

Научная статья

УДК 004.75

<https://doi.org/10.31854/1813-324X-2026-12-3-81-97>

EDN:AGSSRU



Туманные альянсы: децентрализованная облачная структура с федеративным машинным обучением для городских сетевых вселенных

✉ Данг Ван Тханг, dang.vt@sut.ru

✉ Артём Николаевич Волков, artem.nv@sut.ru

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

Аннотация

Актуальность. В последние годы интеллектуальные транспортные системы играют важную роль в управлении городом и снижении транспортных рисков, став одной из инфраструктурных технологий для будущих городских сетевых вселенных. Одной из ключевых задач является повышение эффективности систем в части точного прогнозирования транспортного трафика в реальном времени. Традиционные централизованные модели глубокого обучения страдают от задержек в сети и уязвимости центрального сервера как по безопасности, так и по вычислительной нагрузке.

Целью работы является разработка децентрализованной облачной структуры на основе динамических туманных вычислений и федеративного машинного обучения для прогнозирования трафика в ИТС, устраняющей зависимость от центрального сервера и обеспечивающей отказоустойчивость системы. В интересах достижения цели исследования в работе используются **методы** анализа существующих публикаций в предметной области, математического моделирования и программного моделирования (верификация модели на реальных данных) для оценки результатов. Предлагаемая облачная структура объединяет три технологии: децентрализованное федеративное обучение, туманные вычисления и адаптивные графовые сверточные рекуррентные сети.

Результат. Предложенная структура эффективно работает без центрального сервера. На наборах ReMSD4 и ReMSD7(M) потребность в сетевых ресурсах снижена на 48 % по сравнению с традиционными методами FL, скорость сходимости выше на 17,8 %, точность прогноза сопоставима с моделями, использующими центральный сервер. Предложена **новая** децентрализованная архитектура, полностью исключая центральный сервер при сохранении баланса между точностью, эффективностью и потреблением сетевых ресурсов.

Теоретическая значимость. Подтверждена обоснованность интеграции динамических туманных вычислений с децентрализованным федеративным обучением. Применение AGCRN на уровне туманных узлов обеспечивает точное моделирование пространственно-временных зависимостей без передачи сырых данных и без участия центрального сервера.

Практическая значимость. Результаты экспериментов подтверждают применимость решения в масштабных ИТС умных городов, особенно при ограниченной пропускной способности сети, разрывах соединения с облаком и перегрузке центрального сервера.

Ключевые слова: прогнозирование транспортных потоков, децентрализованное федеративное обучение, туманные вычисления, AGCRN, транспортные системы


Ссылка для цитирования: Тханг Д.В., Волков А.Н. Туманные альянсы: децентрализованная облачная структура с федеративным машинным обучением для городских сетевых вселенных // Труды учебных заведений связи. 2026. Т. 12. № 3. С. 81–97. DOI:10.31854/1813-324X-2026-12-3-81-97. EDN:AGSSRU

Original research

<https://doi.org/10.31854/1813-324X-2026-12-3-81-97>

EDN:AGSSRU

Fog Alliances: A Decentralized Cloud Structure with Federated Machine Learning for Citiverses

 Dang V. Thang✉, dang.vt@sut.ru Artem N. Volkov, artem.nv@sut.ru

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

Annotation

Relevance. In recent years, Intelligent Transportation Systems (ITS) have played a pivotal role in urban management and the reduction of transportation risks, having become a key infrastructure technology for future urban network universes (Citiverse). A key challenge is enhancing system efficiency through accurate, real-time traffic prediction. Traditional centralized deep learning models suffer from network propagation delays and vulnerability of the central server in terms of both security and computational overload.

Objective. To develop a decentralized cloud framework based on dynamic fog computing and federated machine learning for traffic prediction in ITS, eliminating dependency on a central server and ensuring system fault tolerance through the proposed architecture.

Methods. The study employs literature analysis in the subject area, mathematical modeling, and computational experiments for performance evaluation. The proposed cloud framework integrates three technologies: Decentralized Federated Learning, Fog Computing, and Adaptive Graph Convolutional Recurrent Networks.

Results. The proposed framework operates effectively without a central server. Experiments on the real-world datasets PeMSD4 and PeMSD7(M) show that the model reduces communication overhead by approximately 48% compared to traditional FL methods. Convergence speed is significantly faster (a 17.8% reduction in the loss function during initial training rounds), while prediction accuracy remains at a competitive level compared to models relying on a central server. A **novel decentralized system** architecture is proposed that eliminates the central server while maintaining a balance among prediction accuracy, model efficiency, and network resource consumption.

Theoretical Significance. The study confirms the theoretical validity of integrating dynamic fog computing with decentralized federated learning. Implementing this approach using AGCRN at the fog node level enables accurate modeling of complex spatio-temporal dependencies, while eliminating the need for raw data transmission and central server involvement.

Practical Significance. Experimental results on real-world datasets confirm the feasibility of deploying the proposed solution in large-scale ITS within smart cities. The solution is particularly effective under conditions of limited network bandwidth, connectivity disruptions with the cloud, and overload of the central server.

Keywords: time synchronization, TSN, PTP, gPTP, IIoT, timescale

For citation: Thang D.V., Volkov A.N. Fog Alliances: A Decentralized Cloud Structure with Federated Machine Learning for Citiverses. *Proceedings of Telecommunication Universities*. 2026;12(3):81–97. (in Russ.) DOI:10.31854/1813-324X-2026-12-3-81-97. EDN:AGSSRU

Введение

Стремительное расширение городских агломераций и усложнение транспортной инфраструктуры ставят перед муниципальным управлением принципиально новые задачи. Одним из ключевых направлений их решения стало создание интеллектуальных транспортных систем (ITS, аббр. от

англ. Intelligent Transportation Systems) – технологической основы концепции умного города [1] и ее перспективного развития в форме городских сетевых вселенных (от англ. CitiVerse) [2]. Именно системы управления дорожным движением обеспечивают в этой структуре согласованное функционирование городских ресурсов.

Задача анализа и прогнозирования транспортных потоков в условиях реального города отличается высокой вычислительной сложностью: она предполагает обработку непрерывных потоков данных и выявление многомерных пространственно-временных зависимостей. В современных исследованиях для захвата пространственных закономерностей широко применяются графовые нейронные сети (GNN, *аббр. от англ.* Graph Neural Networks), тогда как для описания временной динамики традиционно используются рекуррентные (RNN, *аббр. от англ.* Recurrent Neural Networks) и сверточные (CNN, *аббр. от англ.* Convolutional Neural Networks) нейронные сети [3]. Эти методы эффективно моделируют пространственно-временные связи и показывают хорошие результаты в задачах прогнозирования. Однако остаются вопросы, связанные с объемом необходимых вычислительных ресурсов, удобством развертывания системы и общей ее эффективностью. В реальных условиях оценка модели машинного обучения требует баланса между точностью прогноза, объемом необходимых ресурсов на обработку данных, передачу данных и другими факторами.

Большинство современных моделей глубокого машинного обучения используют централизованные архитектуры в облачной среде. Такие решения требуют передачи данных в облако, что значительно увеличивает сетевой трафик и эксплуатационные расходы системы. Более того, переход к сетям 6G/IMT-2030 предъявляет более строгие требования к услугам класса сверхнадежных сетей связи с ультрамалыми задержками. Эти характеристики необходимы для поддержки новых сервисов, таких как телеприсутствие и голографическая связь, а также для формирования новой среды – мультивселенной (группы подключенных сетевых вселенных). Как отмечалось выше, традиционные централизованные модели облачных вычислений не способны в полной мере удовлетворить эти требования [4].

Туманные вычисления и федеративное обучение (FL, *аббр. от англ.* Federated Learning) стали ключевыми подходами к решению этих проблем. Туманные вычисления переносят обработку данных ближе к их источникам на периферии сети, снижая затраты на передачу и уменьшая задержки связи. В сочетании с этим FL повышает точность модели с каждым раундом обучения, при этом данные не передаются в облако, что обеспечивает конфиденциальность данных и снижает сетевую нагрузку. В последних исследованиях в области FL представлен ряд методов, использующих пространственно-временные характеристики транспортных потоков, среди которых выделяются работы FedAGCN [5], FedSTN [6], T-GCN [7], FASTGNN [8], FCGCN [9]. Результаты этих работ подтверждают эффективность этих методов на реальных данных. Однако боль-

шинство подобных моделей построены на основе традиционной централизованной облачной архитектуры, в которой сервер остается центральным узлом агрегации, накопления данных, обучения и распределения модели. Что создает высокую нагрузку на каналы связи и ресурсы сервера, повышает риски безопасности и снижает устойчивость к сбоям [10, 11]. Кроме того, централизованное обучение модели не учитывает региональные особенности трафика, которые сильно различаются в разных географических зонах.

Для преодоления этих вызовов в данной статье предлагается структура DFL-FC-AGCRN – децентрализованный подход к прогнозированию трафика без использования центрального сервера. Метод объединяет три технологии: 1) децентрализованное FL для распределенного обучения; 2) туманные вычисления для переноса расчетов к источникам данных и снижения зависимости от центрального облака; 3) адаптивная рекуррентная графовая сверточная нейронная сеть (AGCRN, *аббр. от англ.* Adaptive Graph Convolutional Recurrent Network) для описания сложных пространственно-временных зависимостей [12].

Предлагаемая архитектура является иерархически децентрализованной: единый облачный сервер полностью исключается, а координация выполняется через узлы AFN, образующие промежуточный уровень между датчиками и облаком.

В статье представлены следующие основные результаты работы:

- разработана децентрализованная структура DFL-FC-AGCRN для прогнозирования трафика, исключая зависимость от центрального сервера;
- разработан механизм отдельной агрегации параметров, обеспечивающий баланс между глобальными знаниями (общие параметры модели) и локальной адаптацией (индивидуальные векторы встраивания узлов);
- предложен метод кластеризации для оптимизации размещения туманных узлов на основе плотности пространственного распределения датчиков трафика;
- произведена комплексная оценка точности прогноза и используемых сетевых ресурсов.

Обзор работ

Методы глубокого обучения, такие как CNN, RNN и GNN, были представлены в работах [13], [14]. Результаты обучения на реальных наборах данных показали, что применение этих методов к задачам с транспортными данными обеспечивает достаточно высокую точность. В другой работе [12] авторы представили и доказали высокую эффективность модели AGCRN в задаче прогнозирования на основе пространственных и временных образцов данных. Тем не менее, перечисленные

модели прогнозирования требуют передачи больших объемов необработанных данных на центральный сервер.

В работах [5, 6, 15] представлены методы, основанные на обучении общей модели без передачи исходных данных: клиенты обмениваются только параметрами (весами) нейронной сети. Этот подход, включающий алгоритмы FedAvg и FedSTN, повышает уровень защиты данных. Однако общим ограничением остается зависимость от традиционной облачной архитектуры, где сервер выполняет функции агрегации и распределения параметров. Данные методы не исключают риски единой точки отказа и потребности в сетевых ресурсах, что может стать «узким местом» в случае повышения количества данных при обмене с центральной моделью ML. Также данный метод недостаточно учитывает специфику локальных данных в разных географических зонах [10, 11]. В некоторых исследованиях рассматривалась децентрализация с помощью блокчейна [15]. Однако это решение существенно увеличивает потребности в вычислительных ресурсах и в итоге затрудняет работу системы FL в реальном времени.

Параллельно развиваются полностью децентрализованные методы FL, не требующие центрального сервера агрегации. Авторы исследования [16] предложили алгоритм D-PSGD, в котором каждый узел обменивается параметрами только с топологически смежными узлами сети, показав, что децентрализованные алгоритмы могут превосходить централизованные по скорости сходимости в условиях ограниченной пропускной способности. В работе [17] предложен подход на основе сегментированного gossip-протокола для FL с использованием блокчейна, позволяющий эффективно использовать пропускную способность между узлами без привлечения центрального сервера агрегации. В статье [18] разработан алгоритм CD-SGD, сочетающий компрессию градиентов и компенсацию задержек для повышения эффективности децентрализованного обучения. Однако перечисленные методы оперируют абстрактными топологиями сети и не учитывают географическую структуру узлов. Кроме того, они не включают специализированных архитектур для пространственно-временного моделирования транспортных потоков и не решают проблему неоднородности данных (Non-IID), характерную для территориально распределенных датчиков. Предлагаемый подход отличается интеграцией географической кластеризации (HDBSCAN, K-means) с моделью AGCRN на уровне туманных узлов, что обеспечивает адаптацию к реальной топологии транспортной сети и эффективное решение проблемы Non-IID через механизм раздельной агрегации параметров.

Предлагаемая общая структура DFL-FC-AGCRN

Сеть дорожных датчиков состоит из измерительных станций, размещенных по всей исследуемой территории. Каждая станция рассматривается как вершина, которая собирает данные о трафике в реальном времени.

Пусть набор станций: $G = \{G_k\}_{k=1}^K$ где K – число измерительных станций трафика.

Тогда каждая станция G_k формирует данные временного ряда:

$$D_k = \{(X_k, y_k)\},$$

где X_k – входная последовательность признаков на станции k :

$$X_k = \{x_k^t\}_{t=1}^T \in \mathbb{R}^{T \times d};$$

T – число временных шагов; d – число признаков; y_k – соответствующий объем трафика на станции k :

$$y_k = \{y_k^t\}_{t=1}^T \in \mathbb{R}^T.$$

Важная особенность данных о трафике – высокая неоднородность (non-IID) между измерительными станциями. Это связано с различиями в состоянии дорог, плотности транспорта и шаблонах движения в разных районах. По этой причине наборы данных будут иметь существенные различия, что и является серьезным вызовом при применении моделей распределенного обучения. Общая концепция предлагаемой архитектуры DFL-FC-AGCRN, включающей измерительные станции, туманные узлы, альянсы и механизм децентрализованной агрегации, представлена на рисунке 1.

Кластеризация датчиков с помощью HDBSCAN

По сути, иерархическая пространственно-плотностная кластеризация на основе плотности с учетом шума (HDBSCAN, аббр. от англ. Hierarchical Density-Based Spatial Clustering of Applications with Noise) является алгоритмом кластеризации без учителя. Алгоритм использует несколько масштабов расстояния, что позволяет отделять плотные кластеры от разреженных областей, интерпретируемых как шум. Стоит отметить, что этот метод сильно зависит от самих данных и требует меньше параметров, задаваемых пользователем. По вычислительной сложности алгоритм сопоставим с DBSCAN, но часто превосходит K-means и другие методы при кластеризации крупномасштабных данных [19]. Таким образом, в проводимом исследовании был выбран HDBSCAN как метод для кластеризации сложных сетей датчиков трафика.

Процедура HDBSCAN включает определенные шаги.

Шаг 1. Вычисление попарной матрицы расстояний между станциями по формуле гаверсина (1), где R – радиус Земли (≈ 6371 км); ϕ_1, ϕ_2 и λ_1, λ_2 – широта и долгота двух точек (в радианах).



Рис. 1. Концептуальная схема архитектуры DFL-FC-AGCRN в умном городе
 Fig. 1. Simulation Diagram of the DFL-FC-AGCRN Framework Architecture in a Smart City

$$d = 2R \arcsin \left(\sqrt{\sin^2 \left(\frac{\phi_2 - \phi_1}{2} \right) + \cos(\phi_1) \cos(\phi_2) \sin^2 \left(\frac{\lambda_2 - \lambda_1}{2} \right)} \right). \tag{1}$$

Шаг 2. Построение минимального остовного дерева (MST, аббр. от англ. Minimum Spanning Tree) на основе матрицы расстояний. Каждая вершина графа соответствует измерительной станции, а вес каждого ребра определяется гаверсиновым расстоянием между соответствующими станциями. MST соединяет все точки с минимальной суммарной длиной ребер и служит основой для построения иерархии.

Шаг 3. Построение иерархии кластеров с использованием расстояния взаимной достижимости. Начиная с минимального остовного дерева MST, алгоритм модифицирует ребра с учетом плотности и формирует «сжатое» дерево кластеров. Каждое горизонтальное сечение дерева соответствует определенному значению ε и задает кластеры на соответствующем уровне плотности.

Шаг 4. Выделение устойчивых кластеров путем отсекаания иерархии на оптимальном уровне. HDBSCAN просматривает дерево и ищет наиболее «устойчивые» подкластеры по критерию стабильности (например, избыток массы или кластерная стойкость). На выходе алгоритм дает набор

наиболее стабильных кластеров и помечает точки, не входящие ни в один кластер, как шум.

Для алгоритма HDBSCAN не требуется заранее задавать число кластеров. Он автоматически находит оптимальное разбиение на основе структуры данных. Это особенно важно для сценария кластеризации измерительных станций трафика, где оптимальное число кластеров заранее неизвестно и зависит от пространственного размещения станций. Параметры алгоритма HDBSCAN, использованные в настоящем исследовании, приведены в таблице 1.

ТАБЛИЦА 1. Параметры HDBSCAN
 TABLE 1. HDBSCAN Parameters

Имя	Определение	Диапазон	Примечание
Минимальный размер кластера, mcs	Минимум точек в кластере	[2, 20]	Влияет на число кластеров и долю шума
Коэффициент ядра, α	Фактор для min_samples	[0.5, 0.7]	Настраивает «жесткость» плотности
Минимум core-точек, mins	mins = [α · mcs]	-	Чем больше mins, тем плотнее кластеры

Размещение туманных узлов

После кластеризации центр каждого кластера C_n вычисляется как среднее значение координат:

$$\bar{\phi} = \frac{1}{|C|} \sum_{i \in C} \phi_i, \quad \bar{\lambda} = \frac{1}{|C|} \sum_{i \in C} \lambda_i. \quad (2)$$

Туманный узел F_n размещается на станции, которая находится ближе всего к центру кластера. Это обеспечивает выгодное положение для сбора и обработки данных от всех станций в кластере. Размещение туманного узла в центре минимизирует среднее расстояние до станций, снижает задержку распространения и экономит энергию узлов.

В исследовании для верификации разработанной структуры и метода были использованы два реальных набора данных: PeMSD4 с 207 датчиками трафика и PeMSD7(M) с 228 датчиками [20]. Данные содержат измерения трафика в реальном времени и географические координаты датчиков.

AGCRN на каждом туманном узле

Предложенная в [12] AGCRN является продвинутой архитектурой модели машинного глубокого обучения для прогноза транспортных потоков. Она устраняет два основных недостатка прежних методов: во-первых, использование только глобально разделяемых параметров, которые не отражают индивидуальные паттерны узлов; во-вторых, зависимость от заранее заданного графа для моделирования пространственных связей.

Для каждого туманного узла F_n строится локальный граф $G_n = (V_n, E_n)$. $V_n = \{s_i \mid s_i \in C_n\}$ – множество вершин, где каждая вершина соответствует измерительной станции (датчику), входящей в кластер C_n ; общее число станций в кластере равно $|V_n|$. E_n – множество ребер, отражающих пространственные связи между станциями.

Построенный таким образом локальный граф отражает топологическую структуру транспортной сети в пределах кластера C_n , предоставляя модели возможность учитывать пространственные зависимости между станциями-соседями. Принципиально важно разграничить роли элементов графа: вершины V_n соответствуют измерительным станциям (датчикам), тогда как туманные узлы в граф не включаются – каждый туманный узел F_n выступает координатором процесса обучения на графе G_n своего кластера. Модель AGCRN интегрирует два специализированных модуля в архитектуру RNN, что позволяет совместно моделировать пространственные и временные зависимости в данных о транспортном потоке с высокой степенью детализации.

1) Адаптивное обучение параметров узлов графа (NAPL, от англ. Node-Adaptive Parameter Learning), где каждый узел соответствует измерительной станции.

Модуль NAPL формирует индивидуальные параметры для каждого узла, благодаря чему модель способна обучаться специфическим паттернам временных рядов, а не только общим закономерностям:

$$\Theta = E_G \cdot W_G, \quad (3)$$

где $E_G \in \mathbb{R}^{N \times d}$ – матрица встраиваний узлов графа, в которой каждая строка является обучаемым вектором признаков для соответствующей измерительной станции; d – размерность встраивания; $W_G \in \mathbb{R}^{d \times C \times F}$ – общий пул весов, содержащий обучаемые матрицы весов слоев GCN и GRU, которые являются общими для всех вершин графа; каждая станция i извлекает из этого пула свой индивидуальный набор параметров на основе своего вектора встраивания; для станции i модуль NAPL извлекает параметры θ_i из пула весов на основе вектора встраивания E_i^G .

Графовая сверточная сеть с расширением NAPL формально определяется следующим образом:

$$Z = \left(I_N + D^{-\frac{1}{2}} A D^{-\frac{1}{2}} \right) X E_G W_G + E_G b_G, \quad (4)$$

где A и D – матрица смежности и диагональная матрица степеней соответственно.

2) Генерация адаптивных графов по данным (DAGG, аббр. от англ. Data-Adaptive Graph Generation).

Модуль DAGG автоматически обучает матрицу смежности по данным, а не использует заранее заданный граф:

$$\tilde{A} = \text{Softmax}(\text{ReLU}(E_A \cdot E_A^T)), \quad (5)$$

где $E_A \in \mathbb{R}^{N \times d_e}$ – обучаемая матрица встраиваний узлов графа, в которой каждая строка представляет вектор признаков соответствующей станции для генерации графа; Softmax – нормализует матрицу связей; ReLU – обнуляет отрицательные значения.

3) Интеграция NAPL, DAGG and GRU

AGCRN объединяет оба модуля с GRU и одновременно моделирует пространственные и временные зависимости:

$$A_e = \text{softmax}(\text{ReLU}(E E^T)), \quad (6)$$

$$z_t = \sigma(A_e[X_{:,t}, h_{t-1}] E W_z + E b_z), \quad (7)$$

$$r_t = \sigma(A_e[X_{:,t}, h_{t-1}] E W_r + E b_r), \quad (8)$$

$$\hat{h}_t = \tanh(A_e[X_{:,t}, r \odot h_{t-1}] E W_{\hat{h}} + E b_{\hat{h}}), \quad (9)$$

$$h_t = z \odot h_{t-1} + (1 - z) \odot \hat{h}_t. \quad (10)$$

где E – единая матрица встраиваний узлов графа, используемая и в NAPL, и в DAGG: матрица встраиваний – это матрица, в которой каждому объекту ставится в соответствие числовой вектор признаков (встраивание); эти векторы обучаются моделью и представляют объекты в непрерывном векторном пространстве; $W_z, W_r, W_{\hat{h}}, b_z, b_r, b_{\hat{h}}$ – обучаемые параметры; \odot – поэлементное умножение (произведение Адамара).

Благодаря своей структуре AGCRN через модуль NAPL захватывает индивидуальные паттерны узлов, а через модуль DAGG автоматически учит пространственные связи между временными рядами, не требуя заранее заданного графа. В работе [12] показана высокая эффективность AGCRN в задачах прогноза трафика. Это демонстрирует, что AGCRN особенно хорошо подходит для задач прогноза транспортных потоков с неоднородными данными, когда временные ряды из различных источников имеют разные паттерны. Поэтому в данном исследовании модель AGCRN используется как локальная модель обучения на туманных узлах.

В предлагаемой модели туманные узлы разделяются по принципу исполняемых функций:

- обучаемые туманные узлы (TFN, аббр. от англ. Trainable Fog Node) обучают модели на данных от измерительных станций;

- агрегационные туманные узлы (AFN, аббр. от англ. Aggregation Fog Node) выполняют роль узлов-агрегаторов.

Каждый TFN F_n обучает модель AGCRN на локальном наборе данных. Функция потерь для обучения модели имеет следующий вид:

$$L(\theta_n) = \frac{1}{|D_n|} \sum_{(X,y) \in D_n} \|f_{\theta_n}(X) - y\|_2^2, \quad (11)$$

где θ_n – параметры модели AGCRN на туманном узле F_n ; f_{θ_n} – прогнозная функция модели; $\|\cdot\|_2^2$ – квадрат L2-нормы.

Параметры обновляются по градиентному спуску: $\theta_n \leftarrow \theta_n - \eta \nabla_{\theta_n} L(\theta_n)$, где η – шаг обучения.

Процесс обучения модели выполняется независимо на каждом туманном узле. TFN узлы собирают, обрабатывают и обучаются на данных станций внутри своего кластера. Это одновременно защищает приватность данных и уменьшает вычислительную нагрузку на каждый узел.

Формирование альянсов туманных узлов

После кластеризации датчиков с помощью HDBSCAN каждая полученная группа представляется соответствующим туманным узлом, размещенным в меоиде. Цель на этом этапе – организовать туманные узлы в альянсы для поддержки децентрализованного FL. Такая группировка снижает сетевую нагрузку, повышает стабильность системы, сохраняет приватность данных и уменьшает задержку, что соответствует требованиям распределенного интернета вещей [21]. Альянс – это группа туманных узлов, объединенных по географической близости, которые совместно выполняют децентрализованную агрегацию параметров модели в рамках FL. Каждый альянс функционирует автономно и координируется через узел агрегации (AFN).

Теоретической основой служит иерархическая модель FL, в которой туманные узлы объединяются в альянсы и образуют промежуточный слой между локальными датчиками и глобальным облаком. Недавние работы показывают, что такие иерархии позволяют более эффективно использовать сетевые ресурсы: модели сначала агрегируются на промежуточных узлах, а не передаются напрямую в облако. В отличие от слоя датчиков, где неравномерная плотность их распределения в пространстве и неизвестное число кластеров требуют применения методов кластеризации на основе плотности (таких как HDBSCAN), способных работать с шумом и кластерами сложной формы, слой туманных узлов уже «сглажен» и представлен более стабильными географическими репрезентативными точками. Для упрощения предлагается использовать K-means для кластеризации туманных узлов. Этот метод позволяет задать фиксированное число кластеров, минимизирует внутрикластерную дисперсию и легко поддерживает дополнительные ограничения, важные для практической реализации [22].

Число альянсов k определяется задачей развертывания. В данном исследовании рассматриваются значения $k \in \{1, 3, 6\}$, охватывающие диапазон от крупных альянсов с большим числом узлов ($k = 1$) до компактных – с малым числом узлов ($k = 6$).

Для корректной работы алгоритма K-means с географическими данными координаты туманных узлов (широта φ , долгота λ) преобразуются в локальную метрическую систему с помощью равнопромежуточной проекции относительно средней точки $(\bar{\varphi}, \bar{\lambda})$:

$$x_i = R \cdot (\lambda_i - \bar{\lambda}) \cdot \cos \bar{\varphi}, \quad y_i = R \cdot (\varphi_i - \bar{\varphi}), \quad (12)$$

Данная проекция ограничивает искажения на малых и средних широтах и подходит для локальных областей. Матрица попарных расстояний D_{fog} (вычисленная по формуле гаверсинуса) затем используется для оценки внутрикоалиционного радиуса и выбора AFN, обеспечивая географическую точность, а не только евклидову близость.

Ограничения на размер и обработка исключений

Стандартный K-means может создавать несбалансированные или одиночные кластеры, особенно при разреженных географических данных. Это проблематично для децентрализованного FL, так как очень малые альянсы не могут эффективно агрегировать модели. Чтобы снизить этот риск, введем ограничение на минимальный размер ($min_size = 2$ узла на альянс). Такое требование гарантирует, что в каждом альянсе как минимум два участника; это поддерживает внутрисоюзную агрегацию FedAvg, повышает устойчивость и уменьшает влияние шума от данных одного узла [23].

Дополнительно для контроля показателей качества обслуживания (QoS, аббр. от англ. Quality of Service) предлагается последующая проверка радиуса внутри альянса (расстояние от AFN до самого удаленного участника). Если этот радиус превышает порог R_{ma} , система помечает нарушение для последующей корректировки k или переразбиения альянсов, что соответствует ресурсно-ориентированным моделям в туманном узле.

Выбор AFN через минимаксный центр альянса

Внутри каждого альянса мы выбираем два ключевых узла: i – основной AFN, определяемый как минимаксный центр альянса в географическом пространстве; ii – резервный AFN, определяемый как следующий по критерию минимаксного центра.

Формально,

$$\text{Primary AFN}(A) = \operatorname{argmin}_{j \in A} \max_{i \in A} D_{fog}(i, j), \quad (13)$$

$$\begin{aligned} \text{Backup AFN}(A) = \\ = \operatorname{argmin}_{j \in A \setminus \{\text{Primary AFN}\}} \max_{i \in A} D_{fog}(i, j). \end{aligned} \quad (14)$$

Предложенный подход реализует принцип минимакса: выбирается узел, минимизирующий максимальное расстояние до любого участника альянса, тогда как классический метод k -медоидов минимизирует сумму расстояний. Это повышает устойчивость к шуму и географическим выбросам – типичной проблеме распределенных туманных сетей. В отличие от центроида K -means, минимаксный центр всегда соответствует реально существующему туманному узлу, что упрощает развертывание и уменьшает внутриальянсовый радиус, снижая затраты на связь и задержки при агрегации. Помимо этого, механизм резервного AFN повышает отказоустойчивость системы: при отказе основного узла его функции автоматически принимает резервный.

Механизм отказоустойчивости при потере связи с узлом AFN

В данной работе предлагается облегченный алгоритм переключения на резервный узел (построен на принципах отказоустойчивых распределенных систем, аналогичных протоколу [24], но упрощен для среды туманных вычислений малого масштаба). Алгоритм автоматически запускается на узлах-участниках туманных вычислений внутри альянса и обеспечивает непрерывность работы без поддержки глобального облака. Механизм рассчитан на отказ отдельного узла и предполагает связность сети внутри альянса. Сценарий сетевого разделения, требующий механизма кворума, выходит за рамки данной работы и рассматривается как направление дальнейших исследований.

Алгоритм переключения AFN

```

INPUT:
  ALLIANCES, AFN_MAP
  TIMEOUT      # response deadline for the PRIMARY
PROCEDURE RUN_FAILOVER_PROTOCOL(ALLIANCES, AFN_MAP,
TIMEOUT):
  At each node in an alliance A:
    Periodic LOOP:
      PRIMARY, BACKUP ← AFN_MAP[A]
      IF self ≠ PRIMARY:
        send HEARTBEAT to PRIMARY, wait for ACK up to
TIMEOUT
        IF no ACK received:
          send CHECK_PRIMARY to BACKUP
        IF self == PRIMARY:
          reply to all received HEARTBEAT messages with
ACK
        IF self == BACKUP:
          upon receiving CHECK_PRIMARY:
            send a HEARTBEAT to PRIMARY, wait for ACK up
to TIMEOUT
        IF still no ACK:
          # Promote backup → primary
          PRIMARY ← self
          # Select new BACKUP via "next-best minimax"
in A \ {PRIMARY}
          BACKUP ← NEXT_BEST_MINIMAX(A, D_fog, ex-
clude=PRIMARY)
          AFN_MAP[A] ← (PRIMARY, BACKUP)
          broadcast BROADCAST to all nodes in A to
update AFN_MAP

```

В предлагаемых распределенной структуре и методе узлы AFN не обучают модели на данных, а выступают координаторами альянса. В каждом раунде обучения участники выполняют локальные обновления на своих данных и затем отправляют обученные параметры модели в AFN. AFN агрегирует эти параметры (взвешенным усреднением, аналогично FedAvg) и рассылает агрегированную модель всем туманным узлам в альянсе. Поскольку AFN выполняет только агрегацию, его ресурсы не перегружаются.

Агрегированная модель аккумулирует коллективные знания участников альянса, тогда как каждый туманный узел независимо сохраняет локальные параметры – в частности, регион-специфические векторы встраивания. Внутрикоалиционные соединения в предложенной архитектуре намеренно минимизированы: это сокращает задержки по сравнению с централизованными схемами и, одновременно, распределенная региональная структура обеспечивает дополнительную отказоустойчивость. Таким образом, механизм формирования альянсов и выбора AFN образует эффективный уровень децентрализованной координации, при котором достигается точность обучения и рациональное использование ресурсов без привлечения центрального сервера.

Децентрализованная агрегация модели

Параметры модели делятся на два типа:

- глобальные (матрицы весов GCN-GRU W_z, W_r, W и параметры входных / выходных линейных слоев);
- локальные (векторы встраивания узлов E_n для измерительных станций в кластерах).

Как отмечалось в предыдущем разделе, в предлагаемой архитектуре каждый TFN F_n передает свои параметры модели θ_n узлу AFN внутри альянса. Этот процесс должен использовать защищенный протокол, который сохраняет приватность исходных данных. Протокол обмена параметрами может реализовываться с использованием сквозного шифрования, цифровых подписей и механизмов аутентификации, что обеспечивает конфиденциальность и целостность передаваемых параметров (в рамках данной работы не рассматривается этот аспект более подробно).

Узел AFN $F_{agg,i}$ в альянсе B_i получает параметры от туманных узлов и вычисляет агрегированные параметры:

$$\theta_{agg,i} = \frac{1}{|B_i|} \sum_{F_n \in B_i} \theta_n. \quad (15)$$

Однако агрегация выполняется с учетом разделения параметров:

– для глобальных параметров:

$$\theta_{agg,i}^{global} = \frac{1}{|B_i|} \sum_{F_n \in B_i} \theta_n^{global}; \quad (16)$$

– для векторов встраивания узлов: локальные векторы встраивания остаются на туманных узлах, обмен ими между туманными узлами в альянсе не выполняется; такая стратегия обеспечивает обмен общими знаниями (глобальные параметры) между туманными узлами и одновременно сохраняет специфические знания (векторы встраивания узлов) для каждого кластера измерительных станций; это важное нововведение предлагаемого метода, которое позволяет сбалансировать универсальность и локальную адаптацию модели.

Распространение и использование параметров

AFN $F_{agg,i}$ распределяет агрегированные параметры $\theta_{agg,i}$ между всеми туманными узлами альянса B_i . Распределение реализуется посредством однорангового протокола обмена данными: узел AFN адресно передает обновленные параметры каждому TFN внутри коалиции – либо напрямую по протоколу TCP / UDP, либо с применением механизма gossip, при котором каждый узел, получив обновление, ретранслирует его соседним участникам. Подобная схема полностью исключает участие центрального сервера в процессе распределения параметров. Помимо этого, узел AFN сохраняет агрегированные параметры $\theta_n \leftarrow \theta_{agg,i}$ для их последующего использования в собственной локальной модели.

Каждый туманный узел $F_n \in B_i$ обновляет свою модель агрегированными параметрами: $\theta_n \leftarrow \theta_{agg,i}$. Данный механизм обеспечивает включение знаний, накопленных в рамках альянса (посредством

глобальных параметров), в локальную модель каждого узла, сохраняя при этом ее способность адаптироваться к специфике конкретной географической области.

Моделирование и оценка

Верификация предложенной структуры проводится на общедоступных наборах данных PeMSD4 и PeMSD7(M), включающих измерения скорости транспортных потоков с 207 и 228 датчиков соответственно. Сырые данные предварительно обрабатываются перед обучением. Каждый обучающий пример представляет собой последовательность из 12 шагов с интервалом 5 минут, что соответствует одному часу наблюдений.

Модель прогнозирует следующие 12 шагов (на 60 мин. вперед). Для оценки точности краткосрочного и среднесрочного прогноза используются ключевые горизонты 5, 15 и 30 мин. (соответственно 1, 3 и 6 шагов). В данной работе предлагаемое решение сравнивается с двумя базовыми моделями: AGCRN – исходной моделью, обучаемой на одном сервере с полным набором данных (верхняя граница качества прогноза), и FL-AGCRN – федеративным вариантом AGCRN, в котором клиенты координируются через центральный сервер по схеме FedAvg.

Для оценки точности прогноза используются три стандартные метрики: средняя абсолютная ошибка (MAE, аббр. от англ. Mean Absolute Error), корень из среднеквадратичной ошибки (RMSE, аббр. от англ. Root Mean Square Error), симметричная средняя абсолютная процентная ошибка (sMAPE, аббр. от англ. Symmetric Mean Absolute Percentage Error):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (17)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (18)$$

$$sMAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i|)/2}. \quad (19)$$

где y_i – фактическое значение; \hat{y}_i – прогнозное значение; n – число прогнозируемых примеров.

Результаты анализируются и оцениваются для трех ключевых горизонтов: 5, 15 и 30 мин., которые выбраны как контрольные точки в рамках общего 60-минутного окна прогноза (12 шагов по 5 мин.) и соответствуют краткосрочному, среднесрочному и более длительному прогнозу соответственно. Анализ по нескольким горизонтам дает целостное представление о возможностях модели на различных временных масштабах. Для оценки скорости сходимости отслеживается функция потерь после каждого раунда в течение 100 раундов.

Высокая скорость сходимости показывает эффективность обучения модели и существенно влияет на совокупную эффективность при практическом развертывании системы.

Для количественной оценки скорости сходимости используются следующие показатели:

– скорость уменьшения потерь:

$$CR = \frac{L_1 - L_T}{L_1},$$

где L_1, L_T – значения функции потерь в первом и последнем раунде соответственно;

– число раундов до достижения порога:

$$R_{threshold} = \min\{r \mid L_r \leq L_{threshold}\},$$

где $L_{threshold}$ – заданный порог потерь;

– средний наклон сходимости:

$$S_{avg} = \frac{1}{T-1} \sum_{t=1}^{T-1} \frac{L_t - L_{t+1}}{L_t},$$

который измеряет среднюю относительную скорость уменьшения потерь по раундам.

В рамках предложенной структуры общие сетевые ресурсы складываются из трех составляющих: ресурсов для сбора данных, ресурсов децентрализованного FL и внутриальянсовых служебных ресурсов. Ресурсы для сбора данных определяются объемом информации, передаваемой от измери-

тельных станций (датчиков) к обучаемым туманным узлам внутри каждого кластера. Ресурсы децентрализованного FL связаны с обменом параметрами модели между TFN и AFN. Внутриальянсовые служебные ресурсы обеспечивают координацию работы альянса, включая механизм контроля доступности узлов, переключение на резервный AFN и рассылку обновленных параметров участникам альянса. Следует отметить, что ресурсы децентрализованного FL и внутриальянсовые служебные ресурсы не пересекаются: первые отвечают исключительно за обмен параметрами модели в рамках FL, а вторые – за поддержание работоспособности и координацию узлов.

Расчет ресурсов для FL-AGCRN производится по выражению (20), где s_{data} – размер одной записи датчика (байт); r – число записей; $d_{i,client}$ – расстояние от датчика i до клиента; s_{model} – размер модели (байт); $s_{updates}$ – размер обновлений параметров (байт); $n_{clients}$ – число клиентов; R – число раундов обучения; $d_{client,server}$ – расстояние от клиента до сервера.

Расчет ресурсов для DFL-FC-AGCRN производится по выражению (23), где A – число альянсов; n_j – число узлов в альянсе j ; $d_{i,fog}$ – расстояние от датчика i до туманного узла; d_j – среднее расстояние внутри альянса j .

где
$$C_{FL-AGCRN} = C_{sensor} + C_{params}, \quad (20)$$

$$C_{sensor} = \sum_{i=1}^n (s_{data} \cdot r \cdot d_{i,client}), \quad (21)$$

$$C_{params} = (s_{model} \cdot n_{clients} \cdot d_{client,server} + s_{updates} \cdot n_{clients} \cdot d_{client,server}) \cdot R. \quad (22)$$

где
$$C_{DFL-FC-AGCRN} = C_{sensor} + C_{alliance}, \quad (23)$$

$$C_{sensor} = \sum_{i=1}^n (s_{data} \cdot r \cdot d_{i,fog}), \quad (24)$$

$$C_{alliance} = \sum_{j=1}^A (s_{updates} \cdot n_j \cdot d_j + s_{model} \cdot n_j \cdot d_j) \cdot R. \quad (25)$$

Построение топологии сети

В среде туманных вычислений качество прогноза зависит не только от алгоритма обучения, но и от топологии сети. Построение последней состоит из двух шагов.

Шаг 1. Формирование возможных топологий «датчики → туманные узлы» с помощью алгоритма HDBSCAN, основываясь на географических координатах датчиков.

Шаг 2. Анализ влияния числа альянсов туманных узлов на точность и ресурсозатратность модели FL для задачи прогнозирования трафика.

Кластеризация датчиков

Цель первого этапа – подобрать гиперпараметры HDBSCAN так, чтобы преобразовать географически распределенные датчики в слой туманных узлов с компактной топологией. Для этого выполняется перебор по сетке значений параметров HDBSCAN, где входом служит заранее вычисленная матрица геодезических расстояний между датчиками D_{sensor} .

Для практического развертывания важен допустимый радиус связи датчиков. В качестве базовой технологии беспроводного доступа рассматривается Wi-Fi HaLow (IEEE 802.11ah), который поддержи-

вает подключение до 8192 устройств к одной точке доступа и обеспечивает теоретическое покрытие на расстоянии до ≈ 1 км. Согласно модели, предложенной в [25], достижимый радиус связи может составлять около 1,5 км при использовании схемы модуляции и кодирования MCS10. На основе полученного результата в настоящей работе принимается радиус связи датчика, равный 1,5 км. На основе этого порога отбрасываем конфигурации, где макрорадиус превышает предел, и выбираем три представительных варианта (таблица 2).

ТАБЛИЦА 2. Результаты кластеризации датчиков

TABLE 2. Results of Sensor Clustering Optimisation

mcs	mins	alpha	Sil	r_{max} , км	Sensor, %	K
2	1	0,5	0,70	0,31	3,86	79
3	2	0,7	0,52	0,93	10,94	33
5	2	0,5	0,53	1,47	15,77	18

Усл. обозначения: Sil – коэффициент силуэта; r_{max} – максимальный радиус кластера; Sensor – доля нераспределенных датчиков

Чтобы ни один датчик не был отброшен, дополнительно рассматриваем вариант переназначения шума в ближайший кластер по медуиду. В таблице 2 показаны показатели до переназначения, чтобы честно отразить качество HDBSCAN. Большое число туманных узлов приводит к высоким затратам ресурсов на развертывание систем и межальянсовые коммуникации. Для минимизации стоимости при сохранении простоты выбираем конфигурацию с 18 туманными узлами.

Оптимизация формирования альянсов

На втором этапе, опираясь на топологию из 18 туманных узлов, подбираем число альянсов. Требуется учитывать естественную географическую структуру туманных узлов, строго соблюдать ограничение на радиус связи внутри альянса (от AFN до участников). Радиус взаимодействия внутри альянса задается равным 10 км, что соответствует концепции сетей 6G, в рамках которой вычислительные функции и ресурсы распределяются по иерархии от облачного уровня к уровню туманных и периферийных вычислений. При таком подходе альянс туманных узлов, охватывающий территорию протяженностью в десятки километров, рассматривается как единый регион периферийных вычислений с согласованным управлением и

координацией ресурсов. Это согласуется с моделью динамических туманных вычислений, в которой туманные устройства образуют вычислительный кластер с возможностью горизонтального масштабирования, на базе которого могут быть развернуты платформы и услуги.

Рассматриваются значения $k \in \{1, 2, 3, 4, 5, 6\}$, охватывающие диапазон от полностью централизованной агрегации до высокодецентрализованной конфигурации. Следует подчеркнуть, что данный этап относится к инфраструктурному проектированию сети, а не является основным предметом исследования: его цель – зафиксировать топологию развертывания до начала основных экспериментов. Для обеспечения статистической надежности каждая конфигурация запускается 3 раза с различными инициализациями весов модели (seeds: 42, 123, 777) при 10 раундах и 3 локальных эпохах на раунд – итого 18 независимых прогонов. Результаты представлены как среднее \pm стандартное отклонение (выборочное, $n = 3$). Топология альянсов фиксируется через K -means по географическим координатам туманных узлов (seed = 42) и не изменяется между прогонами.

Результаты 18 независимых прогонов выявляют устойчивую U -образную зависимость метрик точности от числа альянсов k : при малых значениях ($k = 1$) высокая неоднородность данных внутри единственного альянса ухудшает агрегацию; при больших ($k \geq 4$) чрезмерная фрагментация вызывает локальное переобучение – функция потерь монотонно снижается ($0,330 \rightarrow 0,238$), тогда как MAE и RMSE на тестовой выборке деградируют. Количественные результаты оценки качества модели, функции потерь и коммуникационных затрат при различных значениях k представлены в таблице 3.

Оптимум достигается при $k \in \{2, 3\}$, где масштаб альянса соответствует естественному транспортному коридору. Стандартное отклонение MAE дополнительно подтверждает нестабильность крайних конфигураций ($k = 1$: $\sigma = 0,549$; $k = 6$: $\sigma = 0,391$) по сравнению со средними ($k = 3$: $\sigma = 0,245$). С учетом точности, устойчивости и коммуникационных затрат конфигурация $k = 3$ обеспечивает наилучший баланс и принимается как оптимальная.

ТАБЛИЦА 3. Оценка при разном числе альянсов

TABLE 3. Performance with Varying Number of Alliances

k	MAE	RMSE	sMAPE	Loss	Коммуникационные затраты, Мб
1	10,428 \pm 0,549	18,192 \pm 0,599	0,158 \pm 0,003	0,330 \pm 0,001	343,28
2	9,814 \pm 0,157	17,342 \pm 0,089	0,153 \pm 0,002	0,313 \pm 0,000	221,40
3	9,869 \pm 0,245	17,477 \pm 0,157	0,151 \pm 0,002	0,292 \pm 0,001	178,61
4	9,958 \pm 0,309	17,693 \pm 0,263	0,154 \pm 0,003	0,262 \pm 0,000	135,20
5	9,969 \pm 0,187	17,713 \pm 0,161	0,152 \pm 0,003	0,262 \pm 0,000	132,67
6	10,170 \pm 0,391	17,997 \pm 0,351	0,154 \pm 0,009	0,238 \pm 0,000	118,59

Сравнительная оценка качества моделей

При радиусе связи $R = 10$ км система содержит 18 туманных узлов, которые обслуживают 207 датчиков и разбиваются на 3 независимых тренировочных альянса. Развертывание системы на датасете PeMSD4 показано на рисунке 2.

Результаты прогноза интенсивности трафика для трех моделей суммированы на рисунке 3. Для горизонтов 5, 15 и 30 мин. после 100 раундов обучения приводятся MAE, RMSE и sMAPE. Централизованная модель достигает наилучшей точности и показывает минимальные значения MAE. Это ожидаемо, так как обучение проводится на полном наборе данных без ограничений. Две другие модели, FL-AGCRN и DFL-FC-AGCRN, демонстрируют более слабые результаты, но сохраняют конкурентоспособную точность.

У всех трех моделей качество прогноза ухудшается при увеличении горизонта прогнозирования, что соответствует общему поведению задач прогнозирования временных рядов. Скорость деградации для DFL-FC-AGCRN сопоставима со скоростью для FL-AGCRN. Это показывает, что характеристики прогноза на больших горизонтах хорошо сохраняются в иерархической децентрализованной архитектуре.

В рамках данного исследования были выбраны 4 случайных датчика внутри сформированных кластеров, где были полученные примеры прогнозов. Результаты прогноза модели DFL-FC-AGCRN на реальном датасете для горизонтов 5, 15 и 30 мин. показаны на рисунке 4. Чтобы дополнительно продемонстрировать эффективность предлагаемой структуры и методы, была оценена скорость сходимости модели, а также необходимые затрачиваемые сетевые ресурсы. Результаты для 10, 20, 50 и 100 раундов обучения суммированы в таблице 4.

Анализ результатов показывает, что предложенная модель демонстрирует не только ускоренную сходимость, но и поддерживает высокую результативность процесса обучения на всем протяжении эксперимента. Для оценки влияния ускоренной

сходимости на объем сетевых взаимодействий были дополнительно рассчитаны коммуникационные затраты, результаты которых представлены в таблице 5. Работоспособность модели при развертывании подтверждается также результатами, представленными на рисунках 5 и 7. Полученные данные однозначно подтверждают практическую применимость и перспективность разработанного подхода.

ТАБЛИЦА 4. Показатели скорости сходимости

TABLE 4. Convergence Rate Indicators

Метрика	FL-AGCRN	DFL-FC-AGCRN	Преимущество DFL-FC-AGCRN, %
Коэффициент снижения потерь после 10 раундов, %	5,79	4,76	17,8
Коэффициент снижения потерь после 20 раундов, %	7,16	6,08	15,1
Коэффициент снижения потерь после 50 раундов, %	8,51	7,45	12,5
Коэффициент снижения потерь после 100 раундов, %	9,26	8,28	10,6
Раунды для достижения потерь 0,325 (FL) / 0,290	18 раундов	13 раундов	27,8
Раунды для достижения потерь 0,320 (FL) / 0,285	43 раунда	33 раунда	23,3

ТАБЛИЦА 5. Влияние скорости сходимости на затраты на связь

TABLE 5. Impact of Convergence Speed on Communication Cost

Метрика	FL-AGCRN	DFL-FC-AGCRN	Экономия, %
Стоимость связи за раунд	34,33 МБ	17,86 МБ	48,0
Затраты до достижения Loss 0,325 (FL) / 0,290 (DFL)	617,94 МБ (18 раундов)	232,18 МБ (13 раундов)	62,4
Затраты до достижения Loss 0,320 (FL) / 0,285 (DFL)	1476,19 МБ (43 раунда)	589,38 МБ (33 раунда)	60,1
Суммарные затраты за 100 раундов	3433,00 МБ	1786,10 МБ	48,0

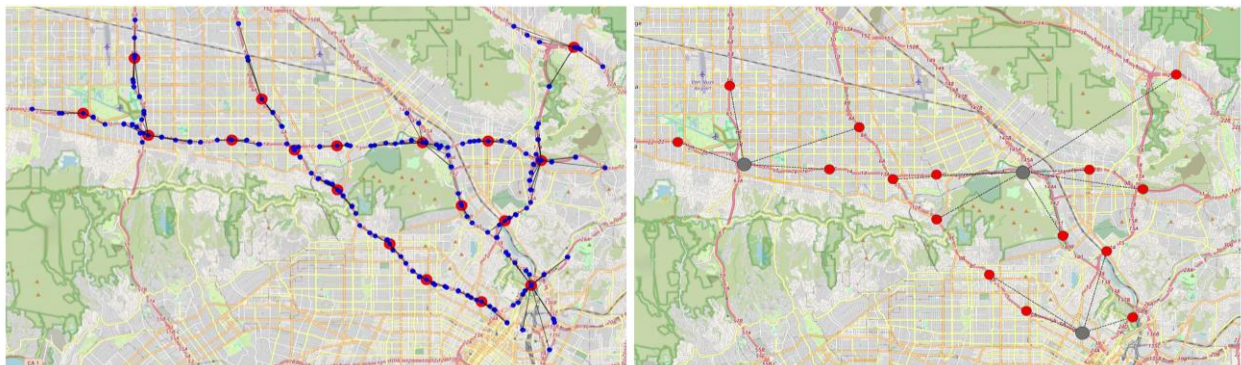


Рис. 2. Развертывание системы на датасете PeMSD4

Fig. 2. Deployment of the System on the PeMSD4 Dataset

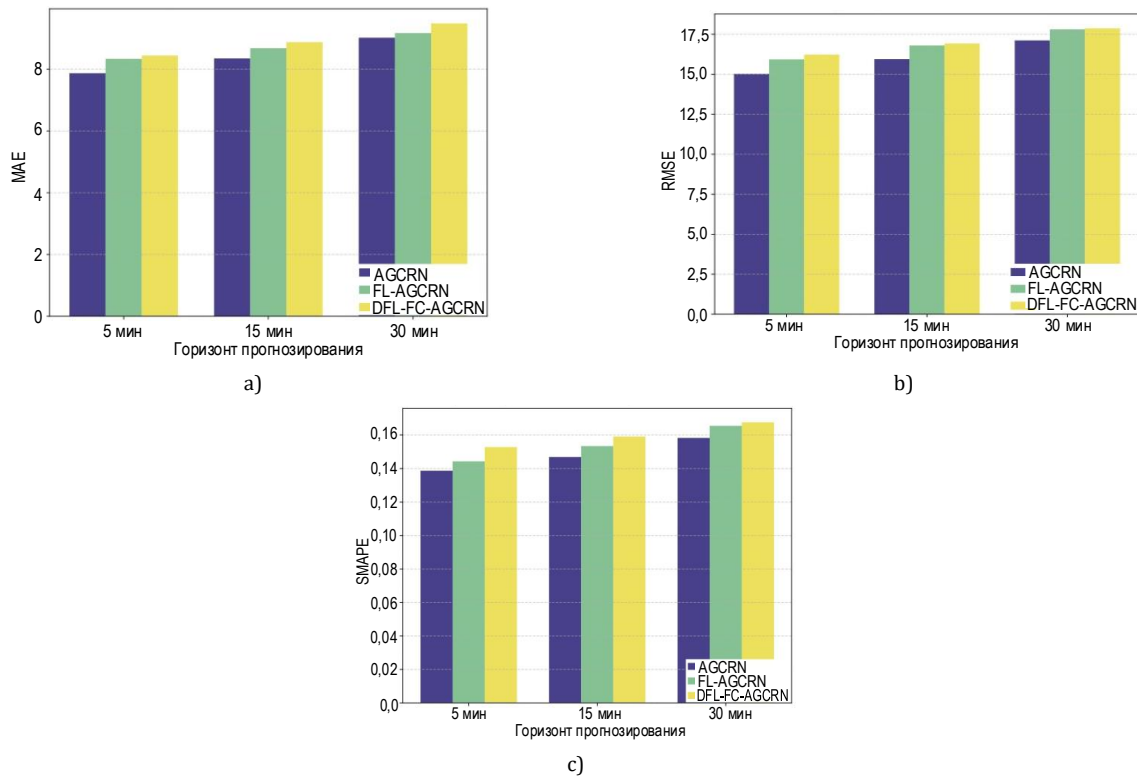


Рис. 3. Точность моделей на датасете PeMSD4: а) MAE; б) RMSE; в) SMAPE
 Fig. 3. Accuracy of Models on the PeMSD4 Dataset: a) MAE; b) RMSE; c) SMAPE

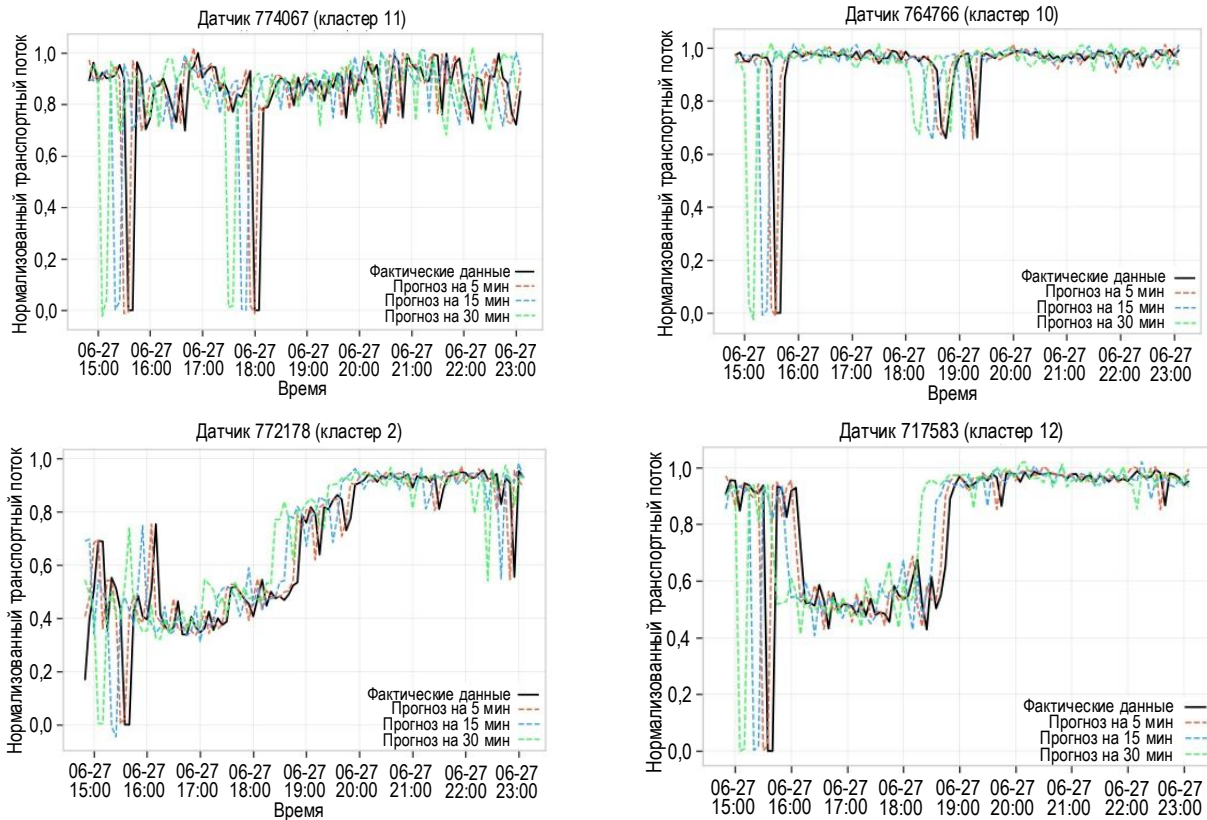


Рис. 4. Результаты прогноза модели DFL-FC-AGCRN для четырех случайно выбранных датчиков в кластерах
 Fig. 4. DFL-FC-AGCRN Model Forecast Results for Four Randomly Selected Sensors in Clusters

Оценка на расширенном датасете

Для проверки применимости предложенной модели были проведены дополнительные эксперименты на наборе данных PeMSD7(M). Это реальный транспортный набор данных из системы измерения производительности Caltrans (Performance Measurement System, Округ 7). Он содержит измерения скорости транспортных потоков с 228 датчиков (станций) на автомагистралях с временным шагом 5 мин. за определенные периоды (обычно один месяц или квартал). По сравнению с другими наборами PeMS, такими как PeMSD4 или PeMSD8, этот датасет содержит больше датчиков и позволяет оценить

способность модели работать с более распределенными и сложными данными.

Было выполнено исследование для выбора оптимального числа кластеров и альянсов туманных вычислений, при этом учитывались следующие критерии: возможность практического развертывания с учетом ограничений на радиус связи датчиков ($\leq 1,5$ км) и радиус взаимодействия внутри альянса (≤ 10 км), минимизация необходимых сетевых взаимодействий и точность прогноза модели. В итоге 228 датчиков организуются в 38 узлов и далее разбиваются на 3 альянса (это показано на рисунке 5).

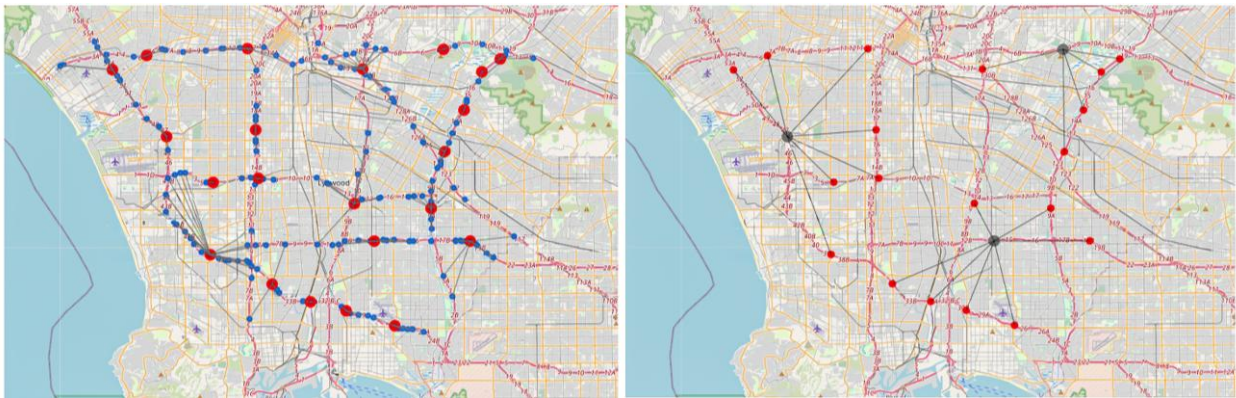


Рис. 5. Развертывание системы на наборе данных PeMSD7(M)

Fig. 5. Deployment of the System on the PeMSD7(M) Dataset

Для 50 раундов обучения с 3 локальными эпохами предлагаемая структура сохраняет эффективность, демонстрируя достаточную точность и при этом уменьшая необходимые сетевые взаимодействия благодаря иерархической структуре и предложенному механизму альянсов. Результаты показаны на рисунках 6 и 7. Сводные значения коммуникационных затрат на различных этапах обучения приведены в таблице 6. Средняя экономия сетевого взаимодействия составляет около 48% после 50 раундов.

ТАБЛИЦА 6. Затраты на связь на этапах реализации проекта

TABLE 6. Communication Cost at Milestones

Количество раундов	FL-AGCRN	DFL-FC-AGCRN	Экономия	
			МБ	%
10	343,30	178,60	164,70	48,0
20	686,60	357,20	329,40	48,0
50	1716,50	893,00	823,50	48,0
100	3433,00	178,10	1646,90	48,0

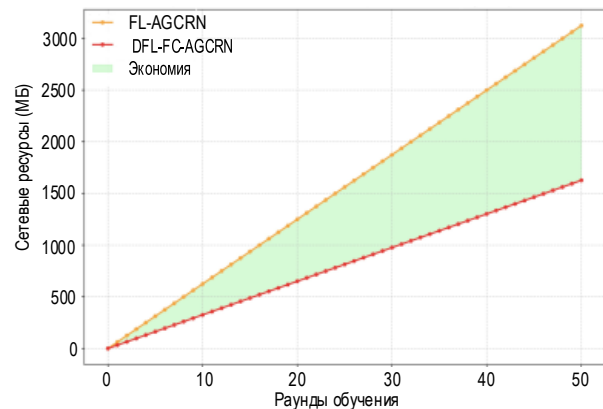


Рис. 6. Коммуникационные затраты нарастающим итогом

Fig. 6. Cumulative Communication Costs

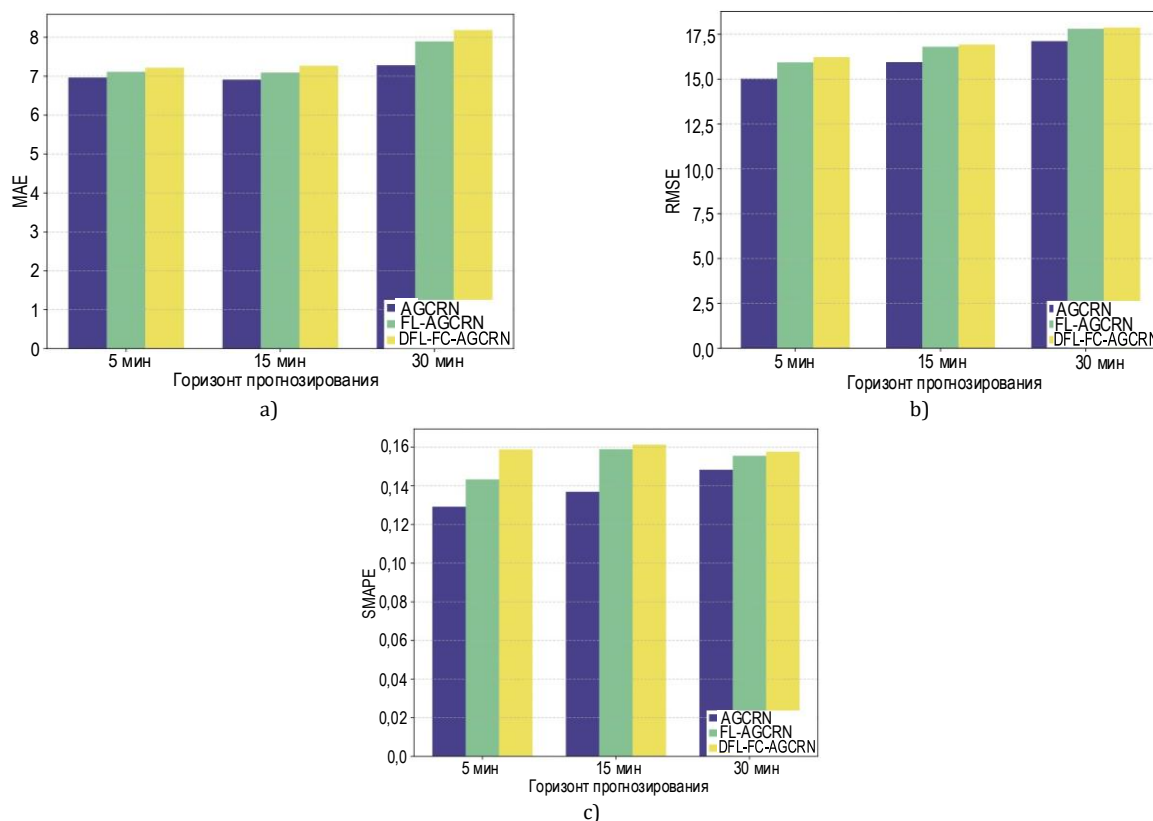


Рис. 7. Точность моделей на датасете PeMSD7(M): а) MAE; б) RMSE; в) SMAPE

Fig. 7. Accuracy of Models on the PeMSD7(M) Dataset: a) MAE; b) RMSE; c) SMAPE

Заключение

В данной работе представлена новая структура на основе альянсов, объединяющая туманные вычисления и децентрализованное FL для задачи прогнозирования трафика в распределенных средах умного города. Объединяя три современные технологии – децентрализованное FL, туманные вычисления и AGCRN, предлагается подход, который позволяет найти компромисс между точностью прогноза распределенной модели искусственного интеллекта, эффективностью использования сетевых ресурсов. При этом децентрализованный характер естественным образом обеспечивает устойчивость системы. Эксперименты на открытых реальных данных из системы Caltrans Performance Measurement System подтверждают осуществимость и эффективность метода. Следует отметить, что небольшое снижение точности модели при значительной экономии сетевого трафика и повышении отказоустойчивости является

допустимым компромиссом для практических приложений, работающих с большими объемами данных.

В целом предложенные структура и метод представляют собой важный шаг к созданию децентрализованных систем прогнозирования транспортных потоков, пригодных для внедрения в инфраструктуру умных городов. Такие системы могут также стать частью инфраструктуры сетевых городских пространств. Предложенный подход повышает не только качество прогнозирования, но и устойчивость и масштабируемость ИТС. С практической точки зрения данную структуру можно интегрировать в различные компоненты ИТС: прогнозирование скорости, потока трафика и другие задачи. Гибкость решения позволяет адаптировать его к различным сценариям, что открывает новые направления исследований в области распределенного прогнозирования транспортных потоков.

Список источников

1. Jiang W., Luo J. Graph neural network for traffic forecasting: A survey // Expert Systems with Applications. 2022. Vol. 207. P. 117921. DOI:10.1016/j.eswa.2022.117921. EDN:MOJUQL
2. Zanella A., Bui N., Castellani A., Vangelista L., Zorzi M. Internet of Things for Smart Cities // IEEE Internet of Things Journal. 2012. Vol. 1. Iss. 1. PP. 22–32. DOI:10.1109/JIOT.2014.2306328
3. Caterini A.L., Chang D.E. Recurrent Neural Networks // In: Deep Neural Networks in a Mathematical Framework. SpringerBriefs in Computer Science. Cham: Springer, 2018. PP. 59–79. DOI:10.1007/978-3-319-75304-1_5

4. Ateya A.A., Abd El-Latif A.A., Muthanna A., Volkov A., Koucheryavy A. Enabling Metaverse and Telepresence Services in 6G Networks. 2025. DOI:10.1201/9788770046749
5. Qi T., Chen L., Li G., Li Y., Wang C. FedAGCN: A traffic flow prediction framework based on federated learning and Asynchronous Graph Convolutional Network // *Applied Soft Computing*. 2023. Vol. 138. P. 110175. DOI:10.1016/j.asoc.2023.110175. EDN:XAIBCN
6. Yuan X., Chen J., Yang J., Zhang N., Yang T., Han T. FedSTN: Graph Representation Driven Federated Learning for Edge Computing Enabled Urban Traffic Flow Prediction // *IEEE Transactions on Intelligent Transportation Systems*. 2023. Vol. 24. Iss. 8. PP. 8738–8748. DOI:10.1109/TITS.2022.3157056. EDN:YKQIZO
7. Zhao L., Song Y., Zhang C., Liu Y., Wang P., Lin T. T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction // *IEEE Transactions on Intelligent Transportation Systems*. 2020. Vol. 21. Iss. 9. PP. 3848–3858. DOI:10.1109/TITS.2019.2935152.
8. Zhang C., Zhang S., Yu J.J.Q., Yu S. FASTGNN: A Topological Information Protected Federated Learning Approach for Traffic Speed Forecasting // *IEEE Transactions on Industrial Informatics*. 2021. Vol. 17. Iss. 12. PP. 8464–8474. DOI:10.1109/TII.2021.3055283
9. Feng Z., Zha H., Xu C., He Y., Lin Y. FCGCN: Feature Correlation Graph Convolution Network for Few-Shot Individual Identification // *IEEE Transactions on Consumer Electronics*. 2024. Vol. 70. Iss. 1. PP. 2848–2860. DOI:10.1109/TCE.2023.3322224
10. McMahan B., Moore E., Ramage D., Hampson S., A. y Arcas B. Communication-Efficient Learning of Deep Networks from Decentralized Data // *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics (PMLR)*. 2017. Vol. 54. PP. 1273–1282. URL: <https://proceedings.mlr.press/v54/mcmahan17a.html> (Accessed 29.09.2025)
11. Giannakis G.B., Ling Q., Mateos G., Schizas I.D., Zhu H. Decentralized Learning for Wireless Communications and Networking // In: Glowinski R., Osher S.J., Yin W. (eds.) *Splitting Methods in Communication, Imaging, Science, and Engineering*. Scientific Computation. Cham: Springer, 2016. PP. 461–497. DOI:10.1007/978-3-319-41589-5_14
12. Bai L., Yao L., Li C., Wang X., Wang C. Adaptive Graph Convolutional Recurrent Network for Traffic Forecasting // *Advances in Neural Information Processing Systems*. 2020. Vol. 33. PP. 17804–17815.
13. Liu Y., Yu J.J.Q., Kang J., Niyato D., Zhang S. Privacy-Preserving Traffic Flow Prediction: A Federated Learning Approach // *IEEE Internet of Things Journal*. 2020. Vol. 7. Iss. 8. PP. 7751–7763. DOI:10.1109/JIOT.2020.2991401. EDN:MKJWWJ
14. Yu B., Yin H., Zhu Z. Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting // *arXiv:1709.04875v4*. 2018. DOI:10.24963/ijcai.2018/505
15. Liu Y., Yu J.J.Q., Kang J., Niyato D., Zhang S. Privacy-Preserving Traffic Flow Prediction: A Federated Learning Approach // *IEEE Internet of Things Journal*. 2020. Vol. 7. Iss. 8. PP. 7751–7763. DOI:10.1109/JIOT.2020.2991401
16. Zhang H., Jiang S., Xuan S. Decentralized federated learning based on blockchain: concepts, framework, and challenges // *Computer Communications*. 2024. Vol. 216. PP. 140–150. DOI:10.1016/j.comcom.2023.12.042. EDN:NYTCWY
17. Lian X., Zhang C., Zhang H., Hsieh C.-J., Zhang W., Liu J. Can Decentralized Algorithms Outperform Centralized Algorithms? A Case Study for Decentralized Parallel Stochastic Gradient Descent // *arXiv:1705.09056v5*. 2017. DOI:10.48550/arXiv.1705.09056
18. Turazza F., Pietri M., Picone M., Mamei M. FedBGS: A Blockchain Approach to Segment Gossip Learning in Decentralized Systems // *Proceedings of the 45th International Conference on Distributed Computing Systems Workshops (ICDCSW, Glasgow, United Kingdom, 21–23 July 2025)*. IEEE, 2025. PP. 760–770. DOI:10.1109/ICDCSW63273.2025.00136
19. Yu E., Dong D., Xu Y., Ouyang S., Liao X. CD-SGD: Distributed Stochastic Gradient Descent with Compression and Delay Compensation // *arXiv:2106.10796v2*. 2021. DOI:10.48550/arXiv.2106.10796
20. Stewart G., Al-Khassaweneh M. An Implementation of the HDBSCAN* Clustering Algorithm // *Applied Sciences*. 2022. Vol. 12. Iss. 5. P. 2405. DOI:10.3390/app12052405
21. Chen C., Petty K., Skabardonis A. Freeway Performance Measurement System: Mining Loop Detector Data // *Transportation Research Record: Journal of the Transportation Research Board*. 2001. Vol. 1748. Iss. 1. DOI:10.3141/1748-12
22. Sharma M., Jaggi P. Reliable federated learning in a cloud-fog-IoT environment // *The Journal of Supercomputing*. 2023. Vol. 79. PP. 15435–15458. DOI:10.1007/s11227-023-05252-w. EDN:EETJGC
23. Manju B., Kumar C.S.P., Jegan J., Jagadeeshan D., Nunna S.K. Hierarchical Federated Learning with Fog Nodes: Enhancing Efficiency in Smart City Networks // *Proceedings of the International Conference on Information Technology (OCIT, Vijayawada, India, 12–14 December 2024)*. IEEE, 2024. PP. 749–753. DOI:10.1109/OCIT65031.2024.00135
24. Lähderanta T., Lovén L., Ruha L., Leppänen T., Launonen I., Riekkilä J., et al. Capacitated spatial clustering with multiple constraints and attributes // *Engineering Applications of Artificial Intelligence*. 2024. Vol. 127. Part A. P. 107182. DOI:10.1016/j.engappai.2023.107182. EDN:CXFPOY
25. Hu J., Liu K. Raft consensus mechanism and the applications // *Journal of Physics: Conference Series*. 2020. Vol. 1544. Iss. 1. P. 012079. DOI:10.1088/1742-6596/1544/1/012079. EDN:IJJLUI
26. Performance evaluation of IEEE 802.11ah systems // *Proceedings of the 24th Telecommunications Forum (TELFOR, Belgrade, Serbia, 22–23 November 2016)*. IEEE, 2016. DOI:10.1109/TELFOR.2016.7818748

References

1. Jiang W., Luo J. Graph neural network for traffic forecasting: A survey. *Expert Systems with Applications*. 2022;207: 117921. DOI:10.1016/j.eswa.2022.117921. EDN:MOJUQL
2. Zanella A., Bui N., Castellani A., Vangelista L., Zorzi M. Internet of Things for Smart Cities. *IEEE Internet of Things Journal*. 2012;1(1):22–32. DOI:10.1109/JIOT.2014.2306328
3. Caterini A.L., Chang D.E. Recurrent Neural Networks. In: *Deep Neural Networks in a Mathematical Framework*. Springer-Briefs in Computer Science. Cham: Springer; 2018. p.59–79. DOI:10.1007/978-3-319-75304-1_5
4. Ateya A.A., Abd El-Latif A.A., Muthanna A., Volkov A., Koucheryavy A. *Enabling Metaverse and Telepresence Services in 6G Networks*. 2025. DOI:10.1201/9788770046749
5. Qi T., Chen L., Li G., Li Y., Wang C. FedAGCN: A traffic flow prediction framework based on federated learning and Asynchronous Graph Convolutional Network. *Applied Soft Computing*. 2023;138:110175. DOI:10.1016/j.asoc.2023.110175. EDN:XAIBCN


6. Yuan X., Chen J., Yang J., Zhang N., Yang T., Han T. FedSTN: Graph Representation Driven Federated Learning for Edge Computing Enabled Urban Traffic Flow Prediction. *IEEE Transactions on Intelligent Transportation Systems*. 2023;24(8): 8738–8748. DOI:10.1109/TITS.2022.3157056. EDN:YKQIZO
7. Zhao L., Song Y., Zhang C., Liu Y., Wang P., Lin T. T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction. *IEEE Transactions on Intelligent Transportation Systems*. 2020;21(9):3848–3858. DOI:10.1109/TITS.2019.2935152. EDN:EDVHGA
8. Zhang C. Zhang S., Yu J.J.Q., Yu S. FASTGNN: A Topological Information Protected Federated Learning Approach for Traffic Speed Forecasting. *IEEE Transactions on Industrial Informatics*. 2021;17(12):8464–8474. DOI:10.1109/TII.2021.3055283
9. Feng Z., Zha H., Xu C., He Y., Lin Y. FCGCN: Feature Correlation Graph Convolution Network for Few-Shot Individual Identification. *IEEE Transactions on Consumer Electronics*. 2024;70(1):2848–2860. DOI:10.1109/TCE.2023.3322224
10. McMahan B., Moore E., Ramage D., Hampson S., A. y Arcas B. Communication-Efficient Learning of Deep Networks from Decentralized Data. *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics, PMLR, vol.54*. 2017. p.1273–1282. URL: <https://proceedings.mlr.press/v54/mcmahan17a.html> [Accessed 29.09.2025]
11. Giannakis G.B., Ling Q., Mateos G., Schizas I.D., Zhu H. Decentralized Learning for Wireless Communications and Networking. In: *Glowinski R., Osher S.J., Yin W. (eds.) Splitting Methods in Communication, Imaging, Science, and Engineering. Scientific Computation*. Cham: Springer; 2016. p.461–497. DOI:10.1007/978-3-319-41589-5_14
12. Bai L., Yao L., Li C., Wang X., Wang C. Adaptive Graph Convolutional Recurrent Network for Traffic Forecasting. *Advances in Neural Information Processing Systems*. 2020;33:17804–17815.
13. Liu Y., Yu J.J.Q., Kang J., Niyato D., Zhang S. Privacy-Preserving Traffic Flow Prediction: A Federated Learning Approach. *IEEE Internet of Things Journal*. 2020;7(8):7751–7763. DOI:10.1109/JIOT.2020.2991401. EDN:MKJWJ
14. Yu B., Yin H., Zhu Z. Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting. *arXiv:1709.04875v4*. 2018. DOI:10.24963/ijcai.2018/505
15. Liu Y., Yu J.J.Q., Kang J., Niyato D., Zhang S. Privacy-Preserving Traffic Flow Prediction: A Federated Learning Approach. *IEEE Internet of Things Journal*. 2020;7(8):7751–7763. DOI:10.1109/JIOT.2020.299140
16. Zhang H., Jiang S., Xuan S. Decentralized federated learning based on blockchain: concepts, framework, and challenges. *Computer Communications*. 2024;216:140–150. DOI:10.1016/j.comcom.2023.12.042. EDN:NYTCWY
17. Lian X., Zhang C., Zhang H., Hsieh C.-J., Zhang W., Liu J. Can Decentralized Algorithms Outperform Centralized Algorithms? A Case Study for Decentralized Parallel Stochastic Gradient Descent. *arXiv:1705.09056v5*. 2017. DOI:10.48550/arXiv.1705.09056
18. Turazza F., Pietri M., Picone M., Mamei M. FedBGS: A Blockchain Approach to Segment Gossip Learning in Decentralized Systems. *Proceedings of the 45th International Conference on Distributed Computing Systems Workshops, ICDCSW, 21–23 July 2025, Glasgow, United Kingdom*. IEEE; 2025. p.760–770. DOI:10.1109/ICDCSW63273.2025.00136
19. Yu E., Dong D., Xu Y., Ouyang S., Liao X. CD-SGD: Distributed Stochastic Gradient Descent with Compression and Delay Compensation. *arXiv:2106.10796v2*. 2021. DOI:10.48550/arXiv.2106.10796
20. Stewart G., Al-Khassaweneh M. An Implementation of the HDBSCAN* Clustering Algorithm. *Applied Sciences*. 2022;12(5):2405. DOI:10.3390/app12052405
21. Chen C., Petty K., Skabardonis A. Freeway Performance Measurement System: Mining Loop Detector Data. *Transportation Research Record: Journal of the Transportation Research Board*. 2001;1748(1). DOI:10.3141/1748-12
22. Sharma M., Jaggi P. Reliable federated learning in a cloud-fog-IoT environment. *The Journal of Supercomputing*. 2023;79:15435–15458. DOI:10.1007/s11227-023-05252-w. EDN:EETJGC
23. Manju B., Kumar C.S.P., Jegan J., Jagadeeshan D., Nunna S.K. Hierarchical Federated Learning with Fog Nodes: Enhancing Efficiency in Smart City Networks. *Proceedings of the International Conference on Information Technology, OCIT, 12–14 December 2024, Vijayawada, India*. IEEE; 2024. p.749–753. DOI:10.1109/OCIT65031.2024.00135
24. Lähderanta T., Lovén L., Ruha L., Leppänen T., Launonen I., Riekkki J., et al. Capacitated spatial clustering with multiple constraints and attributes. *Engineering Applications of Artificial Intelligence*. 2024;127(Part A):107182. DOI:10.1016/j.engappai.2023.107182. EDN:CXFPOY
25. Hu J., Liu K. Raft consensus mechanism and the applications. *Journal of Physics: Conference Series*. 2020;1544(1): 012079. DOI:10.1088/1742-6596/1544/1/012079. EDN:IJLLUI
26. Performance evaluation of IEEE 802.11ah systems. *Proceedings of the 24th Telecommunications Forum, TELFOR, 22–23 November 2016, Belgrade, Serbia*. IEEE; 2016. DOI:10.1109/TELFOR.2016.7818748

Статья поступила в редакцию 23.03.2026; одобрена после рецензирования 18.04.2026; принята к публикации 23.04.2026


The article was submitted 23.03.2026; approved after reviewing 18.04.2026; accepted for publication 23.04.2026

Информация об авторах:

**Тханг
ДАНГ Ван**

аспирант кафедры сетей связи и передачи данных Санкт-Петербургского государственного университета телекоммуникаций им. проф. М.А. Бонч-Бруевича
 <https://orcid.org/0009-0009-2219-3767>

**ВОЛКОВ
Артём Николаевич**

доктор технических наук, доцент, доцент кафедры сетей связи и передачи данных Санкт-Петербургского государственного университета телекоммуникаций им. проф. М.А. Бонч-Бруевича
 <https://orcid.org/0009-0002-4296-1822>

Авторы сообщают об отсутствии конфликтов интересов.

The authors declare no conflicts of interests.