

УДК 004.94

<https://doi.org/10.31854/2307-1303-2026-14-2-25-36>

EDN: LPRJVF

Обзор и сравнительный анализ методов федеративного обучения для оптимизации качества обслуживания в гетерогенных сетях телеприсутствия

Лаптева Т. В.  , Мутханна А. С. А. 

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

Аннотация. Одной из ключевых услуг сетей связи шестого поколения является телеприсутствие, предъявляющее повышенные требования к качеству обслуживания. Современным и будущим коммуникационным инфраструктурам характерна высокая степень гетерогенности. В связи с этим обеспечение стабильного уровня качества обслуживания представляет собой сложную задачу, требующую комплексного подхода и инновационных решений. Традиционные методы управления, такие как статическое назначение приоритетов или адаптивные алгоритмы, не обладают достаточной гибкостью, а централизованные подходы машинного обучения сопряжены с рисками конфиденциальности и высокой нагрузкой на сеть. **Целью** настоящей работы является систематизация и сравнительный анализ методов федеративного обучения, применяемых для прогнозирования и оптимизации качества обслуживания в гетерогенных сетях телеприсутствия. **Сущность** предлагаемого в статье подхода заключается в авторской классификации методов федеративного обучения, за основу которой взяты два критерия: архитектурная организация и способ адаптации к гетерогенности. Для каждого класса приведены детальные описания, выделены сильные и слабые стороны. **Принцип** сравнительного анализа строится на сопоставлении подходов по ключевым показателям: точность прогнозирования, скорость сходимости, коммуникационные задержки, конфиденциальность, вычислительная нагрузка на устройства, устойчивость к гетерогенности, сложность реализации и безопасность. Анализ выполнен на основе данных из рецензируемых источников и позволил выявить количественные преимущества сравниваемых показателей (например, сокращение раундов обучения на 1,91–38,89 % и снижение коммуникационных задержек на 9,52–40,00 % для иерархической архитектуры MultiFed). **Экспериментальные данные**, представленные в анализируемых работах, подтверждают, что федеративное обучение обеспечивает баланс между прогностической точностью, конфиденциальностью и масштабируемостью, причем выигрыш наиболее заметен для устройств с гетерогенными данными. **Научная новизна** состоит в предложенной классификации методов федеративного обучения и систематизации их преимуществ и ограничений применительно к специфике сетей телеприсутствия, что позволяет обоснованно выбирать архитектуру в зависимости от сценария использования. **Практическая значимость** определяется сформулированными авторами рекомендациями по выбору методов федеративного обучения для различных условий (региональная гетерогенность, ограниченные ресурсы устройств, жёсткие требования к задержкам), что может быть использовано при проектировании и эксплуатации сетей связи.

Ключевые слова: федеративное обучение, распределенное обучение, телеприсутствие, QoS, гетерогенные сети, 6G, оптимизация задержек, прогнозирование QoS

Библиографическая ссылка на статью:

Лаптева Т. В., Мутханна А. С. А. Обзор и сравнительный анализ методов федеративного обучения для оптимизации качества обслуживания в гетерогенных сетях телеприсутствия // Информационные технологии и телекоммуникации. 2026. Т. 14. № 2. С. 25–36. DOI: 10.31854/2307-1303-2026-14-2-25-36. EDN: LPRJVF

Reference for citation:

Lapteva T., Muthanna A. Federated Learning as a Method for Optimizing Service Quality in Heterogeneous Telepresence Networks // Telecom IT. 2026. Vol. 14. Iss. 2. PP. 25–36. (in Russian). DOI: 10.31854/2307-1303-2026-14-2-25-36. EDN: LPRJVF

1. Введение

Развитие технологий мобильной связи шестого поколения (6G) создает предпосылки для внедрения иммерсивных коммуникационных сервисов, таких как телеприсутствие, совместное вождение и интерактивные метавселенные [1, 2]. Тактильные и мультимодальные коммуникационные сервисы могут применяться в различных областях, например, в промышленности, робототехнике и телеприсутствии, виртуальной и дополненной реальностях, здравоохранении, дорожном движении, образовании, культуре и интеллектуальных сетях. Эти сервисы поддерживают приложения, позволяющие получать входные данные из нескольких источников и / или выдавать выходные данные более чем из одного источника [3]. Реализация указанных сценариев предъявляет повышенные требования к сетевой инфраструктуре.

В настоящее время, исходя из опыта работы Международного союза электросвязи, для сетей связи Российской Федерации определен первый набор услуг телеприсутствия. Для большинства услуг этого набора сеть должна обеспечивать гарантированные параметры качества обслуживания (QoS, *аббр. от англ.* Quality of Service). Так, например, задержка не должна превышать 1–5 мс с вероятностью безотказной работы на уровне 99,9999 %, при условии высокой пропускной способности и поддержки огромного числа устройств и приложений Интернета вещей с различающимися характеристиками трафика и моделями взаимодействия [4].

Обеспечение стабильного QoS осложняется конвергентностью технологий доступа, гетерогенностью абонентских устройств и динамически изменяющимися условиями распространения радиосигнала [2, 5]. Традиционные методы управления QoS, такие, например, как статическое назначение приоритетов и адаптивные алгоритмы, не обладают достаточной гибкостью для адаптации к быстро меняющейся гетерогенной среде. Централизованный сбор данных для обучения моделей машинного обучения (ML, *аббр. от англ.* Machine Learning) сталкивается с фундаментальными ограничениями и порождает риски, связанные с обработкой конфиденциальной информации пользователей и высокими коммуникационными издержками, а также создает высокую нагрузку на сеть [5–7].

Федеративное обучение (FL, *аббр. от англ.* Federated Learning) предлагает альтернативное решение: обучение моделей происходит локально на пользовательских устройствах, а на сервер передаются только обновления параметров моделей, например веса или градиенты, что позволяет сохранить конфиденциальность данных [1, 5–7].

Цель данной работы – провести систематический обзор и сравнительный анализ существующих FL-методов для прогнозирования и оптимизации QoS в гетерогенных сетях телеприсутствия. В отличие от известных обзоров, в статье предлагается авторская классификация методов, выделяются их сильные и слабые стороны, а также формулируются рекомендации по выбору подхода для различных сценариев телеприсутствия.

Во втором разделе представлен обзор существующих методов к оптимизации QoS и их ограничений. В третьем разделе предложена классификация и де-

тальное описание FL-методов и проведен их сравнительный анализ и обсуждение преимуществ и ограничений. В четвертом разделе сформулированы выводы и обозначены направления дальнейших исследований.

2. Существующие подходы оптимизации QoS и их ограничения

Обеспечение поддержки целевых показателей QoS в системах телеприсутствия является критически важной задачей, однако ее решение существенно осложняется динамичностью сетевых условий, разнородностью оборудования и повышенными требованиями к задержкам и синхронизации. Существующие методы, от классических механизмов управления трафиком до передовых моделей ML, демонстрируют определенные успехи, но каждый из них имеет фундаментальные ограничения, не позволяющие в полной мере адаптироваться к распределенному и гетерогенному характеру современных сетей. Ниже последовательно рассмотрены три ключевые группы проблем, которые являются сдерживающим фактором развития эффективных QoS-решений для сетей телеприсутствия.

Традиционные методы управления QoS

Назначение статических приоритетов трафика, применение адаптивных алгоритмов для предотвращения перегрузок и централизованное управление с глобальным видением межсетевого взаимодействия, основаны, как правило, на текущем состоянии телекоммуникаций и имеют серьезные ограничения в гетерогенных сетях телеприсутствия. Системы на основе программно-конфигурируемых сетей (SDN, *аббр. от англ* Software-Defined Networking), позволяющие в автоматическом режиме производить «эластичное» распределение сетевых ресурсов (для задач вычисления, хранения, определения полосы пропускания) под непрерывно изменяющуюся нагрузку, требуют постоянного сбора глобальной информации, что приводит к вычислительным задержкам и инерционности управления. При этом адаптивные алгоритмы учитывают локальные условия, но не способны обучаться на опыте других устройств и не используют предсказательные модели для упреждающей адаптации.

Централизованное ML

В последние годы исследователями активно применяется ML для прогнозирования и оптимизации QoS. Например, в работе [7] для распределения ресурсов в сетях с поддержкой eMBB и URLLC сервисов предложена иерархическая Deep Learning-структура. Однако применение централизованных ML-методов связано с такими проблемами, как:

- высокая задержка обучения, в связи с тем, что для накопления достаточного объема данных требуется значительное время;
- возрастают риски конфиденциальности, связанные с передачей по незащищенным каналам связи на центральный сервер QoS-данных, что нарушает приватность пользователей;

– масштабируемость, так как взаимодействие большого числа устройств телеприсутствия создает непропорционально высокую нагрузку на центры обработки данных.

Проблема гетерогенности данных

Ключевая проблема, ограничивающая эффективность как традиционных, так и централизованных ML-методов, связана с гетерогенностью данных QoS [5, 6]. В сетях телеприсутствия распределение показателей QoS имеет существенные отличия между различными пользователями и устройствами в зависимости от местоположения и сетевого окружения (город, пригород, сельская местность), разнородности абонентского оборудования (вычислительные возможности, тип радиомодуля) и различий в сценариях использования (домашний, корпоративный, медицинский).

Как отмечено в работе [6], параметры QoS измеряемые у разных пользователей неоднородны, данные каждого отдельного абонента дают искаженное представление о распределении по сети в целом.

Сходимость глобальной модели в FL замедляется при использовании стандартных алгоритмов федеративного усреднения (FedAvg, *аббр. от англ. Federated Averaging*), поскольку гетерогенность данных и устройств приводит к значительному расхождению локальных градиентов на разных узлах, из-за чего агрегированные обновления становятся менее стабильными и требуют большего числа раундов обучения.

3. Методы федеративного обучения для оптимизации QoS: классификация и анализ

В данном разделе представлена авторская классификация FL-методов, применяемых для оптимизации QoS в гетерогенных сетях, и детальное их описание (таблица 1). В основу классификации положены два критерия: архитектурная организация и метод адаптации к гетерогенности.

Для решения проблемы гетерогенности и ускорения сходимости моделей прогнозирования QoS предлагается архитектура MultiFed – многоцентровая федеративная система с механизмом облачно-периферийной коллаборации.

Архитектура MultiFed включает три уровня [3]:

- уровень пользовательских устройств (роботы телеприсутствия, VR-гарнитуры), на котором идет сбор локальных метрик QoS (RTT, джиттер, потери пакетов) и обучение локальных моделей;

- уровень периферийных серверов (MEC, *аббр. от англ. Multi-access Edge Computing*), состоящий из географически распределенных узлов, координирующих группы устройств с относительно однородным распределением QoS-данных; на серверах выполняется как внутренние агрегации, направленные на усреднение градиентов от устройств в своей группе для обновления региональной модели, так и внешние агрегации – при координации облачного сервера происходит обмен обновлениями между MEC-серверами;

- облачный уровень, предназначен для координация глобальной агрегации и обеспечения общего взаимодействия всех подсистем.

Такая архитектура, за счет размещения агрегатора на периферии, позволяет снизить задержки коммуникации между устройствами и центральным сервером, а также эффективнее учитывать региональную гетерогенность QoS-данных.

Таблица 1. Классификация FL-методов

По архитектурной организации		По адаптации к гетерогенности	
Централизованный FL-метод (стандартный)	Единый сервер агрегирует обновления от всех клиентов. Прост в реализации, но уязвим к атакам и не учитывает региональную специфику.	Персонализированный FL-метод (pFL)	Для каждого клиента (или группы клиентов) обучается своя модель, адаптированная к его данным. Эффективно при высокой гетерогенности, но сложно в масштабировании [1, 7].
Иерархический FL-метод (MultiFed, облачно-периферийный)	Предполагает наличие промежуточных агрегаторов на периферии (МЕС-серверов), которые объединяют клиентов по географическому или иному признаку. Это снижает задержки связи и лучше учитывает региональную гетерогенность [6].	Конгруэнтный FL-метод	Использует специальные активационные функции, которые стимулируют сходство локальных и глобальной моделей, предотвращая переобучение на гетерогенных данных. Не требует тонкой настройки гиперпараметров [1].
Гибридный федеративно-разделенный FL-метод	Часть модели (например, слой встраивания) обучается локально на периферии, а общая часть (например, трансформерный декодер) – в облаке. Метод позволяет использовать мощные модели на ограниченных устройствах [2].	Многоагентный FL-метод с подкреплением	Каждый агент (устройство) обучает свою политику управления QoS, обмениваясь опытом с другими через федеративный механизм. Хорошо подходит для динамических сред [9].

В рамках развития сетей связи 6G имеет особое значение способность телекоммуникационных систем к автономной саморегуляции без необходимости внешнего вмешательства оператора. В работе [1] рассматривается метод конгруэнтного FL. Ключевой идеей данного метода является введение «конгруэнтных активационных функций», которые применяются не к представлениям слоев, а к параметрам нейронной сети, к весовым матрицам и векторам смещения. Это стимулирует сходство между локальными и глобальной моделями, а также минимизирует и предотвращает переобучение локальных моделей на гетерогенных данных. Метод не требует подбора количества локальных эпох и обеспечивает устойчивость в динамически изменяющихся сетевых условиях, что позволяет автоматизировать процесс обучения без тонкой настройки гиперпараметров даже при ограниченном объеме локальных данных.

Использование обратной связи от устройств для прогнозирования QoS является эффективным подходом для адаптации параметров приложений телеприсутствия к сетевым условиям. В работе [8] исследуются алгоритмы обучения с подкреплением для прогнозируемого качества обслуживания (PQoS, *аббр. от англ. Predictive Quality of Service*) в сетях телеметрии с федеративной конфигурацией.

Для FL с подкреплением зафиксирован ряд показателей:

- Q-Learning с точки зрения сходимости показывает наилучшие результаты вычислительных затрат и достигаемого вознаграждения;
- равномерное распределение ресурсов между разнородными устройствами и снижение временных затрат в процессе сходимости;
- применение нейросетевой аппроксимации, основанной на алгоритме Deep Q-Network, при наличии ограниченного пространства состояний может быть избыточным для решения задач PQoS.

Одним из перспективных направлений для задач с высокими вычислительными требованиями является федеративно-разделенное обучение. Одной из направлений его применения может быть распределение ресурсов в метавселенных. Архитектура Federated Split Decision Transformer, описанная в работе [2], предлагает трансформерную модель, которая разделяется между МЕС-серверами и облаком. При данном методе, для обеспечения адаптации к специфике каждого региона локальные компоненты (слой встраивания и слой прогнозирования) остаются на МЕС-серверах, а совместное обучение и обобщение знаний производится путем размещения в облаке глобального трансформерного декодера. Результаты экспериментов говорят о том, что применение такого метода в гетерогенных средах на 98 % снижает вычислительную нагрузку на МЕС-серверы при одновременном повышении QoS до 10% [2]. Такие результаты достигаются за счет выноса параметров трансформера в облако. Применительно к системам телеприсутствия это означает, что для прогнозирования QoS даже на ограниченных вычислительных ресурсах периферийных устройств возможно использование мощных трансформерных архитектур.

Сравнительный анализ рассмотренных методов представлен в таблице 2. Его результаты говорят о ряде преимуществ применения FL-методов.

1. Снижение задержек коммуникации.

Централизованный сбор данных для обучения моделей QoS создает значительные накладные расходы и задержки. Использование периферийных серверов для агрегации данных позволяет сократить коммуникационные задержки на 9,52–40,00 % по сравнению с традиционными FL-методами [3]. Применение иерархических и гибридных методов критически важно для услуг телеприсутствия, где предъявляются строгие требования к задержкам (до 10 мс).

2. Конфиденциальность данных.

Все FL-методы позволяют обучать модели прогнозирования QoS без передачи пользовательских данных на центральный сервер, тем самым обеспечивая более высокий уровень приватности по сравнению с централизованными. Это критически важно для сценариев, где видеопотоки и данные о перемещениях являются конфиденциальной информацией (медицина и корпоративное телеприсутствие).

Таблица 2. Сравнительный анализ FL-методов для оптимизации QoS

Критерий	Централизованный FL-метод	Иерархический FL-метод (MultiFed)	Конгруэнтный FL-метод	Гибридный FL-метод (Split)
Точность прогнозирования	Средняя (зависит от гетерогенности)	Высокая (учет региональных особенностей)	Высокая (устойчивость к переобучению)	Высокая (использование мощных моделей)
Скорость сходимости	Низкая (при высокой гетерогенности)	Высокая (сокращение раундов на 1,91–38,8 9% [3])	Высокая (автоматическая адаптация)	Средняя (зависит от разделения)
Коммуникационные задержки	Высокие	Снижены на 9,52–40,00 % [3]	Средние	Низкие (отдельные вычислительные операции осуществляются на локальном узле)
Конфиденциальность	Низкая (передача данных)	Высокая	Высокая	Высокая
Вычислительная нагрузка на устройства	Высокая	Средняя	Средняя	Низкая (ниже на 98 % [2])
Устойчивость к гетерогенности	Низкая	Высокая	Очень высокая	Высокая
Сложность реализации	Низкая	Средняя	Средняя	Высокая
Безопасность (защита от атак)	Низкая (уязвимость для отравления)	Средняя (помогает кластеризация)	Средняя	Высокая (разделение модели)

3. Адаптация к гетерогенности.

Благодаря персонализации моделей на локальных устройствах, FL обеспечивает учет индивидуальных особенностей сетевого окружения каждого пользователя. Как отмечается в работе [1], агенты с наиболее гетерогенными данными получают наибольший выигрыш от персонализации.

4. Масштабируемость, применение гибридных методов позволяет использовать мощные модели FL даже на устройствах с ограниченными ресурсами.

Кроме этого, иерархический FL-метод показывает высокую устойчивость к нестабильности соединения. При потере связи с сервером агрегации каждое устройство продолжает работать с последней доступной локальной моделью, что крайне важно для систем телеприсутствия.

Однако, несмотря на все явные преимущества применения различных методов FL, существуют технические ограничения.

1. Ускорение сходимости.

Из-за гетерогенности QoS-данных остается проблема расхождения локальных градиентов и замедление сходимости глобальной модели. Для решения этой

проблемы предлагаются методы персонализированного FL и оптимизированные стратегии агрегации [1, 6, 7], однако они требуют дальнейших исследований.

2. Обеспечение справедливости.

В гетерогенных сетях данные с устройств, работающих в низкокачественных каналах связи, могут быть недостаточно представлены в глобальной модели. Одним из вариантов решения может быть применение многоагентного FL с подкреплением, которое позволяет оптимизировать трафик для каждого сетевого слоя и для каждого индивидуального пользователя [9];

3. Безопасность агрегации.

FL-системы уязвимы для «атак отравления» (poisoning attacks), когда злонамеренные клиенты присылают некорректные градиенты. В статье [10] предложен ряд методов к обеспечению безопасности, включая FL и методы обнаружения аномалий.

4. Ограничения вычислительных ресурсов конечных устройств.

Некоторые устройства телеприсутствия (например, легкие VR-гарнитуры) имеют ограниченные вычислительные возможности. В таких случаях предлагается использование гибридных архитектур с разделением модели между устройством и сервером на границе сети [2].

Кроме этого, в условиях нестабильной связи проявляется зависимость от качества канала и процесс агрегации может нарушаться, что требует разработки асинхронных алгоритмов.

4. Заключение и направления дальнейших исследований

Проведенный аналитический обзор позволяет сделать выводы о том, что применение методов FL является эффективным и перспективным инструментом для оптимизации QoS в гетерогенных сетях телеприсутствия и позволяет обеспечить баланс между прогностической точностью, конфиденциальностью пользовательских данных и масштабируемостью.

По результатам проведенного анализа отметим ключевые моменты:

- сценарий применения услуг телеприсутствия влияет на выбор архитектуры FL-метода (для сетей с ярко выраженной региональной гетерогенностью данных QoS предпочтительна иерархическая архитектура MultiFed, так как позволяет сократить коммуникационные задержки и количество раундов обучения [4, 6];

- конгруэнтное FL, способное к автоматизации процесса обучения без необходимости применения тонкой настройки гиперпараметров, может идеально подойти для поддержки параметров QoS в динамически меняющихся условиях сети 6G [1];

- гибридные федеративно-распределенные архитектуры FL для оптимизации QoS эффективны при ограниченности ресурсов и открывают возможности для использования сложных трансформерных моделей на периферийных устройствах, что ранее было невозможно [2];

- персонализированный FL позволяет эффективно адаптировать модели к индивидуальным особенностям сетевого окружения каждого пользователя, что

подтверждается экспериментами для сценариев с высокой гетерогенностью [1, 6, 7].

Однако, несмотря на перспективы использования FL-методов, в ходе анализа были выявлены ряд ограничений, которые необходимо учесть при практическом внедрении:

- риски, связанные с безопасностью агрегации из-за уязвимости FL-систем для «атак отравления»;
- значительная вычислительная нагрузка на устройства в стандартных FL-алгоритмах;
- неравномерное распределение устройств в совокупности с использованием каналов связи, не удовлетворяющих требованиям к надежности передачи данных;
- зависимость от качества и стабильности обратной связи.

Перспективными направлениями дальнейших исследований в части применения FL-методов, по мнению авторов, являются интеграция со стандартами 6G и разработка протокольных решений для встраивания FL в архитектуру Network Data Analytics Function (NWDAF) сетей 5G/6G, адаптация FL-алгоритмов для работы в строгих временных рамках услуг телеприсутствия (задержки до 10 мс) с использованием асинхронных методов и прогнозирования градиентов для реального времени, разработка новых методов верификации обновлений алгоритмов и обнаружения аномалий в FL-процессе для закрепления навыков устойчивости к атакам, создание методов гетерогенной федерации, на основе данных о QoS из сетей разных операторов для улучшения глобальных моделей, оптимизация вычислительной нагрузки FL-моделей для устройств с питанием от батарей за счет прунинга, квантизации и выборочного обучения для повышения энергоэффективности.

Литература

1. Taghia J., Moradi F., Larsson H., Lan X., Orucu A., Ebrahimi M., et al. Congruent Learning for Self-Regulated Federated Learning in 6G // IEEE Transactions on Machine Learning in Communications and Networking. 2024. Vol. 2. PP. 29–149. DOI: 10.1109/TMLCN.2023.3347680. EDN: VARJVJ
2. Temiz F., Salehi S., Erol-Kantarci M. Edge Learning via Federated Split Decision Transformers for Metaverse Resource Allocation // arXiv.org. 2026. URL: <https://ar5iv.labs.arxiv.org/html/2602.16174> (Accessed 30.08.2026)
3. 3GPP TS 22.261 version 18.6.1. 3rd Generation Partnership Project. Technical Specification Group Services and System Aspects. Service requirements for the 5G system. Stage 1 (Release 18).
4. Кучерявый А. Е., Давуд А. А., Волков А. Н., Мутханна А. С. А., Пармонов А. И., Елагин В. С. и др. Сети связи шестого поколения: фрактальные архитектуры, голографические взаимодействия, телеприсутствие, сетевые роботы: учебник для вузов. СПб., Москва, Минск: Питер, 2024. 320 с.

5. Al-Quraan M., Mohjazi L., Bariah L., Centeno A., Zoha A., Arshad K., et al. Edge-Native Intelligence for 6G Communications Driven by Federated Learning: A Survey of Trends and Challenges // IEEE Transactions on Emerging Topics in Computational Intelligence. 2023. Vol. 7. Iss. 3. PP. 957–979. DOI:10.1109/TETCI.2023.3251404
6. Xu J., Lin J., Li Y., Xu Z. MultiFed: A fast converging federated learning framework for services QoS prediction via cloud–edge collaboration mechanism // Knowledge-Based Systems. 2023. Vol. 268. P. 110463. DOI: 10.1016/j.knosys.2023.110463. DOI: 10.1016/j.knosys.2023.110463. EDN: ORNKNM
7. Setayesh M. Machine learning-based algorithms design for network slicing, federated learning, and 360° video streaming in wireless systems. PhD Thesis. Vancouver: University of British Columbia, 2024. DOI: 10.14288/1.0441439
8. Bragato F., Giordani M., Zorzi M. Federated Reinforcement Learning to Optimize Teleoperated Driving Networks. 2024. DOI: 10.48550/arXiv. 2410.02312
9. Ossongo E., Esseghir M., Merghem-Boulahia L. A multi-agent federated reinforcement learning-based optimization of quality of service in various LoRa network slices // Computer Communications. 2024. Vol. 213. PP. 320–330. DOI: 10.1016/j.comcom.2023.11.015. EDN: OQGADB
10. Song X., Xu B., Zhang X., Wang S., Song T., Xing G., et al. Everyone-Centric Heterogeneous Multi-Server Computation Offloading in ITS with Pervasive AI // IEEE Network. 2023. Vol. 37. Iss. 2. PP. 62–68. DOI: 10.1109/MNET.2023.10061628. EDN: QWJYJN
11. Li T., Sahu A. K., Zaheer M., Sanjabi M., 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

Статья поступила 27 мая 2026 г.
Одобрена после рецензирования 11 июля 2026 г.
Принята к публикации 30 августа 2026 г.

Информация об авторах

Лаптева Татьяна Владимировна – аспирант кафедры сетей связи и передачи данных Санкт-Петербургского государственного университета телекоммуникаций им. проф. М. А. Бонч-Бруевича. E-mail: lapteva.tv@sut.ru

Муханна Аммар Салех Али – доктор технических наук, профессор кафедры сетей связи и передачи данных Санкт-Петербургского государственного университета телекоммуникаций им. проф. М. А. Бонч-Бруевича.
E-mail: muthanna.asa@sut.ru

<https://doi.org/10.31854/2307-1303-2026-14-2-25-36>
EDN: LPRJVF

Federated Learning as a Method for Optimizing Service Quality in Heterogeneous Telepresence Networks

 T. Lapteva ,  A. Muthanna

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

Abstract. Telepresence is a key service in sixth-generation networks, placing stringent quality of service requirements on them. Current and future communications infrastructures are characterized by a high degree of heterogeneity. Ensuring a stable level of quality of service is therefore a complex task requiring an integrated approach and innovative solutions. Traditional management methods, such as static prioritization or adaptive algorithms, lack sufficient flexibility, while centralized machine learning approaches are associated with privacy risks and high network load. **The aim of this paper** is to systematize and comparatively analyze federated learning methods used to predict and optimize quality of service in heterogeneous telepresence networks. **The essence of the approach proposed** in this paper lies in the author's classification of federated learning methods based on two criteria: architectural organization and the method of adaptation to heterogeneity. Detailed descriptions are provided for each class, and strengths and weaknesses are highlighted. The comparative analysis is based on comparing approaches based on key metrics: forecast accuracy, convergence rate, communication delays, privacy, device computational load, heterogeneity resilience, implementation complexity, and security. The analysis was based on data from peer-reviewed sources, which allowed us to identify quantitative advantages (e.g., a 1.91–38.89% reduction in training rounds and a 9.52–40.00% reduction in communication delays for the hierarchical MultiFed architecture). **Experimental data** presented in the analyzed papers confirm that federated learning provides a balance between predictive accuracy, privacy, and scalability, with the gains being most noticeable for devices with heterogeneous data. **The scientific novelty** lies in the proposed classification of federated learning methods and the systematization of their advantages and limitations as applied to the specifics of telepresence networks, which enables an informed choice of architecture depending on the use case. The authors' **practical significance** lies in their recommendations for selecting a federated learning method for various conditions (regional heterogeneity, limited device resources, and stringent latency requirements), which can be used in the design and operation of communication networks.

Key words: federated learning, distributed learning, telepresence, QoS, heterogeneous networks, 6G, latency optimization, QoS prediction

References

1. Taghia J., Moradi F., Larsson H., Lan X., Orucu A., Ebrahimi M., et al. Congruent Learning for Self-Regulated Federated Learning in 6G // IEEE Transactions on Machine Learning in Communications and Networking. 2024. Vol. 2. PP. 29–149. DOI: 10.1109/TMLCN.2023.3347680. EDN: VARJVJ
2. Temiz F., Salehi S., Erol-Kantarci M. Edge Learning via Federated Split Decision Transformers for Metaverse Resource Allocation // arXiv.org. 2026. URL: <https://ar5iv.labs.arxiv.org/html/2602.16174> [Accessed 30.08.2026]
3. 3GPP TS 22.261 version 18.6.1. 3rd Generation Partnership Project. Technical Specification Group Services and System Aspects. Service requirements for the 5G system. Stage 1 (Release 18).

4. Kucheryavy A. E., Davud 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; Moscow; Minsk: Piter Publ.; 2024. 320 p. (in Russian)
5. Al-Quraan M., Mohjazi L., Bariah L., Centeno A., Zoha A., Arshad K., et al. Edge-Native Intelligence for 6G Communications Driven by Federated Learning: A Survey of Trends and Challenges // IEEE Transactions on Emerging Topics in Computational Intelligence. 2023. Vol. 7. Iss. 3. PP. 957–979. DOI:10.1109/TETCI.2023.3251404
6. Xu J., Lin J., Li Y., Xu Z. MultiFed: A fast converging federated learning framework for services QoS prediction via cloud–edge collaboration mechanism // Knowledge-Based Systems. 2023. Vol. 268. P. 110463. DOI: 10.1016/j.knosys.2023.110463. EDN: ORNKNM
7. Setayesh M. Machine learning-based algorithms design for network slicing, federated learning, and 360° video streaming in wireless systems. PhD Thesis. Vancouver: University of British Columbia, 2024. DOI: 10.14288/1.0441439
8. Bragato F., Giordani M., Zorzi M. Federated Reinforcement Learning to Optimize Teleoperated Driving Networks. 2024. DOI: 10.48550/arXiv.2410.02312
9. Ossongo E., Esseghir M., Merghem-Boulahia L. A multi-agent federated reinforcement learning-based optimization of quality of service in various LoRa network slices // Computer Communications. 2024. Vol. 213. PP. 320–330. DOI: 10.1016/j.comcom.2023.11.015. EDN: OQGADB
10. Song X., Xu B., Zhang X., Wang S., Song T., Xing G., et al. Everyone-Centric Heterogeneous Multi-Server Computation Offloading in ITS with Pervasive AI // IEEE Network. 2023. Vol. 37. Iss. 2. PP. 62–68. DOI: 10.1109/MNET.2023.10061628. EDN: QWGJYN
11. Li T., Sahu A. K., Zaheer M., Sanjabi M., 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

Information about Authors

Lapteva Tatyana – Postgraduate student at the Department of Communication Networks and Data Transmission (The Bonch-Bruевич Saint Petersburg State University of Telecommunications). E-mail: lapteva.tv@sut.ru

Muthanna Ammar – D. Sc. in Engineering Sciences, Professor at the Department of Communication Networks and Data Transmission (The Bonch-Bruевич Saint Petersburg State University of Telecommunications). E-mail: muthanna.asa@sut.ru