением энергопотребления в состав целевой функции наряду с латентностью. Именно такие адаптивные методы будут играть определяющую роль при практической реализации возможностей иммерсивного телеприсутствия, удаленной робототехники и тактильной медицины в рамках будущей инфраструктуры сетей 6G.

Разработанный алгоритм ML-MARL, реализованный в MATLAB, показал свою состоятельность при сравнении с эталонным алгоритмом циклической маршрутизации. В серии вычислительных экспериментов с десятью сервисами и пятью серверами алгоритм ML-MARL продемонстрировал снижение суммарной задержки распределения сервисов с 66 до 26 мс, что в относительном выражении соответствует улучшению примерно на 60 %. Анализ кривых обучения подтвердил устойчивую сходимость алгоритма в пределах 500–700 эпизодов, в то время как алгоритм Round-Robin не демонстрировал какого-либо улучшения во времени. Вместе с тем, проведенное исследование имеет ограничения: эксперименты выполнялись в статической среде с неизменной матрицей задержек, не учитывались накладные расходы на саму процедуру миграции сервиса, а децентрализованный подход не предполагает явной координации между агентами, что может приводить к субоптимальным назначениям.

Несмотря на указанные ограничения, предложенный алгоритм ML-MARL представляет собой практически значимый шаг в создании интеллектуальных механизмов управления миграцией сервисов для систем телеприсутствия. Полученное снижение задержки на 60 % убедительно демонстрирует потенциал многоагентного обучения с подкреплением в задачах распределения ресурсов для взаимодействия человека с аватаром. Дальнейшие исследования могут быть направлены на пере-

ход к динамической среде с изменяющимися нагрузками, сравнительный анализ с алгоритмами MADDPG и QMIX, а также – на включение в целевую функцию энергопотребления наряду с латентностью. Именно такие адаптивные методы будут играть ключевую роль в реализации потенциала иммерсивного телеприсутствия, удаленной робототехники и тактильной медицины в инфраструктуре сетей 6G.

Методы многоагентного обучения с подкреплением доказали свою эффективность и могут быть использованы для улучшения управления вычислительными ресурсами в децентрализованных системах сети связи 6G с помощью предложенного алгоритма. В отличие от распространенных подходов к балансировке нагрузки, где централизация не учитывается, вышеупомянутый метод, в отличие

от любых существующих алгоритмов балансировки нагрузки, которые не принимают во внимание централизацию, может быть скорректирован в соответствии с изменениями объема вычислений, выполняемых в любой данный момент (вычислительная нагрузка), объема вычислительных ресурсов (вычислительного оборудования), доступных в сети, или времени, необходимого для доставки сообщения до места назначения (задержка) или его возврата (время кругового пути). Благодаря этому свойству (способность адаптироваться ко всем типам изменений условий сети, включая вычислительную нагрузку, доступность ресурсов и задержку), этот метод может быть хорошим решением для приложений телеприсутствия, требующих максимально быстрой обработки информации из различных источников или типов данных (модальные).

Список источников

1. Кучерявый А.Е., Давуд А.А.А., Волков А.Н., Мутханна А.С.А., Парамонов А.И., Елагин В.С. и др. Сети связи шестого поколения: фрактальные архитектуры, голографические взаимодействия, телеприсутствие, сетевые роботы. СПб.: Питер, 2025. 320 с.
2. Волков А.Н., Мутханна А.С.А., Кучерявый А.Е., Бородин А.С., Парамонов А.И., Владимиров С.С. и др. Перспективные исследования сетей и услуг 2030 в лаборатории 6G MEGANETLAB СПбГУТ // Электросвязь. 2023. № 6. С. 5–14. DOI:10.34832/ELSV.2023.43.6.001. EDN:CJSYLS
3. Ateya A.A., Abd El-Latif A.A., Muthanna A., Volkov A., Koucheryavy A. Enabling Metaverse and Telepresence Services in 6G Networks. New York: River Publishers, 2025. DOI:10.1201/9788770046749
4. Li T., Sahu A. K., Talwalkar A., Smith V. Federated Learning: Challenges, Methods, and Future Directions // IEEE Signal Processing Magazine. 2020. Vol. 37. Iss. 3. PP. 50–60. DOI:10.1109/msp.2020.2975749. EDN:BFBNOW
5. Аль-Кереа З.А.Х., Мутханна А.С.А., Кучерявый А.Е. Интеллектуальная бессерверная вычислительная система для услуг телеприсутствия // Труды учебных заведений связи. 2025;11(4):18–27. DOI:10.31854/1813-324X-2025-11-4-18-27. EDN:UOYTAY
6. Al-Kerea Z., Yasir H., Lapteva T., Volkov A., Muthanna A., Ibrahim M. Hybrid traffic Offloading method for distributed edge computing in 6G networks // Proceedings of the 8th International Conference on Future Networks & Distributed Systems (ICFNDS '24, Marakech, Morocco, 11–12 December 2024). New York: Association for Computing Machinery, 2025. PP. 930–937. DOI:10.1145/3726122.3726258
7. Ren J., Wang H., Hou T., Zheng S., Tang C. Federated Learning-Based Computation Offloading Optimization in Edge Computing-Supported IoT Networks // IEEE Access. 2020. Vol. 7. PP. 69194–69201. DOI:10.1109/ACCESS.2019.2919736
8. Shlezinger N., Chen M., Eldar Y.C., Poor H.V., Cui S. Federated Learning with Quantization Constraints // Proceedings of the International Conference on Acoustics, Speech and Signal Processing (ICASSP, Barcelona, Spain, 04–08 May 2020). IEEE, 2020. DOI:10.1109/ICASSP40776.2020.9054168
9. Mothukuri V., Parizi R.M., Pouriyeh S., Huang Y., Dehghantanha A., Srivastava G. A survey on security and privacy of federated learning // Future Generation Computer Systems. 2021. Vol. 115. PP. 619–640. DOI:10.1016/j.future.2020.10.007. EDN:FQPQGY
10. Yasir H., Al-Kerea Z., Vorozheykina O., Muthanna A., Shamshieva N.N. kizi. Intelligence serverless computing system for telepresence services // Proceedings of the 8th International Conference on Future Networks & Distributed Systems (ICFNDS '24, Marakech, Morocco, 11–12 December 2024). New York: Association for Computing Machinery, 2025. PP. 938–944. DOI:10.1145/3726122.3726259
11. Lim W.Y.B., Luong N.C., Hoang D.T., Jiao Y., Liang Y.-C., Yang Q. Federated learning in mobile edge networks: A comprehensive survey // IEEE Communications Surveys & Tutorials. 2021. Vol. 22. Iss. 3. PP. 2031–2063. DOI:10.1109/COMST.2020.2986024. EDN:CUJNTK
12. Chen M., Yang Z., Saad W., Yin C., Poor H.V., Cui S. A Joint Learning and Communications Framework for Federated Learning Over Wireless Networks // IEEE Transactions on Wireless Communications. 2020. Vol. 19. Iss. 7. PP. 4941–4954. DOI:10.1109/TWC.2020.3024629
13. Ясир Х.А., Аль-Кереа З.А., Мутханна А.С. Инновационные решения граничных вычислений для сетей 6G: интеграция современных платформ и оркестрация с помощью Kubernetes // Научно-техническая конференция Санкт-Петербургского НТО РЭС им. А.С. Попова, посвященная Дню радио. 2025. № 1(80). С. 168–170. EDN:EVGPDZ
14. Savazzi S., Nicoli M., Bennis M., Kianoush S., Barbieri L. Opportunities of Federated Learning in Connected, Cooperative, and Automated Industrial Systems // IEEE Communications Magazine. 2021. Vol. 59. Iss. 2. PP. 16–21. DOI:10.1109/mcom.001.2000200. EDN:DAKPCL

15. Ясир Х.А., Аль-Кереа З.А., Мутханна А.С. Метод агрегирования данных для распределенных туманных вычислений в сетях автотранспорта // Научно-техническая конференция Санкт-Петербургского НТО РЭС им. А.С. Попова, посвященная Дню радио. 2025. № 1(80). С. 175–178. EDN:FQJKVP
16. Lu Y., Huang X., Dai Y., Maharjan S., Zhang Y. Blockchain and Federated Learning For Privacy-Preserved Data Sharing in Industrial IoT // IEEE Transactions on Industrial Informatics. 2020. Vol. 16. Iss. 6. PP. 4177–4186. DOI:10.1109/tii.2019.2942190. EDN:MCGZXF
17. Muthanna M.S.A., Wang P., Wei M., Ateya A.A., Muthanna A. Toward an Ultra-Low Latency and Energy Efficient LoRaWAN // Proceedings of the 19th International Conference, NEW2AN 2019, and 12th Conference, ruSMART 2019 (St. Petersburg, Russia, 26–28 August 2019). Internet of Things, Smart Spaces, and Next Generation Networks and Systems. Lecture Notes in Computer Science. Cham: Springer, 2019. Vol. 11660. PP. 233–242. DOI:10.1007/978-3-030-30859-9_20. EDN:TDMNSL
18. Кучерявый А.Е., Маколкина М.А., Парамонов А.И., Выборнова А.И., Мутханна А.С., Матюхин А.Ю. и др. Модельная сеть для исследований и обучения в области услуг телеприсутствия // Электросвязь. 2022. № 1. С. 14–20. DOI:10.34832/ELSV.2022.26.1.001. EDN:GBQWCV
19. Singh S.P., Nayyar A., Kumar R., Sharma A. Fog computing: From architecture to edge computing and big data processing // The Journal of Supercomputing. 2019. Vol. 75. PP. 2070–2105. DOI:10.1007/s11227-018-2701-2. EDN:ELSEWT
20. Yasir H., Al-Kerea Z., Qahtan A.M., Gorbacheva L., Muthanna A. A Novel Collaborative Reinforcement Learning Method for Human-to-Avatar Interactions // Proceedings of the 24th International Conference, NEW2AN 2024, and 17th Conference, ruSMART 2024 (Marrakesh, Morocco, 11–12 December 2024). Internet of Things, Smart Spaces, and Next Generation Networks and Systems. Lecture Notes in Computer Science. Cham: Springer, 2025. Vol. 15554. PP. 67–78. DOI:10.1007/978-3-031-95299-9_7

References

1. Kucheryavy A.E., Davud A.A.A., Volkov A.N., Muthanna A.S.A., Paramonov A.I., Elagin V.S., et al. *Sixth-Generation Communication Networks: Fractal Architectures, Holographic Interactions, Telepresence, Network Robots*. St. Petersburg: Piter Publ.; 2025. 320 p. (in Russ.)
2. Volkov A.N., Muthanna A.S.A., Kucheryavy A.E., Borodin A.S., Paramonov A.I., Vladimirov S.S., et al. Perspective Research of Networks and Services 2030 in the Laboratory 6G Meganetlab SPBSUT. *Electrosvyaz*. 2023;6:5–14. (in Russ.) DOI:10.34832/ELSV.2023.43.6.001. EDN:CJSYLS
3. Ateya A.A., Abd El-Latif A.A., Muthanna A., Volkov A., Koucheryavy A. *Enabling Metaverse and Telepresence Services in 6G Networks*. New York: River Publishers; 2025. DOI:10.1201/9788770046749
4. Li T., Sahu A. K., Talwalkar A., Smith V. Federated Learning: Challenges, Methods, and Future Directions. *IEEE Signal Processing Magazine*. 2020;37(3):50–60. DOI:10.1109/msp.2020.2975749. EDN:BFBNOW
5. Al-Kerea Z.A.H., Muthanna A.S.A., Koucheryavy A.E. Intelligent Serverless Computing System for Telepresence Services. *Proceedings of Telecommunication Universities*. 2025;11(4):18–27. (in Russ.) DOI:10.31854/1813-324X-2025-11-4-18-27. EDN:UOYTA
6. Al-Kerea Z., Yasir H., Lapteva T., Volkov A., Muthanna A., Ibrahim M. Hybrid traffic Offloading method for distributed edge computing in 6G networks. *Proceedings of the 8th International Conference on Future Networks & Distributed Systems, ICFNDS '24, 11–12 December 2024, Marakech, Morocco*. New York: Association for Computing Machinery; 2025. p.930–937. DOI:10.1145/3726122.3726258
7. Ren J., Wang H., Hou T., Zheng S., Tang C. Federated Learning-Based Computation Offloading Optimization in Edge Computing-Supported IoT Networks. *IEEE Access*. 2020;7:69194–69201. DOI:10.1109/ACCESS.2019.2919736
8. Shlezinger N., Chen M., Eldar Y.C., Poor H.V., Cui S. Federated Learning with Quantization Constraints. *Proceedings of the International Conference on Acoustics, Speech and Signal Processing, ICASSP, 04–08 May 2020, Barcelona, Spain*. IEEE; 2020. DOI:10.1109/ICASSP40776.2020.9054168
9. Mothukuri V., Parizi R.M., Pouriyeh S., Huang Y., Dehghantanha A., Srivastava G. A survey on security and privacy of federated learning. *Future Generation Computer Systems*. 2021;115:619–640. DOI:10.1016/j.future.2020.10.007. EDN:FQPQGY
10. Yasir H., Al-Kerea Z., Vorozheykina O., Muthanna A., Shamshieva N.N. kizi. Intelligence serverless computing system for telepresence services. *Proceedings of the 8th International Conference on Future Networks & Distributed Systems, ICFNDS '24, 11–12 December 2024, Marakech, Morocco*. New York: Association for Computing Machinery; 2025. p.938–944. DOI:10.1145/3726122.3726259
11. Lim W.Y.B., Luong N.C., Hoang D.T., Jiao Y., Liang Y.-C., Yang Q. Federated learning in mobile edge networks: A comprehensive survey. *IEEE Communications Surveys & Tutorials*. 2021;22(3):2031–2063. DOI:10.1109/COMST.2020.2986024. EDN:CUJNTK
12. Chen M., Yang Z., Saad W., Yin C., Poor H.V., Cui S. A Joint Learning and Communications Framework for Federated Learning Over Wireless Networks. *IEEE Transactions on Wireless Communications*. 2020;19(7):4941–4954. DOI:10.1109/TWC.2020.3024629
13. Yasir H.A., Al-Kerea Z.A., Muthanna A.S. Innovative Edge Computing Solutions for 6G Networks: Integration of Modern Platforms and Orchestration Using Kubernetes. *Scientific and Technical Conference of the St. Petersburg Scientific and Technical Association of the Russian Electronic Networks Named after A.S. Popov, Dedicated to Radio Day*. 2025;1(80):168–170. (in Russ.) EDN:EVGPDZ
14. Savazzi S., Nicoli M., Bennis M., Kianoush S., Barbieri L. Opportunities of Federated Learning in Connected, Cooperative, and Automated Industrial Systems. *IEEE Communications Magazine*. 2021;59(2):16–21. DOI:10.1109/mcom.001.2000200. EDN:DAKPCL

15. Yasir H.A., Al-Kerea Z.A., Muthanna A.S. A Method for Aggregating Data for Distributed Fog Computing in Vehicle Networks. *Scientific and Technical Conference of the St. Petersburg Scientific and Technical Association of the Russian Electronic Networks Named after A.S. Popov, Dedicated to Radio Day*. 2025;1(80):175–178. (in Russ.) EDN:FQJKVP
16. Lu Y., Huang X., Dai Y., Maharjan S., Zhang Y. Blockchain and Federated Learning For Privacy-Preserved Data Sharing in Industrial IoT. *IEEE Transactions on Industrial Informatics*. 2020;16(6):4177–4186. DOI:10.1109/tii.2019.2942190. EDN:MCGZXF
17. Muthanna M.S.A., Wang P., Wei M., Ateya A.A., Muthanna A. Toward an Ultra-Low Latency and Energy Efficient LoRaWAN. *Proceedings of the 19th International Conference, NEW2AN 2019, and 12th Conference, ruSMART 2019, 26–28 August 2019, St. Petersburg, Russia. Internet of Things, Smart Spaces, and Next Generation Networks and Systems. Lecture Notes in Computer Science, vol.11660*. Cham: Springer; 2019. p.233–242. DOI:10.1007/978-3-030-30859-9_20. EDN:TDMNSL
18. Koucheryavy A.E., Makolkina M.A., Paramonov A.I., Vybornova A.I., Muthanna A.S., Matyuhin A.Yu., et al. Model Network for Research, Training, and Testing in the Area of Telepresence Services. *Electrosvyaz*. 2022;1:14–20. DOI:10.34832/ELSV.2022.26.1.001. EDN:GBQWCV
19. Singh S.P., Nayyar A., Kumar R., Sharma A. Fog computing: From architecture to edge computing and big data processing. *The Journal of Supercomputing*. 2019;75:2070–2105. DOI:10.1007/s11227-018-2701-2. EDN:ELSEWT
20. Yasir H., Al-Kerea Z., Qahtan A.M., Gorbacheva L., Muthanna A. A Novel Collaborative Reinforcement Learning Method for Human-to-Avatar Interactions. *Proceedings of the 24th International Conference, NEW2AN 2024, and 17th Conference, ruSMART 2024, 11–12 December 2024, Marrakesh, Morocco. Internet of Things, Smart Spaces, and Next Generation Networks and Systems. Lecture Notes in Computer Science, vol.15554*. Cham: Springer; 2025. p.67–78. DOI:10.1007/978-3-031-95299-9_7

Статья поступила в редакцию 17.03.2026; одобрена после рецензирования 27.04.2026; принята к публикации 04.05.2026

The article was submitted 17.03.2026; approved after reviewing 27.04.2026; accepted for publication 04.05.2026

Информация об авторах:

ЯСИР
Хуссейн Али Ясир

аспирант кафедры сетей связи и передачи данных Санкт-Петербургского государственного университета телекоммуникаций им. проф. М.А. Бонч-Бруевича
 <https://orcid.org/0009-0008-9136-6820>

МУТХАННА
Аммар Салех Али

доктор технических наук, профессор кафедры сетей связи и передачи данных Санкт-Петербургского государственного университета телекоммуникаций им. проф. М.А. Бонч-Бруевича
 <https://orcid.org/0000-0003-0213-8145>

Авторы сообщают об отсутствии конфликтов интересов.

The authors declare no conflicts of interests.