Научная статья
УДК 004.94
https://doi.org/10.17586/2713-1874-2025-4-68-82

ПРОГНОЗИРОВАНИЕ ЗАГРУЖЕННОСТИ УЧАСТКОВ УЛИЧНО-ДОРОЖНОЙ СЕТИ ПО ДАННЫМ ИЗ ОТКРЫТЫХ ИСТОЧНИКОВ

Александр Сергеевич Морозов[1]✉, Полина Дмитриевна Крупенина[2], Татьяна Игоревна Балтыжакова[3]

[1,2,3]Университет ИТМО, Санкт-Петербург, Россия
[1]asmorozov@itmo.ru✉, https://orcid.org/0009-0009-0889-9683
[2]krupenina.p@mail.ru, https://orcid.org/0000-0001-8843-3027
[3]tibaltyzhakova@itmo.ru, https://orcid.org/0000-0001-9160-1167
Язык статьи – русский

Аннотация: В статье представлен метод прогнозирования загруженности участков улично-дорожной сети по данным из открытых источников с использованием гравитационной модели. Актуальность темы исследования обусловлена ограниченной доступностью достоверных и полноценных данных о реальной транспортной загруженности в российских городах. Цель исследования заключается в разработке подхода, который может выступать как альтернатива или дополнение к оценке и прогнозированию загруженности дорог в условиях ограниченности данных. В качестве исходных данных используются параметры городских кварталов – население, плотность и разнообразие сервисов, а также типы землепользования, что позволяет вычислить показатели спроса и привлекательности для перемещений между кварталами. На основе этих данных формируется матрица корреспонденций, отражающая относительный объем транспортных потоков между узлами улично-дорожной сети, представленной в виде взвешенного направленного графа. Метод позволяет оценить потенциальную загруженность дорог города без использования закрытых или дорогостоящих данных о дорожном трафике, что особенно актуально при проектировании новых участков улично-дорожной сети и планировании городской инфраструктуры. Экспериментальная проверка выполнена на примере территории Васильевского острова в Санкт-Петербурге с использованием открытых данных OpenStreetMap. Предложенный подход может быть полезен для повышения эффективности градостроительного планирования и управления транспортной системой города. Дальнейшие исследования могут быть направлены на развитие модели и интеграцию с методами машинного обучения.

Ключевые слова: гравитационная модель, загруженность дорог, открытые данные, транспортные потоки, улично-дорожная сеть

Ссылка для цитирования: Морозов А. С., Крупенина П. Д., Балтыжакова Т. И. Прогнозирование загруженности участков улично-дорожной сети по данным из открытых источников // Экономика. Право. Инновации. – 2025. – Т. 13. – № 4. – С. 68–82. – https://doi.org/10.17586/2713-1874-2025-4-68-82.

FORECASTING TRAFFIC CONGESTION IN ROAD NETWORK SECTIONS BASED ON OPEN SOURCE DATA

Aleksandr S. Morozov[1]✉, Polina D. Krupenina[2], Tatiana I. Baltyzhakova[3]

[1,2,3]ITMO University, Saint Petersburg, Russia
[1]asmorozov@itmo.ru✉, https://orcid.org/0009-0009-0889-9683
[2]krupenina.p@mail.ru, https://orcid.org/0000-0001-8843-3027
[3]tibaltyzhakova@itmo.ru, https://orcid.org/0000-0001-9160-1167
Article in Russian

Abstract: The article presents a method for assessing the traffic demand on city streets and roads based on open data using a gravity model. The relevance of the research topic is due to the limited availability of reliable and comprehensive data on actual traffic congestion in Russian cities. The aim of the study is to develop an approach that can serve as an alternative or supplement to assessing and forecasting road congestion in conditions of limited data. The initial data used are the parameters of urban neighborhoods – population, density and diversity of services, as well as land use types – which allow calculating indicators of demand and attractiveness for travel between neighborhoods. Based on this data, a correspondence matrix is formed, reflecting the relative volume of traffic flows between nodes of the street and road network, presented in the form of a weighted directed graph. The method allows assessing the demand and potential congestion of city roads without using closed or expensive road traffic data, which is especially relevant when designing

new sections of the street and road network and planning urban infrastructure. An experimental test was carried out on the example of Vasilyevsky Island in St. Petersburg using open data from OpenStreetMap. The proposed approach can be useful for improving the efficiency of urban planning and transport management.

Keywords: gravity model, traffic congestion, open data, traffic flows, street and road network

For citation: Morozov A. S., Krupenina P. D., Baltyzhakova T. I. Forecasting Traffic Congestion in Road Network Sections Based on Open Source Data. *Ekonomika. Pravo. Innovacii.* 2025. Vol. 13. No. 4. pp. 68–82. (In Russ.). https://doi.org/10.17586/2713-1874-2025-4-68-82

Введение. Улично-дорожные сети (УДС) являются критически важными инфраструктурными объектами городов и регионов. Дороги, являясь частью транспортной системы, обеспечивают мобильность людей, перемещение товаров и ресурсов. Во многом уровень развития транспортной системы непосредственно связан с уровнем развития городов и их способностью адаптироваться к постоянно меняющимся потребностям общества [1].

Вместе с этим за последние десятилетия значительно вырос уровень автомобилизации, что привело к заметным проблемам в городах, таким как транспортные заторы, загрязнение воздуха, увеличение количества дорожно-транспортных происшествий и среднего времени корреспонденции [2]. Рост производственной и деловой активности и повышение уровня благосостояния населения привели к возрастанию нагрузки на транспортную систему, что требует её модернизации в соответствии с новыми социально-экономическими реалиями.

Для преодоления перечисленных вызовов и повышения качества жизни в городах применяются технологии интеллектуальных транспортных систем (ИТС) [3, 4]. Такие системы ориентированы на сбор и обработку данных для моделирования и регулирования транспортных потоков. Одним из приоритетных направлений развития технологий ИТС является прогнозирование загруженности участков улично-дорожной сети. Загруженность дорог, как правило, определяется через интенсивность транспортного потока. В российских нормативных документах интенсивность обозначает «количество транспортных средств, проходящих через поперечное сечение автомобильной дороги в единицу времени (за сутки или за один час)» [5]. Расчет и прогнозирование загруженности необходимы как для эффективного управления дорожным движением в текущих условиях, так и для планирования развития улично-дорожной сети и города в целом.

За последние годы появилось множество методов и подходов к определению и прогнозированию загруженности УДС. Наряду с существующими примерами «классических» подходов, таких как анализ временных рядов, все чаще в научной литературе можно встретить работы о применении методов машинного обучения, нейронных сетей и комбинированных методов [6–8]. Многие из этих подходов используют данные с устройств, фиксирующих факт передвижения автомобилей. Такие устройства могут располагаться как на магистралях и дорогах, так и непосредственно в автомобилях у пользователей [9].

К сожалению, данные с датчиков и сопутствующих устройств, фиксирующих поток автомобилей на участках улично-дорожной сети, остаются в большинстве своем неточными или закрытыми для исследователей и проектировщиков [10, 11]. Похожая ситуация наблюдается и в развивающихся странах, где сбор и обработка данных о трафике невозможны из-за необходимости больших финансовых вложений в создании систем мониторинга, из-за чего появляется проблема отсутствия точных данных как таковых [12, 13]. Особенностью российского контекста таких исследований является отсутствие не только актуальных данных о загрузке улично-дорожной сети, но и исторических данных, что делает классические методы фактически неприменимыми. В большинстве городов отсутствуют развитые сети детекторов транспорта, не ведётся открытая публикация данных о потоках и скоростях, а существующие «изолированные» источники обладают высокой фрагментарностью и неоднородностью [14]. В связи с этим существует необходимость в поиске альтернативных подходов к опреде-

лению загруженности улично-дорожной сети, основанных на открытых данных, которые будут полезными при принятии решений в системе управления городом.

Постановка задачи исследования. Целью данного исследования является повышение эффективности планирования в градостроительной деятельности за счет применения метода прогнозирования загруженности участков улично-дорожной сети по данным из открытых источников, что позволит прогнозировать параметры улично-дорожной сети, используя минимально-необходимый состав данных, включая информацию о городских сервисах и типах землепользования, для вычисления показателя «привлекательности» квартала для корреспонденции в него.

Литературный обзор в области моделирования транспортной загруженности дорог. Задача моделирования и прогнозирования транспортных потоков зачастую сводится к оценке наблюдаемой величины, к примеру, интенсивности и скорости потока на участке улично-дорожной сети за определенный промежуток времени, для дальнейшего прогнозирования. В таком случае исследователи обращаются к прогнозированию временных рядов с использованием статистических методов.

Статистические методы представляют собой набор математических и аналитических инструментов, используемых для анализа данных и выявления закономерностей. Эти методы основываются на теории вероятностей и статистике и позволяют делать прогнозы на основе исторических данных. К примеру, модель ARIMA (AutoRegressive Integrated Moving Average) является одним из классических статистических подходов для анализа данных об интенсивности потока за определенный период времени, представленных в виде временных рядов. В современных реализациях модель ARIMA часто используется в качестве компонента гибридных моделей для повышения точности прогнозирования [15].

Существуют модели прямого спроса, которые оценивают объем движения на основе набора определенных характеристик, таких как интенсивность дорожного трафика, тип землепользования и различные социально-экономические факторы [16–18]. Однако предложенные подходы игнорируют взаимодействия между землепользованием и транспортной системой и требуют точных данных о трафике за значительный период времени.

Также значительный вклад в оценку загруженности дорог внесли методы машинного обучения и нейронные сети [8, 19]. Их основным преимуществом является способность обнаруживать сложные нелинейные зависимости в данных о транспортных потоках. Среди наиболее часто используемых архитектур нейронных сетей для анализа дорожного трафика выделяются [20]: Feed-Forward Neural Network (FFNN) – прямонаправленные нейронные сети, эффективные для базового прогнозирования транспортных потоков; Dynamic Fuzzy Neural Network (D-FNN) – динамические нейронные сети, обеспечивающие более гибкие прогнозы с учетом изменяющихся условий.

Наибольший прогресс по сравнению с вышеупомянутыми подходами к прогнозированию трафика являются графовые нейронные сети (GNNs) [21]. Так как такие модели работают исключительно с графовой структурой, это позволяет обнаруживать пространственные зависимости в исходных данных для более точного прогнозирования [22]. Модель T-GCN [23] объединила операции свертки графов с временным моделированием, что позволило добиться улучшения точности на 20% по сравнению с традиционными подходами. Механизмы внимания позволяют моделям динамически выделять наиболее важные пространственные и временные зависимости. Благодаря этому улучшилось качество работы архитектур, особенно при прогнозировании состояния дорожной сети в целом [24]. Однако по-прежнему существуют проблемы с интеграцией неструктурированных источников данных, таких как погодные условия или информация о происшествиях на дорогах [25]. Требование наличия большого объема помеченных обучающих данных и ограниченная интерпретируемость GNNs также представляют собой препятствия для практического внедрения.

В отличие от традиционных моделей глубокого обучения, которым сложно работать с текстовой информацией, большие языковые модели способны напрямую

обрабатывать описания дорожных событий, прогнозы погоды, сообщения из социальных сетей и другие неструктурированные источники [26,27]. Это делает их особенно ценными в современных исследованиях, где ключевую роль играет использование мультимодальных данных – разнородной информации, отражающей как физическое состояние транспортной сети, так и контекстные факторы.

Также существуют подходы, основанные на свойствах графов. В таком случае улично-дорожная сеть, на которой оценивают и прогнозируют загруженность дорог, представлена в виде направленного взвешенного графа. В предложенных подходах рассматриваются такие свойства как топология улично-дорожной сети [28], центральность [12], а также степень посредничества (betweenness centrality) [29].

Однако все рассмотренные выше подходы опираются на большое количество исторических данных о дорожном движении, что потенциально делает применение этих подходов невозможным в задачах проектирования новых участков улично-дорожной сети. В таких случаях необходимы методы моделирования, опирающиеся на свойства системы и прогнозные сценарии, а не на исторические данные.

Методы и материалы исследования.

Метод оценки востребованности участков УДС. Предложенный подход основан на моделировании параметров планировочной структуры городской территории на уровне кварталов, которые выступают базовыми пространственными единицами анализа. Для каждого квартала вычисляются показатели спроса и предложения. На основе этих показателей формируется матрица корреспонденций между кварталами. Между узлами сети рассчитываются потоки с использованием гравитационной модели, что позволяет определить востребованность отдельных дорог и оценить роль элементов УДС в формировании транспортных связей между кварталами. Блок-схема метода представлена на Рисунке 1.

Плотность и разнообразие сервисов интерпретируются как косвенные индикаторы сосредоточенности городской активности в пределах квартала. Исследования по связи застройки и транспортного поведения показывают, что увеличение плотности застройки и функционального разнообразия территорий сопровождается ростом числа поездок и более интенсивным использованием улично-дорожной сети [30, 31]. В рамках гравитационных моделей такие показатели включаются в состав переменных, характеризующих «массу» пункта притяжения – его размер, функциональную насыщенность и инфраструктурное обеспечение [32]. Добавление плотности и разнообразия сервисов в компонент предложения согласуется с практикой расширения гравитационных моделей за счёт характеристик землепользования и инфраструктуры пункта назначения [33].

Рисунок 1 – Блок-схема метода
Источник: составлено авторами

Входные данные. Для моделирования параметров единиц планировочной структуры, кварталов, используется библиотека с открытым исходным кодом на Python, BlocksNet [34]. Модель собирается на основе графа квартальной сети, где вершины представлены кварталами изучаемой территории, а ребра – оценки транспортной связанности городских кварталов. Каждый квартал, представленный в виде полигона, включает информацию о размещенных сервисах, жилых домах и населении. Данные были получены из открытого картографического источника OpenStreetMap (Рисунок 2). Используемая квартально-сетевая модель является универсальной и позволяет смоделировать единицы планировочной структуры с учетом топологии улично-дорожной сети таким образом, чтобы оценить обеспеченность жителей всеми необходимыми сервисами в ближайшей доступности.

Каждый полигон квартала характеризуется следующими атрибутами (спецификация данных представлена в таблице 1):

– население квартала (количество человек);

– плотность сервисов (количество/м^2);

– разнообразие сервисов (безразмерный показатель, от 0 до ∞);

– тип землепользования (категориальный показатель).

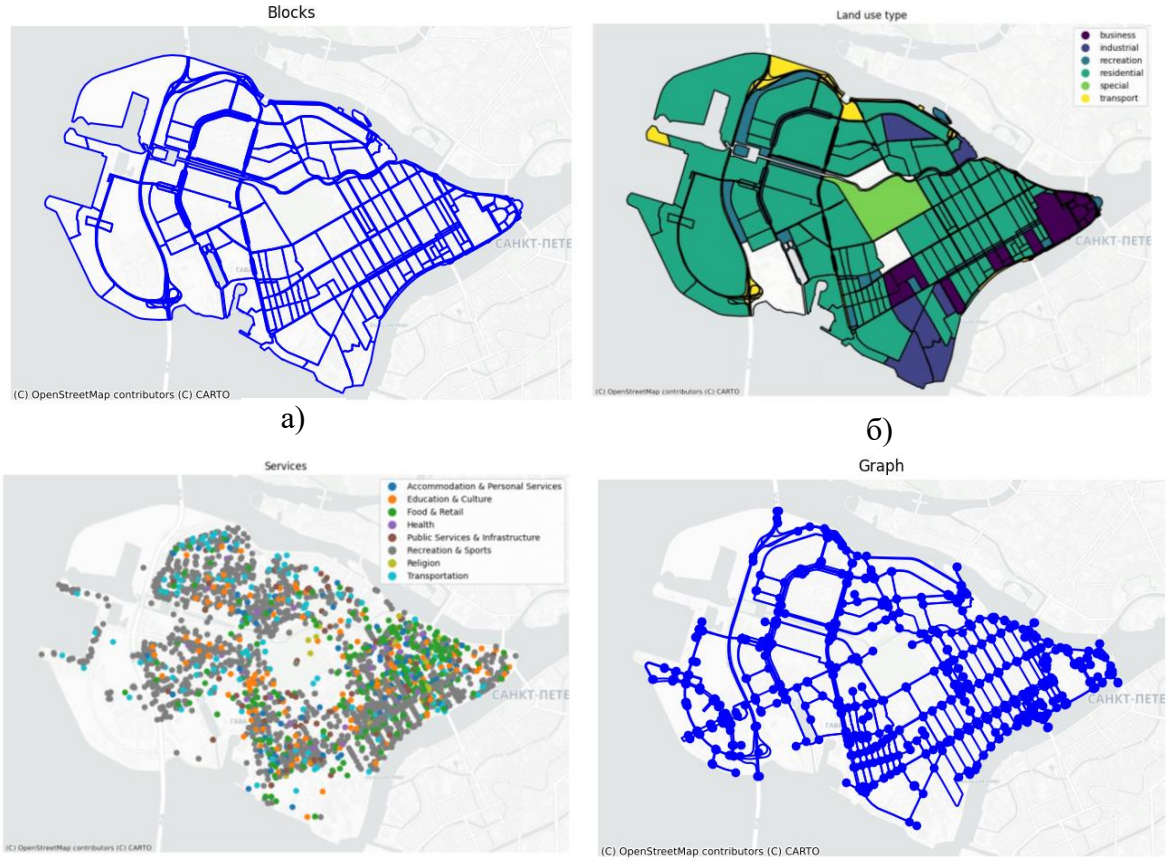

Рисунок 2 – Данные по территории Василеостровского административного района Санкт-Петербурга: а – геометрии кварталов, б – типы землепользования, в – городские сервисы, агрегированные по группам, г – взвешенный направленный граф улично-дорожной сети

Источник: составлено авторами на основе OpenStreetMap

Улично-дорожная сеть городской территории представлена также в виде графа, собранного с помощью библиотеки с открытым исходным кодом на Python, IduEdu [35]. Граф описывает транспортную сеть рассматриваемой территории, при этом вершины графа представляют собой точки перекрёстков, а рёбра – связи между ними, содержащие атрибут расстояния и скорости преодоления ребра на транспорте.

Таблица 1

Спецификация данных

Источник: составлено авторами

Данные	Формат	Атрибуты
Кварталы	gpd.GeoDataFrame	geometry: polygon
Улично-дорожная сеть	nx.MultiDiGraph	crs nodes edges
Землепользование	gpd.GeoDataFrame	geometry: polygon land_use: str
Сервисы	gpd.GeoDataFrame	geometry: point
Здания	gpd.GeoDataFrame	geometry: Point population: int floors: float area: float living_area: float is_living: bool

Формальное представление. Q – множество кварталов с параметрами населения, плотности сервисов и их разнообразия {$\boldsymbol{population_q}$, $\boldsymbol{density_q}$, $\boldsymbol{diversity_q}$}.

G = (V,E) – граф улично-дорожной сети, где *V* – множество вершин (перекрестков, заездов, тупиков), *E* – множество ребер (участков дорог).

Радиус *R* = 10 минутной доступности для агрегации данных.

Для каждого квартала q вычисляется коэффициент согласно типу землепользования, указанного в Таблице 2 (lu_coeff_q). Затем для каждого квартала q вычисляются нормализованные значения его параметров спроса и предложения:

$$P_q = population_q \quad (1)$$

$$\mathrm{A}_q = lu\_coeff_q + density_q + diversity_q \quad (2)$$

Перенос параметров кварталов на вершины графа УДС:

$$P_i = \sum_{q:i\in S_q} \frac{P_q}{d(q,i)} \quad (3)$$

$$A_i = \sum_{q:i\in S_q} \frac{A_q}{d(q,i)} \quad (4)$$

Построение матрицы корреспонденций:

$$x_{ij} = \frac{P_i A_j}{d(i,j)} \quad (5)$$

Моделирование спроса и предложения. Для каждого квартала определяются следующие нормализованные параметры.

1) Коэффициент землепользования – вычисляется на основе типа землепользования, отражает привлекательность района для деловой активности и работы. Так, территории с преобладанием деловой застройки и промышленности получают более высокие значения коэффициента, что свидетельствует об их повышенном потенциале для привлечения работников и экономической активности.

В то же время, зоны с менее интенсивным развитием, такие как сельскохозяйственные (в модели города BlocksNet учитываются семь типов (приведены в таблице 2) функциональных зон [5]) или рекреационные, характеризуются меньшими коэффициентами, указывающими на их относительно низкую привлекательность. Таким образом, коэффициент служит индикатором, который количественно оценивает потенциал района, делая более высокие значения признаком более привлекательных для работы территорий. В таблице 2 приведены значения коэффициента для разных типов землепользования.

2) Спрос – количество людей, которые потенциально могут перемещаться из исходного квартала. Соответствует населению квартала.

3) Привлекательность (предложение) – вычисляется как сумма коэффициента землепользования (lu_coeff), нормализованного разнообразия (diversity) и нормализованной плотности (density).

Таблица 2

Коэффициенты землепользования

Источник: составлена авторами на основе [5]

Коэффициент	Тип землепользования
0.06	None (Тип землепользования не определен)
0.25	Industrial – Промышленный
0.30	Business – Деловой
0.10	Special – Специальный
0.10	Transport – Транспортный
0.10	Residential – Жилой
0.05	Agriculture – Сельскохозяйственный
0.05	Recreation – Рекреационный

Агрегация данных на транспортные узлы. Для переноса параметров из кварталов на узлы транспортной сети применяется следующий алгоритм:

– каждый квартал ассоциируется с набором перекрёстков в радиусе 10 минутной доступности;

– значения спроса и предложения квартала распределяются между соответствующими остановками обратно пропорционально расстоянию от центроида квартала до остановки.

Для каждой вершины графа улично-дорожной сети $i \in S_q$ вклад от квартала рассчитывается по следующим формулам:

$$P_{q \to i} = \frac{P_q}{d(q,i)} \quad (6)$$

$$A_{q \to i} = \frac{A_q}{d(q,i)} \quad (7)$$

где:

$-P_q$ – спрос квартала q;

$-A_q$ – предложение квартала q;

$-S_q$ – множество вершин графа УДС, попадающих в зону 10 минутной доступности от квартала q;

$-d(q,i)$ – расстояние от центроида квартала q до вершины графа i.

Вычисление матрицы корреспонденций. Пусть i и j два узла транспортной сети (Графа УДС). Поток между ними определяется с использованием гравитационной модели:

$$x_{ij} = \frac{P_i A_j}{d(i,j)} \quad (8)$$

где:

$-P_i$ – суммарный спрос, перенесенный на вершину графа;

$-A_j$ – суммарное предложение, перенесенное на вершину графа;

$-d(i,j)$ – расстояние между вершинами i и j, вычисляемое на основе кратчайшего пути в графе УДС.

Полученная матрица $X = [x_{ij}]$ представляет собой матрицу корреспонденций, измеряемую в относительных единицах, отражающих объем потока между каждой парой узлов.

После построения матрицы для каждой пары узлов графа i и j вычисляется маршрут, соответствующий кратчайшему пути. На каждом ребре маршрута суммируется дополнительный вес, пропорционально значению x_{ij}, что позволяет оценить вклад данной корреспонденции в «загруженность» данного участка транспортной сети. Итоговый вес на каждом ребре отражает суммарный поток людей, перемещающихся по этому сегменту, в случае если делается предположение, что все перемещаются по кратчайшим маршрутам.

Выходные данные. На выходе работы метода получается: матрица корреспонденций $\boldsymbol{X}$ – матрица, где каждая ячейка $\boldsymbol{x_{ij}}$ представляет относительный объём потока между кварталами $\boldsymbol{i}$ и $\boldsymbol{j}$; взвешенный граф улично-дорожной сети, в котором каждому ребру сопоставлен суммарный вес, полученный по сумме вкладов из матрицы корреспонденций вдоль маршрутов между узлами.

На рисунке 3 представлена визуализация сгенерированной матрицы корреспонденций по потокам между кварталами исследуемой территории. Чтобы выявить и сравнить сильные и слабые связи, исходящие и входящие потоки разбиваются на квартили. Для каждого квартала (на рисунке отображены точками-центроидами) строятся линии по матрице, цвет и толщина которых отражают объём безразмерных соответствующих перемещений между кварталами. Размеры точек пропорциональны населению в квартале (слева) и привлекательности для поездки в него (справа). На рисунке 4 представлена визуализация потоков между кварталами по графу улично-дорожной сети. Для каждого ребра улично-дорожной сети вычислена суммарная величина потока, проходящего через него по всем кратчайшим путям, определённым на основе матрицы корреспонденций.

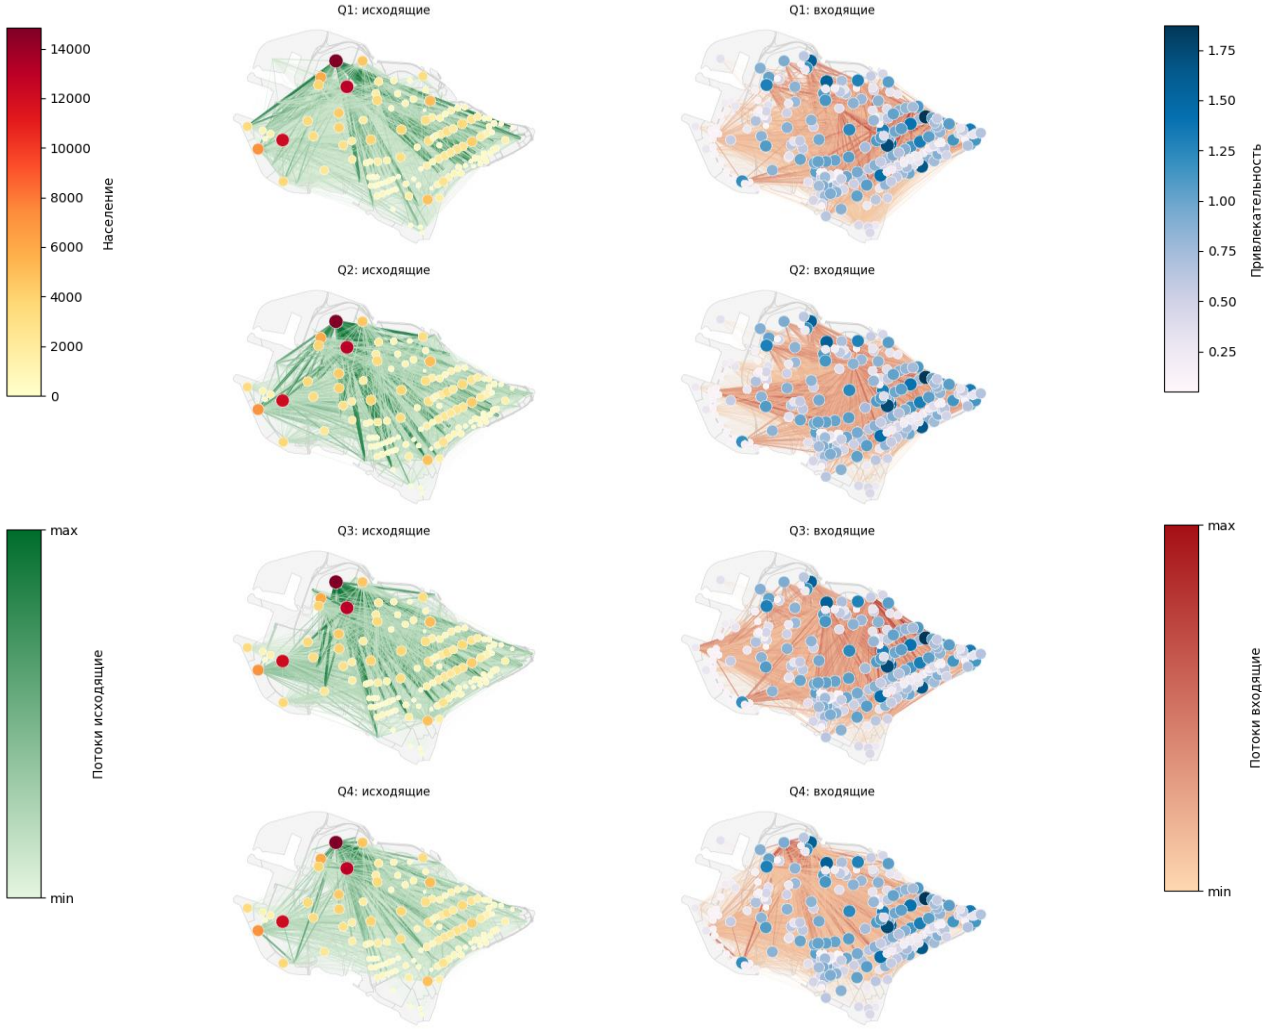

Рисунок 3 – Потоки по матрице между кварталами исследуемой территории
Источник: составлено авторами

Рисунок 4 – Потоки между кварталами, распределенные по улично-дорожной сети
Источник: составлено авторами

Для каждого квартала были вычислены значения спроса и привлекательности на основе данных по городским сервисам. В результате применения метода на предобработанных данных о кварталах и дорогах, была получена матрица корреспонденций, отражающая относительный объем потока перемещений между каждой парой кварталов.

Далее каждой из дорог на графе улично-дорожной сети были сопоставлены веса, соответствующие значению её загруженности. На Рисунке 5 обозначены дороги с весами.

Рисунок 5 – Востребованность дорог по матрице
Источник: составлено авторами

Результаты эксперимента. В качестве эксперимента метод был апробирован на территории Васильевского острова, Санкт-Петербург, Россия. Исходные данные о геометриях и улично-дорожной сети, о населении и городских сервисах взяты с открытого картографического источника OpenStreetMap (OSM) [36].

Кварталы исследуемой территории были получены с помощью библиотеки BlocksNet методом нарезки исходных геометрий линейными объектами улично-дорожной сети, железнодорожной сети и водными объектами [37].

В полученные кварталы были добавлены городские сервисы, разделенные на восемь групп (Рисунок 6а): размещение (Accommodation & Personal Services), образование и культура (Education & Culture), продовольствие и торговля (Food & Retail), здоровье (Health), государственные услуги и инфраструктура (Public Services & Infrastructure), рекреация и спорт (Recreation & Sport), религия (Religion), транспорт (Transportation).

В графе улично-дорожной сети, помимо информации о геометриях дорог, также есть информация о названии улиц и максимально разрешенной скорости на участках.

Для изучения работы метода при изменяющихся данных был проведен аналогичный эксперимент в условиях повышения населения одного из районов. Для этого в одном из кварталов был увеличен параметр населения в десять раз, а также были добавлены несколько сервисов: три кафе, один музей, четыре пекарни и два ресторана (Рисунок 6а). На обновленных кварталах была пересобрана матрица корреспонденций и заново построены маршруты между каждой парой кварталов с суммированием объемов перемещений (Рисунок 6б).

а) б)

Рисунок 6 – Измененная востребованность дорог: а – выбранный квартал с внесенными изменениями выделен красным цветом, б – измененные потоки по УДС

Источник: составлено авторами

Также был проведен эксперимент по изучению работы метода в сценарии добавления новых участков улично-дорожной сети для выявления изменений в загруженности. Апробация проводилась на данных по территориям Василеостровского и Петроградского административных районов. На рисунках 7а и 7б представлена востребованность дорог по матрице корреспонденций между кварталами двух районов. Чтобы оценить последствия перераспределения потоков была вычислена дельта для существующих ребер (Рисунок 8). Отрицательные значения показывают участки, где востребованность снизилась; положительные – где значения выросли; значения вокруг нуля означают, что изменения практически нет. Черным цветом отмечены добавленные дороги.

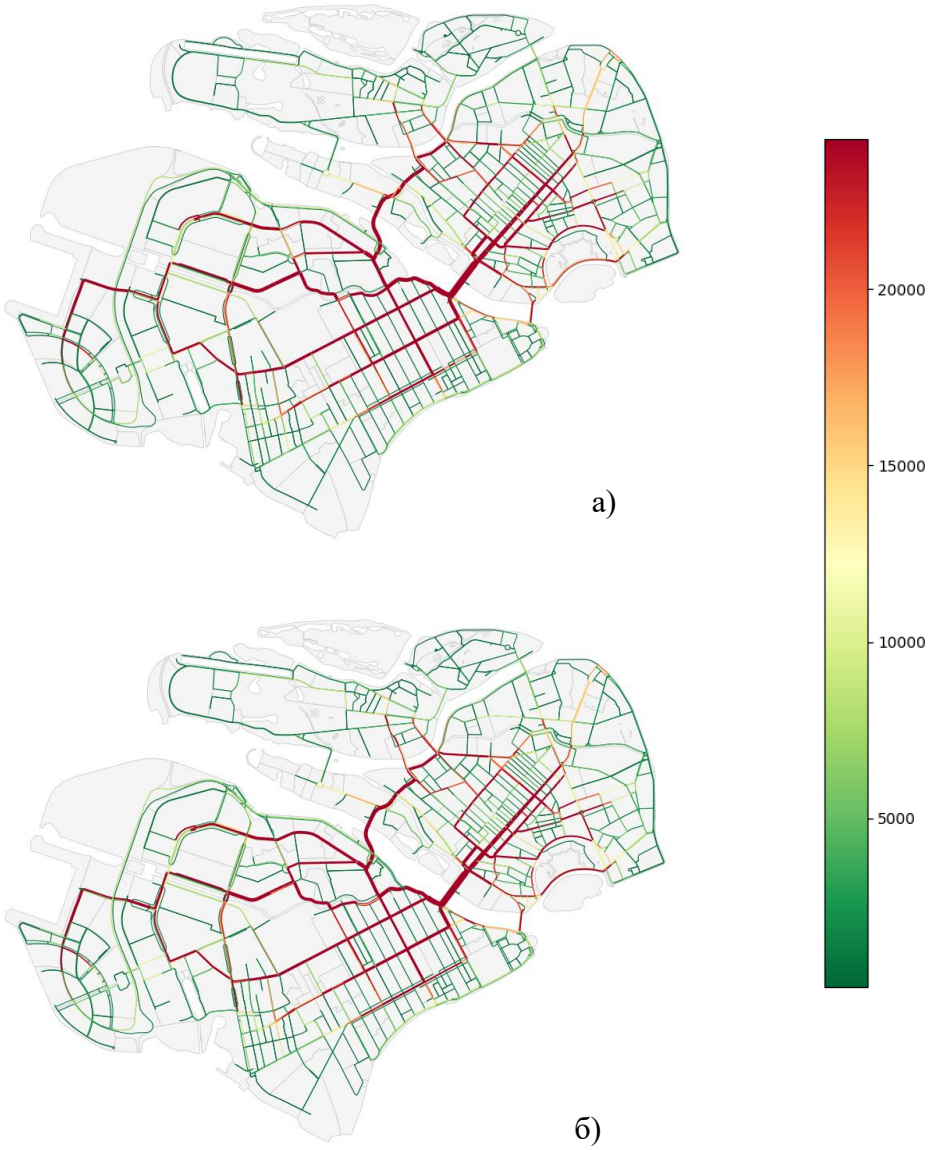

Рисунок 7 – Востребованность дорог в сценарии добавления новых элементов в существующую УДС: а – востребованность по существующим дорогам, б – измененная востребованность с учетом новой дороги

Источник: составлено авторами

Заключение. В данной работе был представлен подход к оценке востребованности дорог с помощью моделирования матрицы корреспонденций на основе свойств кварталов и типов землепользования, который предполагается рассматривать как альтернативу к оценке и прогнозированию загруженности дорог в условиях отсутствия необходимых исторически накопленных данных о дорожных потоках. Такой подход учитывает взаимодействие части транспортной системы (дорог) и типов землепользования. Предлагаемый в работе подход требует сбора исходных данных об услугах и сервисах внутри кварталов, но, так как он происходит на основе открытых источников, этот этап может быть практически полностью автоматизирован. Это может значительно повысить простоту практического применения разработанного подхода. Следует отметить, что традиционные методы оценки загруженности, расчёт интенсивности по данным датчиков, использование четырехступенчатой модели транспортного планирования либо временных рядов, требуют наличия наблюдаемых транспортных потоков. В рассматриваемом случае

Рисунок 8 – Дельта Δ востребованности участков улично-дорожной сети
Источник: составлено авторами

такие данные отсутствуют, что делает прямое количественное сравнение невозможным.

Данный метод может быть использован при проектировании новых районов или при рекультивации существующих участков. В таком случае в качестве необходимых данных будут выступать количество жилья и его вместимость, проектируемая улично-дорожная сеть будущего района, а также информация о планируемых к размещению городских сервисах. В качестве недостатка этого метода можно выделить потенциальную неточность, так как маршруты между каждой парой кварталов, которые строятся по матрице, являются кратчайшими по значению весов в графе улично-дорожной сети (длина участка УДС в километрах).

В рамках дальнейших исследований планируется совместить предложенный подход с методами графовых нейронных сетей для дальнейшего обучения модели на данных других городов. Комбинированный подход позволит учитывать топологические характеристики улично-дорожной сети.

Список источников

1. Берман Н. Д. Влияние транспортной инфраструктуры на устойчивое развитие: тенденции и проблемы // Международный журнал перспективных исследований. – 2020. – Т. 10. – № 2. – С. 7–14. – DOI: 10.12731/2227-930X-220-2-7-14.
2. Kumar S. V. et al. Location-Based Data for Estimated Traffic on Urban Arterial in Heterogeneous Traffic Conditions // Transportation Research Record: Journal of the Transportation Research. – 2011. – Vol. 2239. – P. 16–22. – DOI: 10.3141/2239-03. – Текст: электронный. (In Eng.).
3. Li F. et al. Identification of Critical Links in a Large-Scale Road Network Considering the Traffic Flow Betweenness Index // PLoS One. Public Library of Science. –

References

1. Berman N. D. The Impact of Transport Infrastructure on Sustainable Development: Trends and Problems. *Mezhdunarodnyy zhurnal perspektivnykh issledovaniy.* 2020. Vol. 10. No. 2. pp. 7–14.DOI:10.12731/2227-930X-220-2-7-14.(In Russ.).
2. Kumar S. V. et al. Location-Based Data for Estimated Traffic on Urban Arterial in Heterogeneous Traffic Conditions. *Transportation Research Record: Journal of the Transportation Research*. 2011. Vol. 2239. pp. 16–22. DOI: 10.3141/2239-03.

3. Li F. et al. Identification of Critical Links in a Large-Scale Road Network Considering the Traffic Flow Betweenness Index. *PloS One. Public Library of Science.*

2020. – Vol. 15. – No. 4. – P. e0227474. – DOI: 10.1371/journal.pone.0227474. – Текст: электронный. (In Eng.).
4. Цветков В. Я. Интеллектуальные транспортные системы / В. Я. Цветков, И. Н. Розенберг. – Saarbrücken: LAP LAMBERT, 2012. – 297 с.
5. СП 42.13330.2016 «СНиП 2.07.01-89* Градостроительство. Планировка и застройка городских и сельских поселений» (Приказ Минстроя России от 30 декабря 2016 г. № 1034/пр) | Минстрой России // Электронный фонд правовых и нормативно-технических документов [Электронный ресурс]. – URL: https://docs.cntd.ru/document/ 456054209 (дата обращения: 11.04.2025). – Текст: электронный.
6. Diao Z. et al. A Hybrid Model for Short-Term Traffic Volume Prediction in Massive Transportation Systems // IEEE Transactions on Intelligent Transportation Systems. Institute of Electrical and Electronics Engineers Inc. – 2019. – Vol. 20. – No. 3. – P. 935–946. (In Eng.).
7. He Y. et al. In-Depth Insights into the Application of Recurrent Neural Networks (RNNs) in Traffic Prediction: A Comprehensive Review // Algorithms. – 2024. – Vol. 17. – No. 9. – P. 398. – DOI: 10.3390/a17090398. – Текст: Электронный. (In Eng.).
8. Shaik M.E., Islam M.M., Hossain Q.S. A Review on Neural Network Techniques for the Prediction of Road Traffic Accident Severity // Asian Transport Studies. – 2021. – Vol. 7. – No. 2. – P. 100040. – DOI: 10.1016/ j.eastsj.2021.100040. – Текст: Электронный. (In Eng.).
9. Как работают Яндекс.Пробки [Электронный ресурс]. – URL: https://yandex.ru/company/technologies/yaprobki/ (дата обращения: 11.04.2025). – Текст: Электронный.
10. Ge L. et al. Review of Transit Data Sources: Potentials, Challenges and Complementarity // Sustainability. – 2021. – Vol. 13. – No. 20. – P. 11450. – DOI: 10.3390/ su132011450. – Текст: Электронный.
11. Lu K. et al. A Review of Big Data Applications in Urban Transit Systems // IEEE Transactions on Intelligent Transportation Systems. Institute of Electrical and Electronics Engineers Inc. – 2021. – Vol. 22. – No. 5. – P. 2535–2552. (In Eng.).
12. Jayasinghe A., Sano K., Rattanaporn K. Application for Developing Countries: Estimating Trip Attraction in Urban Zones Based on Centrality // Journal of Traffic and Transportation Engineering. – 2017. – Vol. 4. – No. 5. – P. 464–476. (In Eng.).
13. Verma A., Ramanayya T. V. Public Transport Planning and Management in Developing Countries. – Boca Raton: CRC press, 2014. – DOI: 10.1201/b17891. – Текст: электронный. (In Eng.).
14. Покусаев О., Намиот Д., Чекмарев А. Об управлении трафиком в умном городе // International Journal of Open Information Technologies. Лаборатория Открытых Информационных Технологий факультета ВМК МГУ им. М. В. Ломоносова. – 2021.– Т. 9. – № 5.
15. Lim J. et al. Enhancing Real-Time Traffic Volume Prediction: A Two-Step Approach of Object Detection and Time Series Modelling // IET Intelligent Transport Systems. – 2024. – Vol. 18. – No. 12. P. 2744–2758. – DOI: 10.1049/itr2.12576. – Текст: электронный. (In Eng.).

2020. Vol. 15. No. 4. P. e0227474. DOI: 10.1371/journal.pone.0227474.

4. Tsvetkov V. Ya., Rosenberg I. N.. Intelligent Transport Systems. *Saarbrücken: LAP LAMBERT*, 2012. 297 p. (In Russ.).
5. SP 42.13330.2016 «SniP 2.07.01-89* Urban development. Planning and development of urban and rural settlements» (Order of the Ministry of Construction of Russia dated December 30, 2016 No. 1034/pr). Ministry of Construction of Russia. *Elektronnyy fond pra-vovykh I normativno-tekhnicheskikh dokumentov.* Available at: https://docs.cntd.ru/document/456054209 (Accessed: 11.04.2025). (In Russ.).
6. Diao Z. et al. A Hybrid Model for Short-Term Traffic Volume Prediction in Massive Transportation Systems. *IEEE Transactions on Intelligent Transportation Systems. Institute of Electrical and Electronics Engineers Inc*. 2019. Vol. 20. No. 3. pp. 935–946.
7. He Y. et al. In-Depth Insights into the Application of Recurrent Neural Networks (RNNs) in Traffic Prediction: A Comprehensive Review. *Algorithms.* 2024. Vol. 17. No. 9. P. 398. DOI: 10.3390/ a17090398.

8. Shaik M.E., Islam M.M., Hossain Q.S. A Review on Neural Network Techniques for the Prediction of Road Traffic Accident Severity. *Asian Transport Studies*. 2021. Vol. 7. No. 2. P. 100040. DOI: 10.1016/j.eastsj. 2021.100040.
9. How Yandex.Traffic Works. Available at: https://yandex.ru/company/technologies/yaprobki/ (Accessed: 11.04.2025). (In Russ.).

10. Ge L. et al. Review of Transit Data Sources: Potentials, Challenges and Complementarity. *Sustainability*. 2021. Vol. 13. No. 20. P. 11450. DOI: 10.3390/su132011450.

11. Lu K. et al. A Review of Big Data Applications in Urban Transit Systems. *IEEE Transactions on Intelligent Transportation Systems. Institute of Electrical and Electronics Engineers Inc*. 2021. Vol. 22. No. 5. pp. 2535–2552.
12. Jayasinghe A., Sano K., Rattanaporn K. Application for Developing Countries: Estimating Trip Attraction in Urban Zones Based on Centrality. *Journal of Traffic and Transportation Engineering*. 2017. Vol. 4. No. 5. pp. 464–476.
13. Verma A., Ramanayya T. V. Public Transport Planning and Management in Developing Countries. *Boca Raton: CRC press*. 2014. DOI: 10.1201/b17891.

14. Pokusaev O., Namiot D., Chekmarev A. On Traffic Management in a Smart City. *International Journal of Open Information Technologies. Laboratory of Open Information Technologies of the Faculty of Mechanical Engineering of Lomonosov Moscow State University*. 2021. Vol. 9. No. 5. (In Russ.).
15. Lim J. et al. Enhancing Real-Time Traffic Volume Prediction: A Two-Step Approach of Object Detection and Time Series Modelling. *IET Intelligent Transport Systems*. 2024. Vol. 18. No. 12. pp. 2744–2758. – DOI: 10.1049/itr2.12576.

16. Twum E., Asa E., Awuku B. Estimation of Annual Average Daily Traffic (AADT) Data for Low-Volume Roads: A Systematic Literature Review and Meta-Analysis // Emerald Open Research. – 2022. – DOI: 10.35241/emeraldopenres.14515.1. – Текст: электронный. (In Eng.).
17. Pun L., Zhao P., Liu X. A Multiple Regression Approach for Traffic Flow Estimation // IEEE Access. Institute of Electrical and Electronics Engineers Inc. – 2019. – Vol. 7. – P. 35998–36009. (In Eng.).
18. Lowry M. et al. GIS Tools to Estimate Average Annual Daily Traffic. National Institute for Advanced Transportation Technology (NIATT) (US). – 2012. – URL: https://rosap.ntl.bts.gov/view/dot/ 24942 (дата обращения: 11.04.2025). – Текст: электронный. (In Eng.).
19. Пупырев С., Пронченков А. Прогнозирование загруженности автомобильных дорог // Труды Четвертой Российской конференции молодых ученых по информационному поиску. – Воронеж: Издательско-полиграфический центр ВорГУ, 2010. – P. 64–78.
20. Zaki J. F. et al. Framework for Traffic Congestion Prediction // International Journal of Scientific Engineering Research.–2016.–Vol.7.– No.5. – P. 1205–1210. (In Eng.).
21. Jiang W., Luo J. Graph Neural Network for Traffic Forecasting: A Survey // Expert Syst Appl. Pergamon. – 2022. – Vol. 207. – P. 117921. (In Eng.).
22. Sharma A. et al. A Graph Neural Network (GNN)-Based Approach for Real-Time Estimation of Traffic Speed in Sustainable Smart Cities // Sustainability. – 2023. – Vol. 15. – No. 15. – P. 11893. (In Eng.).
23. Zhao L. et al. T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction // IEEE Transactions on Intelligent Transportation Systems. Institute of Electrical and Electronics Engineers Inc. – 2020. – Vol. 21. – No. 9. – P. 3848–3858. (In Eng.).
24. Reza S. et al. A Multi-Head Attention-Based Transformer Model for Traffic Flow Forecasting with a Comparative Analysis to Recurrent Neural Networks // Expert Syst Appl. Pergamon. – 2022. – Vol.202. – P. 117275. (In Eng.).
25. Attioui M., Lahby M. A. Systematic Literature Review of Traffic Congestion Forecasting: From Machine Learning Techniques to Large Language Models // Vehicles. – 2025. – Vol. 7. – P. 142. (In Eng.).
26. Su J. et al. Large Language Models for Forecasting and Anomaly Detection: A Systematic Literature Review. – 2024. – URL: https://doi.org/10.48550/arXiv.2402.10350 (дата обращения: 07.04.2025). – Текст: электронный. (In Eng.).
27. Liu C. et al. Spatial-Temporal Large Language Model for Traffic Prediction // Proceedings IEEE International Conference on Mobile Data Management. Institute of Electrical and Electronics Engineers Inc., 2024. P. 31–40. (In Eng.).
28. Qiu H. et al. Topological Graph Convolutional Network-Based Urban Traffic Flow and Density Prediction // IEEE Transactions on Intelligent Transportation Systems. Institute of Electrical and Electronics Engineers Inc. – 2021. – Vol. 22. – No. 7. – P. 4560–4569. (In Eng.).
29. Henry E. et al. Spatio-Temporal Correlations of Betweenness Centrality and Traffic Metrics // 6th International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS). – 2019. – P. 1–10. – URL: https://ieeexplore.ieee.org/abstract/document/888

16. Twum E., Asa E., Awuku B. Estimation of Annual Average Daily Traffic (AADT) Data for Low-Volume Roads: A Systematic Literature Review and Meta-Analysis. *Emerald Open Research*. 2022. DOI: 10.35241/emeraldopenres.14515.1.
17. Pun L., Zhao P., Liu X. A Multiple Regression Approach for Traffic Flow Estimation. *IEEE Access. Institute of Electrical and Electronics Engineers Inc*. 2019. Vol. 7. P. 35998–36009.
18. Lowry M. et al. GIS Tools to Estimate Average Annual Daily Traffic. National Institute for Advanced Transportation Technology (NIATT) (US). 2012. Available at: https://rosap.ntl.bts.gov/view/dot/ 24942 (Accessed: 11.04.2025).
19. Pupyrev S., Pronchenkov A. Forecasting Road Congestion. *Proceedings of the Fourth Russian Conference of Young Scientists on Information Retrieval. Voronezh: Publishing and Printing Center of Voronezh State University*. 2010. pp. 64–78. (In Russ.).
20. Zaki J. F. et al. Framework for Traffic Congestion Prediction. *International Journal of Scientific Engineering Research*. 2016. Vol. 7. No. 5. pp. 1205–1210.
21. Jiang W., Luo J. Graph Neural Network for Traffic Forecasting: A Survey. *Expert Syst Appl. Pergamon*. 2022. Vol. 207. P. 117921.
22. Sharma A. et al. A Graph Neural Network (GNN)-Based Approach for Real-Time Estimation of Traffic Speed in Sustainable Smart Cities. *Sustainability*. 2023. Vol. 15. No. 15. P. 11893.
23. Zhao L. et al. T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction. *IEEE Transactions on Intelligent Transportation Systems. Institute of Electrical and Electronics Engineers Inc*. 2020. Vol. 21. No. 9. P. 3848–3858.
24. Reza S. et al. A Multi-Head Attention-Based Transformer Model for Traffic Flow Forecasting with a Comparative Analysis to Recurrent Neural Networks. *Expert Syst Appl. Pergamon*. 2022. Vol. 202. P. 117275.
25. Attioui M., Lahby M. A. Systematic Literature Review of Traffic Congestion Forecasting: From Machine Learning Techniques to Large Language Models. *Vehicles*. 2025. Vol. 7. P. 142.
26. Su J. et al. Large Language Models for Forecasting and Anomaly Detection: A Systematic Literature Review. 2024. Available at: https://doi.org/10.48550/arXiv.2402.10350 (Accessed: 07.04.2025).
27. Liu C. et al. Spatial-Temporal Large Language Model for Traffic Prediction. *Proceedings IEEE International Conference on Mobile Data Management. Institute of Electrical and Electronics Engineers Inc*. 2024. pp. 31–40.
28. Qiu H. et al. Topological Graph Convolutional Network-Based Urban Traffic Flow and Density Prediction. *IEEE Transactions on Intelligent Transportation Systems. Institute of Electrical and Electronics Engineers Inc*. 2021. Vol. 22. No. 7. pp. 4560–4569.
29. Henry E. et al. Spatio-Temporal Correlations of Betweenness Centrality and Traffic Metrics. *6th International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS)*. 2019. – P. 1–10. – URL:

3379 (дата обращения: 07.04.2025). – Текст: электронный (In Eng.).
30. Cervero R., Kockelman K. Travel Demand and the 3Ds: Density, Diversity, and Design // Transp Res D Transp Environ. Pergamon. – 1997. – Vol. 2. – No. 3. – P. 199–219. (In Eng.).
31. Ewing R., Cervero R. Travel and the Built Environment // Journal of the American Planning Association. Taylor & Francis Group. – 2010. – Vol. 76. – No. 3. – P. 265–294. (In Eng.).
32. Acharya K. et al. A Data-Driven Approach to Enhancing Gravity Models for Trip Demand Prediction // Proceedings 2025 IEEE Conference on Artificial Intelligence, CAI 2025. Institute of Electrical and Electronics Engineers Inc. – 2025. – P. 815–820. (In Eng.).
33. Jacobs-Crisioni C. et al. Evaluating the Impact of Land-Use Density and Mix On Spatiotemporal Urban Activity Patterns: An Exploratory Study Using Mobile Phone Data // Environ Plan A. SAGE Publications Ltd. – 2014. – Vol. 46. No. 11. – P. 2769–2785. (In Eng.).
34. BlocksNet – Open Library with Tools for Generation the City Model and Optimal Requirements for Future Development with Specified Target Parameters [Электронный ресурс]. – URL: https://githubcom/aimclub/blocksnet (дата обращения: 07.04.2025). – Текст: электронный. (In Eng.).
35. GitHub – IduEdu: Creation and Manipulation of City Networks from OpenStreetMap [Электронный ресурс] – URL: https://github.com/DDonnyy/Idu Edu (дата обращения: 07.04.2025). – Текст: электронный. (In Eng.).
36. OpenStreetMap [Электронный ресурс]. – URL: https://www.openstreetmap.org (дата обращения: 07.04.2025). – Текст: электронный. (In Eng.).
37. Kontsevik G. I. et al. Urban Blocks Modelling Method // Procedia Comput Sci. – 2023. – Vol. 229. – P. 119–127. (In Eng.).

https://ieeexplore.ieee.org/abstract/document/8883379 (Accessed: 07.04.2025).
30. Cervero R., Kockelman K. Travel Demand and the 3Ds: Density, Diversity, and Design. *Transp Res D Transp Environ. Pergamon*. 1997. Vol. 2. No. 3. P. 199–219.

31. Ewing R., Cervero R. Travel and the Built Environment. *Journal of the American Planning Association. Taylor & Francis Group*. 2010. Vol. 76. No. 3. P. 265–294.
32. Acharya K. et al. A Data-Driven Approach to Enhancing Gravity Models for Trip Demand Prediction. *Proceedings 2025 IEEE Conference on Artificial Intelligence, CAI 2025. Institute of Electrical and Electronics Engineers Inc*. 2025. pp. 815–820.
33. Jacobs-Crisioni C. et al. Evaluating the Impact of Land-Use Density and Mix On Spatiotemporal Urban Activity Patterns: An Exploratory Study Using Mobile Phone Data. *Environ Plan A. SAGE Publications Ltd*. 2014. Vol. 46. No. 11. pp. 2769–2785.
34. BlocksNet – Open Library with Tools for Gen-eration the City Model and Optimal Requirements for Future Development with Specified Target Parameters. Available at: https://github.com/aimclub/blocksnet (Accessed: 07.04.2025).

35. GitHub – IduEdu: Creation and Manipulation of City Networks from OpenStreetMap. Available at: https://github.com/DDonnyy/IduEdu (Accessed: 07.04.2025).
36. OpenStreetMap Available at: https://www.openstreetmap.org (Accessed: 07.04.2025).

37. Kontsevik G. I. et al. Urban Blocks Modelling Method. *Procedia Comput Sci.* 2023. Vol. 229. pp. 119–127.

Статья поступила в редакцию 31.10.2025; одобрена после рецензирования 05.12.2025; принята к публикации 12.12.2025.
The article was submitted 31.10.2025; approved after reviewing 05.12.2025; accepted for publication 12.12.2025.