

МНОВИДОВАЯ ПРОСТРАНСТВЕННО-ВРЕМЕННАЯ СВЕРТКА ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ ПРОГНОЗИРОВАНИЯ ТРАНСПОРТНЫХ ПОТОКОВ

Пугачев Игорь Николаевич,
Хабаровский Федеральный исследовательский центр
Дальневосточного отделения Российской академии наук
(ХФИЦ ДВО РАН), г. Хабаровск, Россия, ipugachev64@mail.ru

Тормозов Владимир Сергеевич,
Тихоокеанский государственный университет" (ТОГУ)
г. Хабаровск, Россия, 007465@pnu.edu.ru

Евтюков Станислав Сергеевич,
Санкт-Петербургский государственный архитектурно-
строительный университет, г. Санкт-Петербург, Россия,
tm@spbgasu.ru

Смокталь Николай Николаевич,
Севастопольский государственный университет,
г. Севастополь, Россия, nnsmoktal@sevsu.ru

Золкин Александр Леонидович,
Поволжский государственный университет телекоммуникаций
и информатики" (ПГУТИ), г. Самара, Россия, nnsmoktal@sevsu.ru

DOI: 10.36724/2072-8735-2025-19-2-31-37

Manuscript received 15 December 2024;
Accepted 25 January 2025

Работа выполнена при поддержке Минобрнауки
РФ, дополнительное соглашение от
21.04.2020 № 075-02-2020-152911

Ключевые слова: прогнозирование
транспортного потока, глубокое обучение,
машинное обучение, графовые нейронные сети

Быстрое развитие информационных технологий значительно повысило важность прогнозирования множественных временных рядов, особенно в контексте анализа транспортных потоков, для эффективной обработки больших объемов данных. Прогнозирование транспортных потоков является ключевым элементом интеллектуальных транспортных систем (ИТС), предоставляя ценные научные и практические данные для планирования городского движения, улучшения качества и эффективности как логистического транспорта, так и общественных транспортных стратегий. В рамках интеллектуальных транспортных систем прогнозирование транспортных потоков остается одной из наиболее значимых задач. Однако, из-за сложных временных и пространственных зависимостей, свойственных последовательностям транспортных потоков, создание точных моделей прогнозирования с использованием кольцевых нейронных сетей, графовых сетей и моделей трансформеров сталкивается с серьезными трудностями. Для преодоления этих проблем и использования преимуществ сверточных сетей, которые известны своей высокой вычислительной эффективностью и надежностью в извлечении признаков, предлагается новая модель прогно-

зирования транспортных потоков, основанная на многовидовой пространственно-временной свертке. Эта модель представляет собой инновационный подход к анализу и прогнозированию транспортных потоков, который сочетает в себе преимущества сверточных сетей с возможностями пространственно-временной свертки. Многовидовая свертка позволяет учитывать различные аспекты транспортных потоков, такие как временные зависимости, пространственные характеристики и взаимодействия между различными видами транспорта. Это делает модель более гибкой и адаптивной к разнообразным условиям и изменениям в транспортной инфраструктуре. Применение многовидовой пространственно-временной свертки в модели прогнозирования транспортных потоков позволяет значительно улучшить точность и надежность прогнозов, что, в свою очередь, способствует более эффективному управлению городским движением и оптимизации транспортных систем. Внедрение этой модели может привести к значительным улучшениям в области логистики, общественного транспорта и общей транспортной инфраструктуры, что сделает города более удобными и эффективными для жителей и гостей.

Информация об авторах:

Пугачев Игорь Николаевич, Хабаровский Федеральный исследовательский центр Дальневосточного отделения Российской академии наук (ХФИЦ ДВО РАН), заместитель директора по научной работе ХФИЦ ДВО РАН, д.т.н., г. Хабаровск, Россия

Тормозов Владимир Сергеевич, ФГБОУ ВО "Тихоокеанский государственный университет" (ТОГУ), доцент высшей школы кибернетики и цифровых технологий к.т.н., г. Хабаровск, Россия

Евтюков Станислав Сергеевич, Санкт-Петербургский государственный архитектурно-строительный университет, Автомобильно-дорожный факультет, заведующий кафедрой транспортных систем, д.т.н., доцент, г. Санкт-Петербург, Россия

Смокталь Николай Николаевич, ФГАОУ ВО "Севастопольский государственный университет", старший преподаватель кафедры "Энергетические системы и комплексы традиционных и возобновляемых источников", г. Севастополь, Россия

Золкин Александр Леонидович, ФГБОУ ВО "Поволжский государственный университет телекоммуникаций и информатики" (ПГУТИ), доцент кафедры "Информатика и вычислительная техника", к.т.н., г. Самара, Россия

Для цитирования:

Пугачев И.Н., Тормозов В.С., Евтюков С.С., Смокталь Н.Н., Золкин А.Л. Многовидовая пространственно-временная свертка для повышения точности прогнозирования транспортных потоков // T-Comm: Телекоммуникации и транспорт. 2025. Том 19. №2. С. 31-37.

For citation:

I. N. Pugachev, V. S. Tormozov, S. S. Evtukov, N. N. Smoktal, A. L. Zolkin, "Multi-view spatial-temporal convolution to improve the accuracy of traffic flow forecasting," T-Comm, 2025, vol. 19, no.2 pp. 31-37. (in Russian)

Введение

С ускорением развития информационных технологий, прогнозирование транспортных потоков стало критически важным для анализа больших данных. Как фундамент интеллектуальной транспортной системы, оно имеет значительное научное и практическое значение для планирования городского движения, улучшения качества и эффективности логистики и общественного транспорта. Однако, извлечение пространственно-временных признаков из сложных многомерных данных о транспортных потоках и реализация комплексного прогнозирования от начала до конца остается исследовательской задачей. Основная проблема прогнозирования транспортных потоков заключается в сложной связи между многомерными данными и извлечении постоянно меняющихся пространственно-временных признаков.

Традиционные статистические методы и классические методы машинного обучения, такие как локальная регрессия и фильтр Калмана, подходят для прогнозирования одиночных последовательностей, но не могут эффективно обрабатывать сложные многомерные данные. Новые методы, такие как сверточные нейронные сети (CNN), рекуррентные нейронные сети (RNN) и автоматические кодировщики, достигли более точного извлечения признаков временных рядов. Графовая сверточная сеть (GCN) извлекает уникальные пространственные признаки данных о транспортных потоках, используя сверточную операцию над графами. Многослойные модели, которые извлекают пространственные и временные признаки одновременно, постоянно обновляют лучшие результаты прогнозирования транспортных потоков.

В последнее время методы, основанные на представлении графов и свертке графов, достигли заметного прогресса в прогнозировании многомерных временных рядов. Глубокие модели обучения, такие как CNN и RNN, эффективно захватывают признаки на евклидовых данных, но требуют адаптации для применения к графовым данным, что привело к развитию GCN. Операции свертки графов включают пространственную свертку графов и свертку графов в спектральной области.

Прогнозирование транспортных потоков имеет важное значение для планирования городской инфраструктуры: строительство дорог, мостов и транспортных узлов. Точное прогнозирование транспортных потоков может помочь городским планировщикам принимать обоснованные решения о развитии инфраструктуры, что может привести к уменьшению пробок, улучшению безопасности дорожного движения и снижению уровня загрязнения воздуха.

Более того, прогнозирование транспортных потоков может быть использовано для оптимизации маршрутов общественного транспорта, что может привести к уменьшению времени в пути и улучшению качества обслуживания пассажиров, а также для мониторинга и управления транспортными потоками в реальном времени, что может помочь в предотвращении пробок и улучшении безопасности дорожного движения.

В целом, прогнозирование транспортных потоков является важной задачей, которая требует разработки новых методов и алгоритмов для эффективного извлечения пространственно-временных признаков из сложных многомерных данных. Развитие методов, основанных на представлении

графов и свертке графов, может помочь в решении этой задачи и привести к улучшению качества и эффективности транспортных систем.

Подготовка и установка зависимостей

На основе проанализированных источников можно сделать вывод, что многовидовая пространственно-временная свертка широко используется в прогнозировании транспортных потоков. Исследования, рассмотренные в статье, демонстрируют эффективность этого подхода в захвате сложных пространственных и временных зависимостей в транспортных данных.

Использование многовидовой пространственно-временной свертки для прогнозирования транспортных потоков было впервые предложено в [1], где авторы предложили новую модель, которая объединяет сверточные нейронные сети (CNN) и графовые сверточные сети (GCN) для захвата как пространственных, так и временных зависимостей в транспортных данных. Этот подход был показан более точным и эффективным по сравнению с традиционными методами.

Последующие исследования развили это направление, исследуя использование многовидовой пространственно-временной свертки в различных приложениях прогнозирования транспортных потоков. Например, [2] использовали многовидовую пространственно-временную сверточную сеть для прогнозирования транспортных потоков на автомагистралях, достигнув высокой точности и устойчивости. Аналогично, [3] применили этот подход к прогнозированию транспортных потоков в городских условиях, демонстрируя его эффективность в захвате сложных пространственных и временных паттернов.

Другие исследования были сосредоточены на улучшении производительности многовидовых пространственно-временных сверточных сетей для прогнозирования транспортных потоков. Например, [4] предложили новый механизм внимания для селективного фокусирования на соответствующих пространственных и временных признаках, что привело к улучшению точности прогнозирования. Между тем, [5] разработали подход к трансферному обучению для адаптации многовидовых пространственно-временных сверточных сетей к новым транспортным сценариям, уменьшив потребность в обширном повторном обучении.

Использование многовидовой пространственно-временной свертки также было исследовано в других связанных областях, таких как прогнозирование транспортного спроса [6] и обнаружение транспортных инцидентов [7]. Эти исследования демонстрируют универсальность и эффективность этого подхода в захвате сложных пространственных и временных зависимостей в транспортных данных.

Кроме того, [8] предоставили всесторонний обзор методов глубокого обучения для прогнозирования транспортных потоков, включая многовидовую пространственно-временную свертку. Этот обзор подчеркнул сильные и слабые стороны этих подходов и предоставил руководство для будущих исследований.

Наконец, [9] предложили новый фреймворк для интеграции многовидовой пространственно-временной свертки с другими машинными алгоритмами, такими как графовые нейронные

сети и обучение с подкреплением, для создания более полной системы прогнозирования транспортных потоков.

В целом, обзорные исследования демонстрируют эффективность многовидовой пространственно-временной свертки в прогнозировании транспортных потоков и подчеркивают ее потенциал для дальнейшего развития и применения в этой области [10].

Динамическое представление гиперграфа данных о транспортном потоке

Прогнозирование транспортного потока (ТП) – сложная задача с пространственно-временной зависимостью. Прогнозирование ТП всегда было одной из самых сложных задач в области транспортной инфраструктуры. Это связано с тем, что поток транспорта зависит от двух основных факторов: пространственной и временной зависимостей.

Пространственная зависимость ТП означает, что изменение его объема напрямую зависит от топологии городской улично-дорожной сети (УДС). Условия ТП на верхних дорогах влияют на условия на нижних дорогах через эффект переноса. Через эффект обратной связи состояние ТП на нижних дорогах, в свою очередь, влияет на условия потока на верхних дорогах. Это означает, что поток на одной дороге может влиять на поток соседних дорог, таким образом порождая сложную систему взаимосвязей.

Временная зависимость ТП означает, что объем потока динамически изменяется со временем, что в основном проявляется в периодичности и тренде. Это означает, что поток может изменяться в зависимости от времени суток, дня недели, месяца и года. Например, поток может быть более интенсивным в часы пик, а также в дни праздников и выходных. Кроме того, временная зависимость потока может быть связана с другими факторами, такими как погода, дорожные работы, особые события и т.д. Это означает, что прогнозирование ТП должно учитывать не только пространственную зависимость, но и временную зависимость, чтобы обеспечить точное и надежное прогнозирование.

Дополнительные факторы, влияющие на состояние ТП:

- погодные условия: дождь, снег, жара и др.;
- дорожные работы: ремонт дорог, строительство новых дорог и др.;
- особые события: спортивные мероприятия, концерты, фестивали и др.;
- часы пик и дни недели, месяцы года.

Прогнозирование транспортных потоков является сложной задачей, для решения которой необходимо учитывать, как пространственную, так и временную зависимости. Для решения этой задачи используются различные методы и модели, которые могут помочь обеспечить точное и надежное прогнозирование. Это может помочь улучшить управление потоками на УДС, уменьшить пробки и повысить безопасность на дорогах.

Построение модели потока транспортных потоков с помощью графовой нейронной сети и воротной циклической единицы

В современном мире управление и прогнозирование характеристик транспортных потоков становятся все более

актуальными задачами. Для их решения предлагается использовать графовую нейронную сеть (GCN) и воротную циклическую единицу (GRU).

Графовая нейронная сеть (GCN) представляет собой мощный инструмент для моделирования сложных систем, таких как дорожная сеть. Она позволяет учитывать топологию дорожной сети, что критически важно для прогнозирования. GCN может учитывать различные факторы, такие как интенсивность, время суток, день недели и другие. Воротная циклическая единица (GRU) является важным компонентом, который позволяет захватывать динамическое изменение данных на дороге и моделировать временную зависимость. GRU может учитывать различные факторы, такие как погода, дорожные работы, специальные события и другие. Комбинация GCN и GRU позволяет создать мощную модель, способную прогнозировать потоки транспорта с высокой точностью. Модель T-GCN, предложенная в этой статье, может не только реализовывать краткосрочное прогнозирование, но и использоваться для долгосрочных задач.

Результаты прогнозирования модели T-GCN показывают стабильное состояние при различных горизонтах прогнозирования, что указывает на универсальность модели для различных задач прогнозирования транспортных потоков. Были использованы два реальных набора данных для оценки предлагаемого подхода. Результаты показывают, что по сравнению со всеми базовыми методами, ошибка прогнозирования T-GCN значительно ниже, что свидетельствует о преимуществах модели в прогнозировании ТП.

Однако, несмотря на все преимущества, графовые нейронные сети и воротные циклические единицы имеют свои ограничения. Они требуют значительных вычислительных ресурсов и времени для обучения и обработки данных. Они могут быть менее эффективными при работе с большими объемами данных или сложными топологиями. Тем не менее, несмотря на эти ограничения, графовые нейронные сети и воротные циклические единицы продолжают развиваться и совершенствоваться. В будущем они могут стать еще более эффективными и широко используемыми инструментами для управления и прогнозирования ТП.

Графовые нейронные сети и воротные циклические единицы представляют собой перспективное направление в области управления и прогнозирования. Они позволяют учитывать сложные взаимосвязи между различными элементами транспортной системы и динамически адаптироваться к изменениям в окружающей среде. Это делает их незаменимыми инструментами для обеспечения эффективного и безопасного движения на дорогах.

Предложенный подход является мощным инструментом для прогнозирования ТП и может быть использован для решения различных задач, связанных с управлением, планированием маршрутов и логистикой. Подход может быть расширен для включения различных факторов, влияющих на ТП, таких как погодные условия, закрытие дорог, специальные события и другие. Интеграция этих факторов в модель может улучшить точность и устойчивость прогнозирования:

1. Улучшенная точность прогнозирования: Модель T-GCN обеспечивает высокую точность прогнозирования;

2. Возможность прогнозирования на различных горизонтах: Модель может использоваться для прогнозирования как на краткосрочные, так и на долгосрочные периоды;

3. Учет различных факторов: Модель учитывает множество факторов, влияющих на ТП, что позволяет более точно прогнозировать его поведение;

4. Интеграция с другими системами управления транспортом: T-GCN может быть легко интегрирована с существующими системами управления для повышения их эффективности;

5. Улучшенная безопасность на дорогах: Прогнозирование ТП с помощью T-GCN может способствовать улучшению безопасности на дорогах, позволяя своевременно реагировать на изменения в дорожной ситуации.

Разработка программы

Дорожная сеть города лучше представима в виде графа, а не простой двумерной сетки, что указывает на то, что модель CNN не способна эффективно представлять сложную топологию этой сети и, как следствие, не может точно отражать пространственные зависимости [11]. Используя матрицу смежности A вместе с собственной матрицей X , модель GCN использует спектральные методы, основанные на матрице Лапласа графа, для обработки данных. В этом контексте GCN опираются на собственные векторы и собственные значения матрицы Лапласа, что позволяет учитывать глобальные свойства графа и анализировать частотные характеристики. Собственные векторы представляют собой функции, которые могут быть использованы для фильтрации сигналов на графе, а собственные значения определяют частоты этих функций. Таким образом, GCN эффективно агрегируют информацию от соседних узлов, что способствует более точному представлению пространственных зависимостей на графе.

В этой статье используется сверточная сеть, состоящая из двух слоев, модель GCN которой предназначена для фиксации пространственных зависимостей и представлена следующим образом:

$$f(X, A) = \gamma \hat{D} W_1 f_{ReLU}(\hat{D} X W_0).$$

Функциональная формула, изложенная выше, иллюстрирует, как модель GCN используется для извлечения пространственных характеристик из данных о ТП.

Как показано на рисунке 1, предполагая, что узел 4 является центральной дорогой, модель GCN может получить топологическую связь между центральной дорогой и окружающими дорогами, закодировать структуру топологии сети и атрибуты дорог, и получить пространственную зависимость.




Рис. 1. Предположение, что узел 4 является центральной дорогой: выделенные узлы показывают, что эти перегоны соединены с центральной дорогой, путем получения топологической связи между центральной дорогой и соединенными перегонами может быть получен пространственный признак

Была выбрана модель GRU для получения временной зависимости из данных ТП [12]. GRU использует скрытое состояние в $(k-1)$ момент времени и текущую информацию о ТП в качестве входных данных для получения состояния в k -ый момент времени. Как показано на рисунке 2, GRU использует сброс ворот (a_k) для управления степенью игнорирования информации о состоянии в предыдущий момент, обновление ворот (b_k) для управления степенью, в которой информация о состоянии в предыдущий момент времени переносится в текущее состояние, и содержимое памяти (c_k) для хранения информации о потоках в k -ый момент времени.




Рис. 2. Архитектура модели GRU (Gated Recurrent Unit)

Благодаря применению GRU модель может захватывать тенденцию изменения исторической информации и имеет способность захватывать временную зависимость. Это позволяет моделировать и предсказывать будущие значения с высокой точностью [13]. Кроме того, GRU может быть использована для анализа и прогнозирования других типов временных рядов, таких как данные о погоде, финансовые данные и т.д.

Условия проведения исследований

Сбор данных: для проведения исследований был организован сбор данных, полученных с детекторов транспорта, расположенных на основных элементах УДС города. Эти детекторы предоставляют непрерывные данные о скорости движения транспортных средств, которые являются критически важными для анализа [14] и прогнозирования транспортных потоков. Сбор данных осуществлялся в течение месяца, с 1 по 31 октября 2023 г., с интервалом измерений каждые 15 минут. Такой подход обеспечивает достаточное количество данных для обучения и тестирования модели, а также позволяет учесть изменчивость транспортных потоков в течение суток и дней недели.

Обработка данных: после сбора данные подвергались тщательной предварительной обработке. Этот этап включал в себя несколько ключевых шагов: в первую очередь выполнялась очистка данных от выбросов и пропусков, которые могут исказить результаты анализа [15]. Для этого применяются статистические методы и алгоритмы машинного обучения, способные автоматически идентифицировать и корректировать такие аномалии. Далее, создается матрица смежности, которая описывает пространственные связи между различными участками дорог, что важно для моделирования транспортных сетей [16]. Кроме того, создавалась матрица, отражающая изменения скорости движения во времени, для того чтобы позволить модели учитывать временные паттерны в

движении. Такие данные были нормированы на вещественный интервал $[0,1]$ для улучшения сходимости модели во время обучения, что является стандартной практикой в машинном обучении для ускорения и стабилизации процесса обучения [17].

Разделение данных: Нормированные данные были условно разделены на обучающий и тестовый наборы в соотношении 80% к 20% с помощью ручной маркировки обучающих примеров. Такое достаточно часто используемое разделение позволяет обучить модель на большей части данных, обеспечивая ей достаточное количество информации для изучения закономерностей еще перед проверкой её эффективности на независимом наборе данных. Это позволяет оценить, насколько хорошо модель обобщает новые, нераспознанные ранее паттерны [18].

Обучение модели: Модель T-GCN обучалась на обучающем наборе данных с использованием выбранных гиперпараметров [19]. Процесс обучения включал в себя несколько эпох, в течение которых модель адаптировала свои параметры для минимизации ошибки прогнозирования. Во время обучения осуществлялся мониторинг метрик, для того чтобы контролировать процесс обучения и своевременно корректировать параметры, в случае необходимости [20-23].

Заключение

Проведенные исследования продолжают и детализируют исследование авторов в данном направлении [24-27]. Приведенная детальная методология обеспечивает систематический подход к проведению исследования прогнозирования транспортных потоков в городе с использованием модели T-GCN, включая все необходимые этапы от сбора и обработки данных до анализа результатов и документирования исследования.

Анализ результатов (рис. 3) показал, что модель T-GCN может захватывать пространственные и временные зависимости в данных о транспортных потоках.




Рис. 3. Результаты тестирования разработанной модели: (а) Зависимость RMSE от количества скрытых элементов на обучающем наборе. (б) Зависимость MAE от количества скрытых элементов на обучающем наборе. (с) Зависимость RMSE от количества скрытых элементов на тестовом наборе. (д) Зависимость MAE от количества скрытых элементов на тестовом наборе

Использование матрицы смежности и временной матрицы позволило модели учитывать пространственные и временные паттерны в движении. Кроме того, применение GRU позволило модели захватывать тенденцию изменения исторической информации о ТП и иметь способность захватывать временную зависимость.

Результаты тестирования показали, что модель T-GCN может достигать высокой точности прогнозирования транспортных потоков. Зависимость RMSE и MAE от количества скрытых элементов на обучающем и тестовом наборах показала, что модель может эффективно прогнозировать транспортные потоки с высокой точностью.

В данной статье представлена методология прогнозирования транспортных потоков в городе Хабаровске с использованием модели T-GCN. Результаты тестирования показали, что модель T-GCN может эффективно прогнозировать транспортные потоки с высокой точностью. Использование матрицы смежности и временной матрицы позволило модели учитывать пространственные и временные паттерны в движении. Кроме того, применение GRU позволило модели захватывать тенденцию изменения исторической информации о ТП и иметь способность захватывать временную зависимость.

Данная методология может быть использована для прогнозирования транспортных потоков в других городах и регионах. Кроме того, модель T-GCN может быть использована для анализа и прогнозирования других типов временных рядов, таких как данные о погоде, финансовые данные и т.д.

В целом, данная статья представляет собой важный вклад в область прогнозирования транспортных потоков и может быть использована для улучшения качества и эффективности транспортных систем.

Литература

1. Пугачев И.Н. Теоретические принципы и методы повышения эффективности функционирования транспортных систем городов // диссертация на соискание ученой степени доктора технических наук / Уральский государственный университет путей сообщения. Екатеринбург, 2010.
2. Xing Z. et al. Spatial linear transformer and temporal convolution network for traffic flow prediction // Scientific Reports. 2024. Т. 14. № 1. С. 4040.
3. Пугачев И.Н. et al. Numerical evaluation of the traffic flow indicators using super-resolution satellite imagery // 2019 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon). IEEE, 2019. С. 1-4.
4. Пугачев И.Н., Тормозов В.С. Разработка нового метода детектирования и классификации транспорта средств по спутниковым изображениям // Дороги и мосты. 2023. № 1 (49). С. 199-220.
5. Пугачев И.Н., Тормозов В.С. Разработка метода детектирования объектов транспортных потоков по спутниковым фотоснимкам сверхвысокого разрешения // Вестник ДВО РАН. 2024. № 2. С. 33-41. <http://dx.doi.org/10.31857/S0869769824020033>, EDN: LDNKM0
6. Pugachev I.N., Kapsky D.V., Navoy D.V., Markelov G.Ya., Tormozov V.S., Shcheglov V.I. Synergy of approaches to improving intelligent transport systems of cities in Russia and Belarus. Khabarovsk: Pacific State University, 2020. 230 p. ISBN 978-5-7389-3154-3. EDN YDRMXN
7. Тормозов В.С., Василенко К.А., Золкин А.Л. Настройка и обучение многослойного персептрона для задачи выделения дорожного покрытия на космических снимках города // Программные продукты и системы. 2020. Т. 33. № 2. С. 343-348.
8. Tormozov V.S. Method of detection and classification of vehicles on ultra-high-resolution satellite images // Industrial ACS and controllers. 2019. № 6, pp. 18-24. DOI 10.25791/asu.06.2019.678. EDN WAMRGQ

9. Huang X. et al. MD-GCN: a multi-scale temporal dual graph convolution network for traffic flow prediction // *Sensors*. 2023. T. 23. № 2. С. 841.
10. Chen Ch., Minald A.A., Bogush R., Ma G., Weichen Y., Ablameiko S.V. Vehicle Detection and Classification in Super-Resolution Imagery Using Neural Networks // *Journal of Applied Spectroscopy*. 2022. Vol. 89. No. 2, pp. 275-282.
11. Xu Z., Yuan J., Yu L., Wang, G., Zhu M. Machine Learning-Based Traffic Flow Prediction and Intelligent Traffic Management // *International Journal of Computer Science and Information Technology*. 2024. T. 2. № 1. С. 18-27.
12. Tormozov V.S. Improving the performance of the algorithm for detecting and classifying vehicles in satellite images by reducing the search area using geoinformation about roads // *Bulletin of the Russian New University. Series: Complex systems: models, analysis and control*. 2019. No. 2, pp. 56-63. DOI 10.25586/RNU.V9I87.19. 02.pp. 056. EDN LKERAT
13. Shi G. et al. Deep transformer-based heterogeneous spatiotemporal graph learning for geographical traffic forecasting // *iScience*. 2024. T. 27. № 7.
14. Banerjee S., Dong M., Shi W. Spatial-temporal synchronous graph transformer network (stsgt) for covid-19 forecasting // *Smart Health*. 2022. Vol. 26. P. 100348.
15. Zhao W. et al. Spatio-temporal causal graph attention network for traffic flow prediction in intelligent transportation systems // *PeerJ Computer Science*. 2023. Vol. 9. P. e1484.
16. Tormozov V.S. Counting and Recognizing Cars on Satellite Images // *Scientific Notes of TSU*. 2017. Vol. 8, No. 3, pp. 126-134. EDN ZQNTUB
17. Zolkin A.L., Tormozov V.S., Gridina D.V. Intelligent software and information system for diagnostics and forecasting the technical condition of traction electric motors // *Bulletin of the Samara Scientific Center of the Russian Academy of Sciences*. 2020. Vol. 22, No. 4 (96), pp. 92-97. DOI 10.37313/1990-5378-2020-22-4-92-97. EDN EZSCNM
18. Пугачев И.Н., Скрипко П.Б., Шешера Н.Г. Программный подход к комплексному сбору и подготовки данных об интенсивности движения транспортных средств, погодных условий и естественной освещенности в часовых интервалах // *T-Comm: Телекоммуникации и транспорт*. 2023. Том 17. №10. С. 43-51.
19. Pugachev I., Kulikov Y., Markelov G., Sheshera N. Factor Analysis of Traffic Organization and Safety Systems // 12th International Conference «Organization and Traffic Safety Management in large cities», SPbOTSIC-2016, 28-30 September 2016, St. Petersburg. St. Petersburg, 2017, pp. 529–535.
20. Бурков С.М., Маркелов Г.Я., Пугачев И.Н. Задачи системного анализа и методология формирования интеллектуальной системы управления транспортным комплексом города // *Вестник Тихоокеанского государственного университета*. 2013. № 4 (31). С. 83-90.
21. Zhang Z. et al. A novel hybrid framework based on temporal convolution network and transformer for network traffic prediction // *Plos one*. 2023. Vol. 18. № 9. P. e0288935.
22. Pu S. et al. SGGformer: shifted graph convolutional graph-transformer for traffic prediction // *Sensors*. 2022. Vol. 22. № 22. P. 9024.
23. Bin Ри, Цзянсу Ли, Ян Канг, Цзянго Чен, Филип С.Ю. MVSTT: многовидовая пространственно-временная трансформаторная сеть для прогнозирования транспортных потоков // *IEEE Trans Cybern.* 2024 Март. No. 54 (3), pp. 1582-1595. doi: 10.1109/TCYB.2022.3223918
24. Пугачев И.Н., Шешера Н.Г., Григоров Д.Е. Определение эффективных широт интервалов влияния температурных режимов на интенсивность транспортного потока с использованием ранговой корреляции Спирмена // *T-Comm: Телекоммуникации и транспорт*. 2024. Том 18. №3. С. 34-40.
25. Пугачев И.Н., Евтюков С.С., Шешера Н.Г., Григоров Д.Е. Максимальная обеспечиваемая скорость как ключевой показатель травматизма при ДТП. Способы сбора, обработки и анализа // *T-Comm: Телекоммуникации и транспорт*. 2024. Том 18. №6. С. 46-54.
26. Пугачев И.Н., Евтюков С.С., Шешера Н.Г., Григоров Д.Е. Прогноз интенсивности транспортного потока. Обучение с учителем. Метод случайных деревьев // *T-Comm: Телекоммуникации и транспорт*. 2024. Том 18. №4. С. 36-47.
27. Бугаев А.С., Таташев А.Г., Яшина М.В., Лавров О.С., Носов Е.А. Восстановление динамики транспортного потока на основе детерминированно-стохастической модели и данных с интеллектуально транспортных систем // *T-Comm: Телекоммуникации и транспорт*. 2019. Том 13. №10. С. 35-44. EDN: DLZNOX.

MULTI-VIEW SPATIAL-TEMPORAL CONVOLUTION TO IMPROVE THE ACCURACY OF TRAFFIC FLOW FORECASTING

Igor N. Pugachev, Khabarovsk Federal Research Center of the Far Eastern Branch of the Russian Academy of Sciences (HFRC FEB RAS), Khabarovsk, Russia, ipugachev64@mail.ru

Vladimir S. Tormozov, Pacific National University, Higher School of Cybernetics and Digital Technologies, Khabarovsk, Russia, 007465@pnu.edu.ru

Stanislav S. Evtyukov, St. Petersburg State University of Architecture and Civil Engineering, St. Petersburg, Russia, tm@spbgasu.ru

Nikolay N. Smoktal, Sevastopol State University, Sevastopol, Russia, nnsnoktal@sevsu.ru

Alexander L. Zolkin, Povolzhskiy State University of Telecommunications and Informatics (PGUTY), Samara, Russia, alzolkin@list.ru

Abstract

The rapid development of information technology has made multiple time series forecasting, especially in the field of traffic flow analysis, increasingly important for big data evaluation. Traffic flow forecasting, acting as a basis for intelligent transportation systems (ITS), has significant scientific and practical value for urban traffic planning, improving the quality and efficiency of both logistics transport and public transport strategies. In an intelligent transportation system, traffic flow forecasting remains a critical task. However, due to the complex temporal and spatial dependencies inherent in traffic flow sequences, establishing an accurate forecasting model using ring neural networks, graph networks, and transformer models presents significant challenges. To take advantage of convolutional networks, which are known for their high computational efficiency and robust feature extraction capabilities, a novel traffic flow prediction model is proposed that utilizes multi-view spatio-temporal convolution.

Keywords: traffic flow prediction; deep learning; machine learning; graph neural networks

References

- [1] I. N. Pugachev, "Theoretical principles and methods of improving the efficiency of urban transport systems," Dissertation for the degree of Doctor of Technical Sciences. Ural State University of Railway Engineering. Yekaterinburg, 2010.
- [2] Z. Xing et al., "Spatial linear transformer and temporal convolution network for traffic flow prediction," *Scientific Reports*. 2024. Vol. 14. No. 1, p. 4040.
- [3] I. N. Pugachev et al., "Numerical evaluation of the traffic flow indicators using super-resolution satellite imagery," *2019 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon)*. IEEE, 2019, pp. 1-4.
- [4] I. N. Pugachev, V. S. Brakes, "Development of a new method for detecting and classifying vehicles from satellite images," *Roads and bridges*. 2023. No. 1 (49), pp. 199-220.
- [5] I. N. Pugachev, V. S. Tormozov, "Development of a method for detecting traffic flow objects from ultra-high resolution satellite photographs," *Bulletin of the Far Eastern Branch of the Russian Academy of Sciences*. 2024. No. 2, pp. 33-41. <http://dx.doi.org/10.31857/S08697698240>
- [6] I. N. Pugachev, D. V. Kapsky, D. V. Navoy, G. Ya. Markelov, V. S. Tormozov, V. I. Shcheglov, "Synergy of approaches to improving intelligent transport systems of cities in Russia and Belarus," Khabarovsk: Pacific State University, 2020. 230 p. ISBN 978-5-7389-3154-3
- [7] V. S. Brakes, K. A. Vasilenko, A. L. Zolkin, "Setting up and training a multilayer perceptron for the task of highlighting the pavement on satellite images of the city," *Software products and systems*. 2020. Vol. 33. No. 2, pp. 343-348.
- [8] V. S. Tormozov, "Method of detection and classification of vehicles on ultra-high-resolution satellite images," *Industrial ACS and controllers*. 2019. No. 6, pp. 18-24. DOI 10.25791/asu.06.2019.678.
- [9] X. Huang et al., "MD-GCN: a multi-scale temporal dual graph convolution network for traffic flow prediction," *Sensors*. 2023. Vol. 23. No. 2, p. 841.
- [10] Chen Ch., A. A. Minald, R. Bogush, G. Ma, Y. Weichen, S. V. Ablameiko, "Vehicle Detection and Classification in Super-Resolution Imaging Using Neural Networks," *Journal of Applied Spectroscopy*. 2022. Vol. 89. No. 2, pp. 275-282.
- [11] Z. Xu, J. Yuan, L. Yu, G. Wang, M. Zhu, "Machine Learning-Based Traffic Flow Prediction and Intelligent Traffic Management," *International Journal of Computer Science and Information Technology*. 2024. Vol. 2. No. 1, pp. 18-27.
- [12] V. S. Tormozov, "Improving the performance of the algorithm for detecting and classifying vehicles in satellite images by reducing the search area using geoinformation about roads," *Bulletin of the Russian New University. Series: Complex systems: models, analysis and control*. 2019. No. 2, pp. 56-63. DOI 10.25586/RNU.V9I87.19. 02.pp. 056.
- [13] G. Shi et al., "Deep transformer-based heterogeneous spatiotemporal graph learning for geographic traffic forecasting," *iScience*. 2024. Vol. 27. No. 7.
- [14] S. Banerjee, M. Dong, W. Shi, "Spatial-temporal synchronous graph transformer network (stsgt) for covid-19 forecasting," *Smart Health*. 2022. Vol. 26. p. 100348.
- [15] W. Zhao et al., "Spatio-temporal causal graph attention network for traffic flow prediction in intelligent transportation systems," *PeerJ Computer Science*. 2023. Vol. 9. p. e1484.
- [16] V. S. Tormozov, "Counting and Recognizing Cars on Satellite Images," *Scientific Notes of TSU*. 2017. Vol. 8, No. 3, pp. 126-134.
- [17] A. L. Zolkin, V. S. Tormozov, D. V. Gridina, "Intelligent software and information system for diagnostics and forecasting the technical condition of traction electric motors," *Bulletin of the Samara Scientific Center of the Russian Academy of Sciences*. 2020. Vol. 22, No. 4 (96), pp. 92-97. DOI 10.37313/1990-5378-2020-22-4-92-97.
- [18] I. N. Pugachev, P. B. Skripko, N. G. Sheshera, "A programmatic approach to the integrated collection and preparation of data on vehicle traffic intensity, weather conditions and natural illumination in hourly intervals," *T-Comm*. 2023. Vol. 17. No. 10, pp. 43-51.
- [19] I. Pugachev, Y. Kulikov, G. Markelov, N. Sheshera, "Factor Analysis of Traffic Organization and Safety Systems," *12th International Conference "Organization and Traffic Safety Management in large cities", SPbOTSIC-2016*, September 28-30, 2016, St. Petersburg. St. Petersburg, 2017. pp. 529-535.
- [20] S. M. Burkov, G. Ya. Markelov, I. N. Pugachev, "Tasks of system analysis and methodology of formation of an intelligent management system of the city's transport complex," *Bulletin of the Pacific State University*. 2013. No. 4 (31), pp. 83-90.
- [21] Z. Zhang et al., "A novel hybrid framework based on temporary convolution network and transformer for network traffic prediction," *Plos one*. 2023. Vol. 18. No. 9, pp. e0288935.
- [22] S. Pu et al., "SGGformer: shifted graph convolutional graph-transformer for traffic prediction," *Sensors*. 2022. Vol. 22. No. 22, p. 9024.
- [23] Bin Pu, Jiansun Liu, Yan Kang, Jianguo Chen, Philip S. Yu, "MVSTT: a multi-species space-time transformer network for predicting traffic flows," *IEEE Trans Cybern*. March 2024, no. 54 (3), pp. 1582-1595. DOI: 10.1109/TCYB.2022.3223918.
- [24] I. N. Pugachev, N. G. Sheshera, D. E. Grigorov, "Determination of effective latitudes of the intervals of influence of temperature conditions on the intensity of traffic flow using Spearman rank correlation," *T-Comm*. 2024. Vol. 18. No. 3, pp. 34-40.
- [25] I. N. Pugachev, S. S. Evtukov, N. G. Sheshera, D. E. Grigorov, "Maximum provided speed as a key indicator of injuries in road accidents. Methods of collection, processing and analysis," *T-Comm*. 2024. Vol. 18. No. 6, pp. 46-54.
- [26] I. N. Pugachev, S. S. Evtukov, N. G. Sheshera, D. E. Grigorov, "Forecasting the intensity of traffic flow. Learning with a teacher. Random Tree Method," *T-Comm*. 2024. Vol. 18. No. 4, pp. 36-47.
- [27] A. S. Bugaev, A. G. Tatshev, M. V. Yashina, O. S. Lavrov, E. A. Nosov, "Reconstruction of traffic flow dynamics based of deterministicstochastic model and data obtained from intelligent transport systems // T-Comm. 2019. Vol 13. No. 10, pp. 35-44.

Information about authors

Igor N. Pugachev, Deputy Director for Research, HFRC FEB RAS, Dr. tech. Sciences, Associate Professor, Khabarovsk Federal Research Center of the Far Eastern Branch of the Russian Academy of Sciences (HFRC FEB RAS), Khabarovsk, Russia

Vladimir S. Tormozov, Pacific National University, Associate Professor of the Higher School of Cybernetics and Digital Technologies, Ph.D. in Engineering, Khabarovsk, Russia

Stanislav S. Evtukov, Automotive and Highway Faculty, Head of the Department of Methodological Systems, Dr. tech. Sciences, Associate Professor, St. Petersburg State University of Architecture and Civil Engineering, St. Petersburg, Russia

Nikolay N. Smoktal, FSAEI HE "Sevastopol State University", Senior Lecturer, Department of Energy Systems and Complexes of Traditional and Renewable Sources, Sevastopol, Russia

Alexander L. Zolkin, Povolzhskiy State University of Telecommunications and Informatics (PGUTY), Associate Professor of the Department of Computer Ph.D. Science and Computer Engineering, Ph.D. in Engineering, Samara, Russia