

Федеральное государственное автономное образовательное учреждение
высшего образования
«Национальный исследовательский университет
«Высшая школа экономики»

На правах рукописи

Сеунгмин Джин

**СИСТЕМА ВИЗУАЛЬНОЙ АНАЛИТИКИ ДЛЯ
ОБЪЯСНЕНИЯ И УЛУЧШЕНИЯ МОДЕЛЕЙ
ПРОГНОЗИРОВАНИЯ ДОРОЖНОГО ДВИЖЕНИЯ
НА ОСНОВЕ МЕХАНИЗМА ВНИМАНИЯ**

РЕЗЮМЕ

на соискание ученой степени
кандидата компьютерных наук

Научный руководитель:
доктор компьютерных наук
Аттила Кертес-Фаркаш

Москва — 2024

Содержание

1	Введение	3
1.1	Контекст и мотивация	3
1.2	Актуальность исследования	4
1.3	Цели и область исследования	5
1.4	Практическая значимость работы	5
1.5	Публикации	6
2	Объяснение модели пространственно-временной графовой нейронной сети с механизмом внимания (ST-GRAT) и механизма внимания	8
2.1	Механизм внимания	8
2.2	Проблема прогнозирования дорожного движения в графовых нейронных сетях	9
2.3	Пространственно-временная графовая нейронная сеть с механизмом внимания (ST-GRAT)	11
3	Введение в AttnAnalyzer	14
3.1	Описание задачи и условий	14
3.2	Интеграция методов динамической временной трансформации (DTW) и тестов причинности Грейнджера	16
3.3	Обзор различных представлений и визуализаций, предоставляемых AttnAnalyzer	17
4	Анализ модели и результаты экспериментов по производительности	19
4.1	Кейс-исследования, демонстрирующие эффективность AttnAnalyzer	19
4.1.1	Описание данных	20
4.2	Эксперимент по улучшению ST-GRAT с использованием принудительных весов	20
4.3	Обратная связь и валидация со стороны экспертов в предметной области	21
5	Заключение	23
	Список литературы	25

1 Введение

В данной работе проводится исследование ошибок модели пространственно-временной графовой нейронной сети с механизмом внимания (ST-GRAT) [1] в задаче прогнозирования дорожного движения с использованием моей системы визуального анализа данных. Моя цель заключается в улучшении производительности модели на основе понимания скрытых состояний и паттернов ошибок [2]. В конечном итоге это приводит к более точному прогнозированию дорожного движения и обеспечивает эффективное развитие моделей глубокого обучения для прогнозирования дорожного движения. В данной диссертации я объясню, что такое модель ST-GRAT, затем продемонстрирую анализ прогнозов и ошибок модели, процесс отладки модели с использованием моей системы визуального анализа данных, названной AttnAnalyzer [3].

Основные вклады моей диссертации следующие:

1. Я представляю модель пространственно-временной графовой нейронной сети с механизмом внимания (ST-GRAT) [1], которую я разработал для прогнозирования дорожного движения (Глава 2). Эта глава также включает в себя обзор литературы по задаче прогнозирования дорожного движения, определение с использованием графовых нейронных сетей, включая временную и пространственную зависимость, и объяснение механизма внимания для декомпозиции прогноза.
2. Я объясняю систему визуального анализа данных для понимания прогнозов модели ST-GRAT в задаче прогнозирования дорожного движения (Глава 3). Эта глава представляет требования к исследованиям системы визуального анализа данных, автоматизированную методологию и её реализацию для понимания скрытого пространства модели и паттернов прогноза.
3. Я провожу анализ модели ST-GRAT, используя две разные дорожные сети: городские дороги и автострады. Эта глава объясняет проблему модели и показывает метод, как улучшить производительность, взламывая сети внимания с помощью моей системы визуального анализа данных, названной AttnAnalyzer [3]. (Глава 4).
4. Я подвожу итоги моей диссертации и указываю направления для будущих исследований (Глава 5).

1.1 Контекст и мотивация

Заторы дорожного движения стали серьезной проблемой в городских районах по всему миру, что приводит к увеличению времени в пути, экологическому загрязнению и снижению экономической продуктивности [4, 5]. Точное прогнозирование дорожного движения необходимо для решения этих проблем и предоставления более эффективных решений в управлении дорожным движением. Пространственно-временные графовые сети с механизмом внимания

возникли как многообещающий подход к прогнозированию дорожного движения, благодаря их способности улавливать сложные пространственные и временные зависимости в данных о дорожном движении [5]. Среди этих моделей модель ST-GRAT показала перспективные результаты в прогнозировании динамически меняющихся скоростей дорожного движения [1].

Несмотря на то что модели, основанные на механизме внимания, показывают хорошие результаты, есть проблемы с их применением в реальном мире. Самая большая проблема - это надежность прогнозов модели, поскольку у нас есть отчет о средней производительности, но нет понимания поведения модели. Поведение указывает на паттерн ошибок в прогнозе. Например, мы не знаем, когда и в каких случаях эта модель терпит неудачу, и, более того, почему происходят такие ошибки. В среднем модель может предоставить хороший прогноз, но если она продолжает показывать неправильные прогнозы, то возникают проблемы с доверием со стороны пользователей [6].

Еще одной серьезной проблемой является высокая стоимость отладки. Сети с механизмом внимания, которые представляют пространственно-временные зависимости, огромны и сложны [7, 1], их действительно сложно и времязатратно отлаживать. Более того, сама глубокая модель машинного обучения требует большого времени обучения для процесса отладки [8]. В данной диссертации рассматриваются эти проблемы или ограничения, путем понимания поведения модели и разработки методов улучшения процесса отладки.

1.2 Актуальность исследования

Для решения этих ограничений крайне важно понимать поведение моделей глубокого обучения в прогнозировании дорожного движения и разрабатывать методы для улучшения их производительности, такие как понимание скрытого пространства для проблемы классификации глубокого обучения [9]. Это исследование крайне актуально в свете растущего спроса на точный прогноз дорожного движения в городских районах, где пробки на дорогах являются серьезной проблемой. Более того, разработка более эффективных моделей глубокого обучения для прогнозирования дорожного движения может иметь более широкие последствия для управления транспортом и городского планирования [6].

В нескольких недавних исследованиях также подчеркивается необходимость углубленного понимания поведения моделей глубокого обучения в задачах прогнозирования дорожного движения [5]. Например, в исследовании Zhang et al. (2020) [10] авторы предложили новый механизм внимания для улучшения производительности моделей прогнозирования дорожного движения. В другом исследовании Huang et al. (2020) [11] авторы использовали мультимодальный подход глубокого обучения для прогнозирования потока дорожного движения и заторов. Эти исследования подчеркивают важность разработки более эффективных моделей глубокого обучения для прогнозирования дорожного движения, а также потенциальные преимущества углубленного понимания поведения этих моделей.

1.3 Цели и область исследования

Целью данной диссертации является улучшение производительности модели ST-GRAT, которая представляет собой современную модель глубокого обучения с механизмом внимания, путем внедрения системы визуального анализа для понимания причин неудач модели и их устранения. Основными целями исследования являются:

1. Исследовать факторы, вызывающие неудачи модели ST-GRAT в точном прогнозировании дорожного движения.
2. Разработать систему визуального анализа для понимания и анализа поведения модели и её недостатков.
3. Улучшить модель ST-GRAT на основе полученных инсайтов из системы визуального анализа.
4. Оценить производительность улучшенной модели в прогнозировании дорожного движения и её потенциальное влияние на управление дорожными заторами.

Областью исследования включает в себя анализ модели ST-GRAT, разработку системы визуального анализа, а также улучшение и оценку производительности модели.

1.4 Практическая значимость работы

Основными вкладами данной работы являются:

1. Модель прогнозирования дорожного движения, использующая графовые нейронные сети с механизмом внимания.
2. Дизайн системы визуального анализа (VA) для исследования паттернов прогнозирования модели прогнозирования дорожного движения с пространственной и временной перспективой.
3. Интеграция автоматизированных методов, таких как динамическое выравнивание времени (DTW) [12], тест причинно-следственных связей Грейнджера [13] и кластеризация для визуального временного анализа.
4. Разработка метода усиления внимания.
5. Количественная и качественная оценка системы на основе трех случаев исследования, чтобы продемонстрировать, как объяснить модели глубокого обучения с помощью механизма внимания, подтвердить улучшение точности модели с использованием метода усиления внимания и обратную связь от представителей отрасли.
6. Показ того, как разработчики моделей могут улучшить производительность модели, используя наш инструмент, разработав улучшенную версию модели на основе результатов исследования.

На мой взгляд, данная работа является первой попыткой исследования процесса прогнозирования моделей, основанных на механизме внимания, в области прогнозирования дорожного движения. Эта работа также впервые пытается улучшить производительность в области дорожного движения, продемонстрировав мощь подходов визуального анализа [14]. Данные о дорожном движении являются разнообразными, включая экстремальные случаи [6, 4, 15], и подвержены неконтролируемым внешним факторам, таким как аварии. Таким образом, задача прогнозирования дорожного движения является особенно сложной, поскольку модели в данной области должны учиться не только пространственно-временным характеристикам данных, но и тому, как реагировать на неявные внешние события на дорогах. Внешние факторы могут варьироваться даже по регионам [7], что дополнительно усложняет задачу.

1.5 Публикации

Моя диссертация основана на следующих трех основных исследовательских статьях, все они были опубликованы в журналах Q1 или на конференциях A*. Рейтинг основан на данных Scopus и Web of Science.

Публикации первого уровня.

1. Seungmin Jin, Hyunwook Lee, Cheonbok Park, Hyeshin Chu, Yunwon Tae, Jaegul Choo, Sungahn Ko. “Система визуального анализа для улучшения моделей прогнозирования дорожного движения на основе механизма внимания.” **IEEE транзакции по визуализации и компьютерной графике, журнал Q1**, 2022, doi: <https://doi.org/10.1109/tvcg.2022.3209462>.

Основной вклад: В качестве главного автора я разработал весь исследовательский процесс, систему визуального анализа и метод улучшения производительности модели ST-GRAT. Я не только выявил паттерны ошибок модели ST-GRAT через детальные исследования случаев, но также продемонстрировал, как можно исправить ошибки, используя представительные скоростные паттерны.

2. Cheonbok Park, Chunggi Lee, Hyojin Bahng, Yunwon Tae, Kihwan Kim, Seungmin Jin, Sungahn Ko and Jaegul Choo. “ST-GRAT: новая пространственно-временная графовая нейронная сеть с механизмом внимания для точного прогнозирования динамически изменяющейся скорости дороги.” **Материалы 29-й международной конференции ACM по управлению информацией & знаниями. (CIKM), ACONF**, 2020, doi: <https://doi.org/10.1145/3340531.3411940>.

Основной вклад: Я участвовал как один из основных разработчиков модели. Особенно я отлаживал и анализировал эту модель, чтобы понять, в каких случаях ST-GRAT предсказывает хорошо или плохо. В этом исследовании я обнаружил мотивацию, почему мне нужно разрабатывать систему визуального анализа для понимания поведения моделей глубокого обучения. Я испытал, что процесс отладки не только сложно анализировать, но и требует много усилий и времени из-за сложности процесса.

3. Chunggi Lee, Yeonjun Kim, Seungmin Jin, Dongmin Kim, Ross Maciejewski, David Ebert, Sungahn Ko. “Система визуальной аналитики для исследования, мониторинга и прогнозирования заторов на дорогах.” **Транзакции IEEE по визуализации и компьютерной графике, журнал Q1**, 2020, doi: <https://doi.org/10.1109/tvcg.2019.2922597>.

Основной вклад: В этом исследовании я разработал всю систему визуального анализа, показывающую дорожные пробки в городе Ульсан, Южная Корея. Я также провел несколько исследований, которые анализируют, при каких условиях возникают пробки в дорожном движении. Я также обнаружил мотивацию для моего основного исследования, поскольку используемая здесь модель глубокого обучения, LSTM, не предоставляет структурированной информации вывода, поэтому было трудно понять.

Другие публикации.

Несмотря на то, что все следующие статьи были опубликованы в журналах Q1 или на конференциях A*, они не являются основой данной диссертации.

1. Hyeshin Chu, Joohee Kim, Seongouk Kim, Hongkyu Lim, Hyunwook Lee, Seungmin Jin, Jongeun Lee, Taehwan Kim, and Sungahn Ko. “Эмпирическое исследование восприятия людьми созданной AI музыки.” **Процедуры 31-ой Международной конференции по информационным технологиям и управлению знаниями (SIKM), ACONF**, 2022. doi: <https://doi.org/10.1145/3511808.3557235>
2. Beknazarov, Nazar, Seungmin Jin, and Maria Poptsova. “Глубокое обучение для прогнозирования функциональных регионов Z-ДНК с использованием омических данных.” **Научные отчеты 10.1 (2020): 19134, журнал Q1**. doi: <https://doi.org/10.1038/s41598-020-76203-1>.
3. Hyunwook Lee, Seungmin Jin, Hyeshin Chu, Hongkyu Lim, and Sungahn Ko. “Обучение запоминанию паттернов: Memory Networks для прогнозирования дорожного движения.” **Международная конференция по обучению представлениям (ICLR), ACONF**, 2022, doi: <https://doi.org/10.48550/arXiv.2110.10380>.
4. Hyunwook Lee, Cheonbok Park, Seungmin Jin, Hyeshin Chu, Jaegul Choo, and Sungahn Ko. “Эмпирический эксперимент над моделями глубокого обучения для прогнозирования данных о дорожном движении.” **37-я Международная конференция по инженерии данных IEEE (ICDE), ACONF**, 2021, doi: <https://doi.org/10.1109/icde51399.2021.00160>.

2 Объяснение модели пространственно-временной графовой нейронной сети с механизмом внимания (ST-GRAT) и механизма внимания

Прогнозирование дорожного движения играет ключевую роль в предсказании будущих дорожных условий на основе исторических данных [4]. В последние годы глубокие методы обучения получили значительное внимание благодаря своей способности выявлять сложные закономерности и зависимости в данных о дорожном движении. Однако, в моих предыдущих исследованиях, я заметил, что понимание поведения моделей глубокого обучения очень сложно из-за их сложности в пространственных и временных зависимостях [7]. Именно это послужило моим основным мотивом для начала разработки модели ST-GRAT, используя механизмы внимания, поскольку они могут предоставлять интуитивно понятную информацию о скрытом пространстве в качестве справочных данных. В данной главе рассматриваются важные концепции и методики, связанные с прогнозированием дорожного движения с использованием глубокого обучения, включая механизмы внимания, графовые нейронные сети (GNN), динамическое выравнивание временных рядов (DTW), тест Грейнджера и модель пространственно-временной графовой нейронной сети с механизмом внимания (ST-GRAT) [1], которую я анализировал.

2.1 Механизм внимания

Механизмы внимания стали мощной техникой в глубоком обучении и нейронных сетях [16, 4]. Они позволяют моделям сосредотачиваться на конкретных частях входных данных при прогнозировании или принятии решений, что позволяет им назначать разные веса или важность различным элементам на основе их релевантности для задачи [17].

Формально механизм внимания вычисляет взвешенную сумму векторов значений размером d на основе сходства или совместимости между вектором запроса $q \in \mathbb{R}^d$, набором векторов ключей $K = k_1, k_2, \dots, k_n \in \mathbb{R}^d$ и набором векторов значений $V = v_1, v_2, \dots, v_n \in \mathbb{R}^d$. Механизм внимания h_{att} может быть представлен как:

$$\text{Внимание}(q, K, V) = h_{\text{att}}(q, K, V) = \sum_{i=1}^n \alpha_i v_i,$$

где α_i - вес, назначенный i -му вектору значений. Веса вычисляются на основе функции совместимости $f(q, k_i)$, измеряющей сходство или отношение между вектором запроса q и i -м вектором ключа k_i . Обычно веса α_i вычисляются с использованием функции softmax по оценкам совместимости, что гарантирует их суммирование до 1.

Механизм внимания широко используется в различных областях, включая обработку естественного языка, компьютерное зрение и анализ временных рядов. Его применяют для задач, таких как машинный перевод, создание подписей к изображениям и анализ настрое-

ний [16].

В контексте прогнозирования дорожного движения механизмы внимания могут быть включены в архитектуры глубокого обучения для выявления взаимосвязей и зависимостей в данных о транспортных потоках. Сосредотачиваясь на разных частях входных данных с разной важностью, модели могут эффективно извлекать актуальную информацию и улучшать свою производительность и интерпретируемость.

2.2 Проблема прогнозирования дорожного движения в графовых нейронных сетях

Прогнозирование дорожного движения направлено на предсказание будущих условий дорожного движения на основе исторических данных. В контексте прогнозирования дорожного движения на основе графов, транспортная сеть представлена в виде графа, где узлы представляют собой участки дорог, а рёбра - связи между ними. Каждый узел в графе ассоциирован с атрибутами дорожного движения, такими как скорость, объём, типы дорог, количество полос и т. д. [1].

Графовые нейронные сети (GNN) стали мощным подходом для прогнозирования дорожного движения в данных, структурированных в виде графа [18]. GNN используют внутренние пространственные и временные зависимости в транспортной сети для выявления сложных закономерностей и точных прогнозов. В GNN каждый узел представляет собой датчик дорожного движения, а рёбра представляют корреляции между датчиками. Путём передачи информации между узлами и агрегирования локальных характеристик от соседей GNN могут выявлять пространственные зависимости в потоке дорожного движения на разных участках. Обработав последовательные данные о движении транспорта, GNN также могут выявлять временные зависимости в потоке дорожного движения, наблюдаемые в разные периоды времени [19].

Одним из ключевых компонентов в GNN является механизм внимания, который позволяет модели фокусироваться на важных характеристиках или узлах в транспортной сети. Механизм внимания в GNN обучается назначать разные веса или важность узлам в транспортной сети на основе их значимости для задачи прогнозирования. Сосредотачиваясь на значимых узлах, модель может учитывать пространственные зависимости и включать их в процесс прогнозирования [20]. Механизм внимания позволяет модели адаптивно распределять больше внимания на информативные узлы, снижая влияние менее информативных узлов [1].

В контексте прогнозирования дорожного движения механизм внимания может учиться сосредотачиваться на соседних узлах, оказывающих сильное влияние на поведение дорожного движения на целевом узле. Это достигается путём вычисления весов внимания на основе совместности или сходства между целевым узлом и ключевыми узлами в графе [1, 17]. Веса внимания затем используются для вычисления взвешенной суммы значений узлов, представляющих характеристики или атрибуты соседних узлов.

Весовой ориентированный граф G , который представляет основную дорожную сеть, является угловым камнем данного исследования. Он определяется как $G = (V, E, A)$, где:

- V обозначает множество узлов, с $|V| = N$.
- E представляет собой множество рёбер.
- $A \in \mathbb{R}^{N \times N}$ - это взвешенная матрица смежности, кодирующая близость между узлами, часто вычисляемая на основе расстояний в дорожной сети.

Матрица смежности A включает в себя два важных аспекта близости в дорожной сети:

1. Связность: Этот элемент A указывает, прямо связаны ли два узла или нет.
2. Веса рёбер: Веса рёбер в A предоставляют более тонкое понимание. Они учитывают не только наличие соединения, но и подробности, такие как расстояние между связанными узлами и направление соединения.

В совокупности эти показатели близости формируют общую структуру графа, охватывая характеристики, такие как связность, направление рёбер и расстояния между узлами.

Теперь мы переходим к графовому сигналу X , который представляет нашу матрицу для графа G . Графовый сигнал X представляет наблюдаемый поток дорожного движения и обозначается как $X \in \mathbb{R}^{N \times P}$. Здесь P представляет собой количество признаков, связанных с каждым узлом. Эти признаки могут быть различными атрибутами, включая скорость, объём, типы дорог и количество полос. Однако следует отметить, что ST-GRAT использует только информацию о скорости в качестве признака и прогнозирует будущую скорость.

Взаимодействие между G и X имеет значение:


- Узлы графа G соответствуют строкам в матрице X .
- Каждая строка в X содержит конкретные характеристики потока дорожного движения, относящиеся к соответствующему узлу.

Это симбиотическое отношение между G и X заложило основу для анализа динамики дорожного движения и паттернов в дорожной сети. В последующих обсуждениях мы рассмотрим, как это взаимодействие является основой для прогнозирования дорожного движения, дополненного интеграцией механизма внимания для более точных прогнозов.

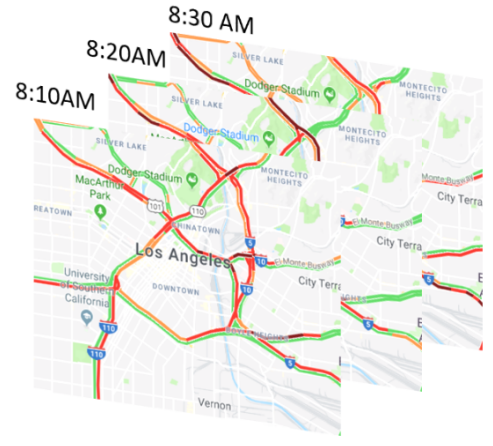
Пусть $X(t) \in \mathbb{R}^{N \times P}$ представляет наблюдаемый графовый сигнал в момент времени t . Задача прогнозирования дорожного движения направлена на изучение функции h , которая отображает T' исторических графовых сигналов в будущем T графовых сигналов, учитывая граф G :

$$[X(t - T' + 1), \dots, X(t); G] \xrightarrow{h} [X(t + 1), \dots, X(t + T)]. \quad (1)$$

Эта формула представляет задачу прогнозирования дорожного движения, где целью является прогноз будущей скорости дорожного движения, учитывая ранее наблюдаемое движение



(a) Which neighbor road has the largest effects?



(b) Which historical observation is more relevant?

Рис. 1: Интерпретируемый прогноз дорожного движения. Пространственная зависимость (a) и временная зависимость (b) являются наиболее важной информацией для прогнозирования дорожного движения [6].

транспорта от N коррелирующих сенсоров на дорожной сети. Механизм внимания встроено в функцию h , которая отвечает за отображение входной последовательности $[X(t - T' + 1), \dots, X(t); G]$ в выходную последовательность $[X(t + 1), \dots, X(t + T)]$. Механизм внимания $h_{att}(q, K, V)$ внутри h позволяет модели назначать разные веса или важность различным элементам (например, узлам, признакам) во входной последовательности на основе их значимости для задачи прогнозирования. Таким образом, модель может динамически фокусироваться на наиболее информативных частях данных в процессе прогнозирования.

Графовые нейронные сети (GNN) с механизмом внимания показали большой потенциал в прогнозировании дорожного движения, эффективно улавливая как пространственные, так и временные зависимости в потоке дорожного движения. С увеличением доступности данных о дорожном движении и разработкой новых моделей GNN, я ожидаю, что GNN с механизмом внимания станет все более популярным методом для прогнозирования дорожного движения [20, 18, 5].

2.3 Пространственно-временная графовая нейронная сеть с механизмом внимания (ST-GRAT)

Я продемонстрировал использование ST-GRAT в рамках моего подхода к визуальной аналитике (VA). Я выбрал ST-GRAT по двум основным причинам: 1) она продемонстрировала высокую производительность и 2) она позволяет мне генерировать матрицы внимания для анализа пространственно-временных зависимостей.

На рисунке 3 представлен обзор рабочего процесса моей системы, который включает различные функциональные модули и способность отвечать на вопросы на основе данных. Рабочий процесс включает в себя предварительную обработку данных (A), автоматизированные методы для поддержки пространственно-временного анализа (B), обучение модели и вывод (C), модули визуализации (D) и возможность отвечать на вопросы, используя систему

(E).

ST-GRAT основан на архитектуре трансформера и следует структуре кодировщика-декодировщика с самовниманием (т.е. временным вниманием). Кроме того, он включает в себя графовое внимание как механизм пространственного внимания перед временным вниманием, используя вектор-знак для пропуска соединений в пределах одной дороги. ST-GRAT использует последовательные исторические данные о скорости длиной 12 для каждой дороги с закодированными характеристиками и предсказывает 12 последовательных прогнозов скорости.

Общая архитектура ST-GRAT изображена на рисунке 2. Она состоит из трех типов слоев: встраивание, слой пространственного внимания и слой временного внимания. Слой встраивания принимает сеть дорог, скорость и наблюдаемое время в качестве входных характеристик и использует метод встраивания положения для кодирования порядка заданной последовательности. Слой пространственного внимания захватывает пространственные зависимости между соседними дорогами с помощью графовой сети внимания, улучшая моделирование зависимостей и интерпретируемость. Слой временного внимания моделирует временную зависимость и тенденции заданных последовательностей с помощью выполнения многоголового внимания.

Для анализа пространственно-временных зависимостей я получаю матрицу пространственно-временного внимания (ST-матрицу) из каждого слоя внимания. Эта матрица представляет собой связь между входной последовательностью перед пространственным вниманием и выходной последовательностью после временного внимания. Для каждой головы внимания связь может быть записана следующим образом:

$$H = (TA \odot SA)X,$$

где $TA \in \mathbb{R}^{N \times T}$, а $SA \in \mathbb{R}^{N \times T}$. Обратите внимание, что ST-GRAT использует $T = 12$ для последовательностей окон. $TA \odot SA$ представляет собой пространственно-временное внимание, которое представляет интерес для понимания поведения модели.

В заключение, ST-GRAT является вариацией модели трансформера, которая объединяет механизмы пространственного и временного внимания для захвата пространственно-временных зависимостей. Он использует преимущества моделей внимания в различных задачах, включая прогнозирование скорости, оценку времени в пути и прогнозирование спроса на такси [16, 74]. В таблице 1 показано, что ST-GRAT превосходит другие модели на основе графовых нейронных сетей (GNNs). Матрицы внимания, созданные ST-GRAT, облегчают анализ пространственно-временных отношений и улучшают интерпретируемость модели.

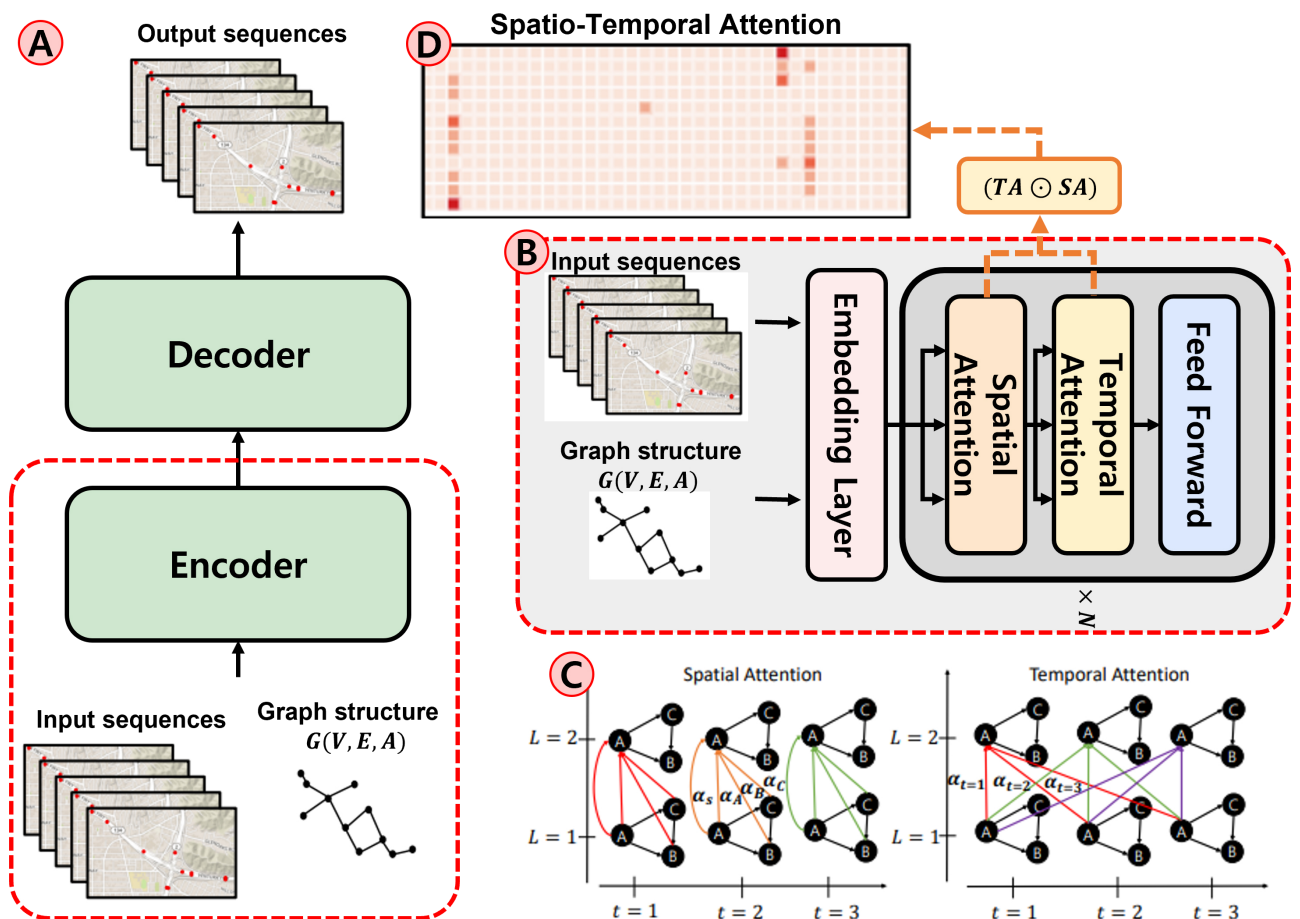


Рис. 2: Общая архитектура ST-GRAT (A). Каждый слой в кодере состоит из стека идентичных слоев (B). $G(V, E, A)$ в (A) указывает на набор узлов, связей и взвешенной матрицы смежности соответственно. Я создаю матрицу пространственно-временного внимания (D), вычисляя поэлементное умножение между весами пространственного и временного внимания (C).

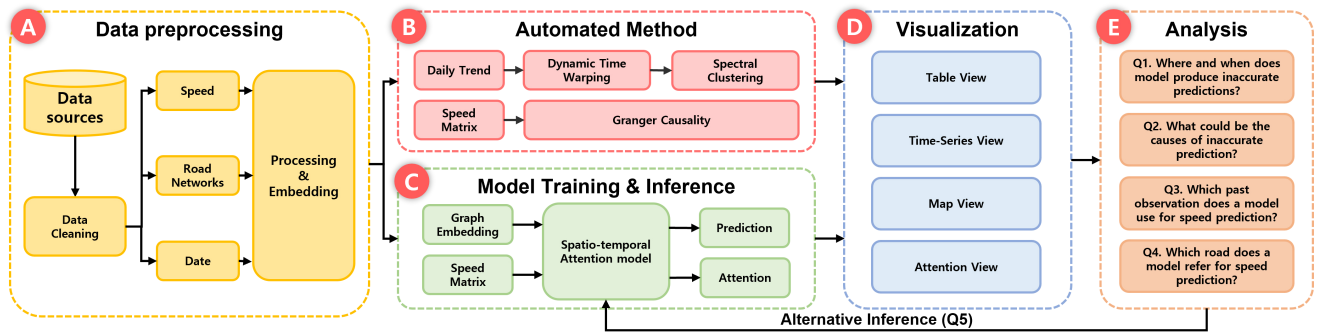


Рис. 3: Обзор рабочего процесса системы с функциональными модулями и вопросами. (A) Предварительная обработка данных, (B) автоматизированные методы поддержки пространственно-временного анализа, (C) обучение модели и вывод, (D) модули визуализации и (E) ответы на вопросы с использованием системы.

3 Введение в AttnAnalyzer

Техники визуального анализа приобрели популярность в различных областях, включая анализ транспорта. Эти методики используют интерактивные визуализации для помощи аналитикам в понимании и исследовании сложных наборов данных. В контексте анализа транспорта визуальный анализ может помочь в понимании пространственно-временных закономерностей транспортных потоков, выявлении факторов, способствующих заторам и дорожным происшествиям, а также поддержке процессов принятия решений [21].

Системы визуального анализа предоставляют интерактивные инструменты и визуализации, которые позволяют аналитикам исследовать и анализировать данные о дорожном движении интуитивно и эффективно. Визуализируя пространственные и временные закономерности транспортных потоков, аналитики могут выявлять тенденции, выявлять аномалии и получать представление о поведении транспорта. Эти системы часто включают алгоритмы машинного обучения и методы исследования данных для облегчения исследования и интерпретации данных о дорожном движении [21, 7, 6].

В данном разделе я представляю дизайн системы и методологию, которую я разработал для решения задач, вытекающих из обсуждений с экспертами в предметной области. Основной целью моей системы, названной **AttnAnalyzer**, является предоставление платформы визуального анализа для изучения поведения и производительности моделей прогнозирования транспорта.

3.1 Описание задачи и условий

Для разработки моей системы я сотрудничал с тремя экспертами в области корпоративной организации, которая занимается значительным объемом картографических и навигационных услуг. Эти эксперты предоставили ценные знания о проблемах, с которыми они сталкиваются при оптимизации навигационных услуг, и ограничениях существующих моделей машинного обучения. В результате обширных обсуждений на протяжении 18 месяцев были выявлены следующие условия к задаче:

- **Условие R1:** Система должна выделять дороги с низкой точностью и предоставлять информацию о том, когда модель производит неточные прогнозы.
- **Условие R2:** Система должна предоставлять эффективные методы для исследования закодированных пространственно-временных зависимостей между дорогами для выявления причин неточных прогнозов и понимания, какие прошлые наблюдения модель использует для прогнозирования скорости.
- **Условие R3:** Система должна поддерживать пользователей в формулировании и проверке гипотез для улучшения точности модели и предоставлять информацию о том, насколько можно ожидать улучшения.

Эти условия были сформулированы на основе вопросов, заданных экспертами, таких как выявление неточных прогнозов, понимание причин неточностей и улучшение производительности модели на различных типах дорожных сетей. Кроме того, следующие вопросы были учтены для предоставления более глубокого понимания поведения модели и зависимостей.

- **Q1:** В каких местах и в какое время модель генерирует неточные прогнозы?
- **Q2:** Какие потенциальные факторы способствуют неточностям в прогнозах?
- **Q3:** Какие исторические (комбинации) наблюдения использует модель для прогнозирования скорости?
- **Q4:** К какой конкретной дороге модель обращается для прогнозирования скорости?
- **Q5:** Какие стратегии могут быть использованы для повышения точности модели?
- **Q6:** Как модель работает в различных конфигурациях дорожной сети?

Среди этих вопросов Q1 и Q2 имеют первостепенное значение, в то время как Q3 и Q4 служат вспомогательными вопросами, которые требуют разъяснения для более полного ответа на Q1 и Q2. Q5 можно рассматривать как вопрос, направленный на повышение конкурентоспособности на рынке, а Q6 представляет собой окончательный вопрос, требующий внимания перед внедрением в реальные условия.

На основе обсуждений были выделены следующие условия к системе визуального анализа (VA), спроектированной для изучения поведения моделей прогнозирования дорожного движения и повышения их производительности. В первую очередь, поскольку важно выявлять проблемные дороги, связанные с данной моделью, **(R1) VA-система должна выделять дороги, проявляющие недостаточную точность, и предоставлять информацию о случаях, когда точность модели снижается (Q1)**. Учитывая, что модели предсказывают предстоящие скорости через пространственно-временные взаимосвязи между дорогами, **(R2) система должна предоставлять метод для эффективного исследования этих**

закодированных взаимосвязей (Q2–Q4), позволяя пользователям выявлять доказательства корреляции между повышенными ошибками и паттернами скорости [22, 6]. Примеры данных, поддерживающие исследование пространственно-временных зависимостей, включают в себя **(R2-1) исторические тенденции движения на дорогах, паттерны распределения скорости, стандартное отклонение, ежедневные тенденции скорости (Q3, Q4)**, и **(R2-2) понимание поведения модели (Q2–Q5)**, включая дороги, влияющие на прогноз модели (т.е., дороги, влияющие на прогнозы для конкретной целевой дороги [23]) и критические входные последовательности для прогнозов. Выявление дорог, влияющих на производительность прогноза для данной дороги, часто представляло сложности для пользователей [6]. Несмотря на то, что предыдущие исследования продемонстрировали [23] сильную взаимосвязь соседних дорог и дорог, связанных вторично и третично через перекрестные проверки, методики определения того, ссылается ли целевая дорога на подходящие соседние дороги, были редкими. Следовательно, **система также должна предоставлять понимание сходства временных данных и причинных связей между дорогами (Q2–Q4)**. Наконец, для облегчения формулирования и проверки гипотез пользователями, **(R3) система должна предоставлять метод для демонстрации потенциального улучшения, которое пользователи могут ожидать (Q5, Q6)**.

Интегрируя выведенные условия к задаче и исследовательские вопросы в мой дизайн системы, я стремлюсь предоставить комплексное решение, которое дает экспертам возможность получить более глубокое понимание поведения и производительности моделей прогнозирования дорожного движения.

3.2 Интеграция методов динамической временной трансформации (DTW) и тестов причинности Грейнджера

Для анализа пространственно-временных зависимостей в данных о дорожном движении AttnAnalyzer интегрирует использование метода динамической временной трансформации (DTW) и тестов причинности Грейнджера.

- 1. Метод динамической временной трансформации (DTW):** В контексте анализа движения DTW может использоваться для сравнения сходства двух временных рядов движения с разных мест или разных временных периодов. AttnAnalyzer использует DTW для измерения сходства между паттернами движения в разных участках дороги. Путем кластеризации временных рядов на основе их расстояний DTW аналитики могут выявлять группы участков с аналогичными паттернами движения и получать представление о временных зависимостях и трендах в потоке движения.
- 2. Тесты причинности Грейнджера:** В контексте анализа движения тесты причинности Грейнджера могут использоваться для определения причинно-следственных связей между различными датчиками в дорожной сети. AttnAnalyzer использует тесты причинности Грейнджера для анализа зависимостей между различными участками дороги

и выявления факторов, способствующих заторам и дорожным происшествиям. Путем анализа причинности Грейнджера между различными парами датчиков аналитики могут получать представление о потоке движения в сети и выявлять потенциальные узкие места или участки заторов.

3.3 Обзор различных представлений и визуализаций, предоставляемых AttnAnalyzer

AttnAnalyzer предоставляет разнообразные представления и визуализации для поддержки исследования данных, выбора характеристик и интерпретации модели. Среди них:

1. **Представление на карте:** Представление на карте отображает дорожную сеть и визуализирует атрибуты движения, такие как скорость, объем и уровень заторов. Пользователи могут взаимодействовать с представлением на карте, чтобы выбирать конкретные участки дорог, увеличивать или уменьшать масштаб и исследовать пространственное распределение паттернов движения. Различные цвета или значки могут представлять разные атрибуты движения, что позволяет пользователям выявлять интересующие области и наблюдать изменения со временем.
2. **Представление временных рядов:** Представление временных рядов отображает исторические и прогнозируемые данные о дорожном движении для выбранных участков дороги. Оно позволяет пользователям анализировать временные паттерны, выявлять аномалии и сравнивать разные временные периоды. Пользователи могут взаимодействовать с представлением временных рядов, чтобы выбирать конкретные временные интервалы, настраивать степень детализации временных рядов и увеличивать масштаб для детального изучения вариаций движения.
3. **Представление матрицы внимания:** Представление матрицы внимания визуализирует матрицы внимания, созданные моделью ST-GRAT. Оно отображает веса, назначенные разным участкам дороги и временным периодам для прогнозов. Пользователи могут исследовать матрицы внимания, чтобы понять, как модель назначает важность различным атрибутам и выявлять участки дороги, оказывающие значительное влияние на прогнозы. Представление матрицы внимания повышает интерпретируемость модели ST-GRAT, предоставляя информацию о ее внутренних механизмах.

Предоставляя эти различные представления и визуализации, AttnAnalyzer позволяет аналитикам взаимодействовать с данными о дорожном движении, выявлять значимые характеристики и получать более глубокое понимание пространственно-временных зависимостей в дорожном движении. Это поддерживает обоснованные решения и облегчает улучшение стратегий управления транспортными потоками.

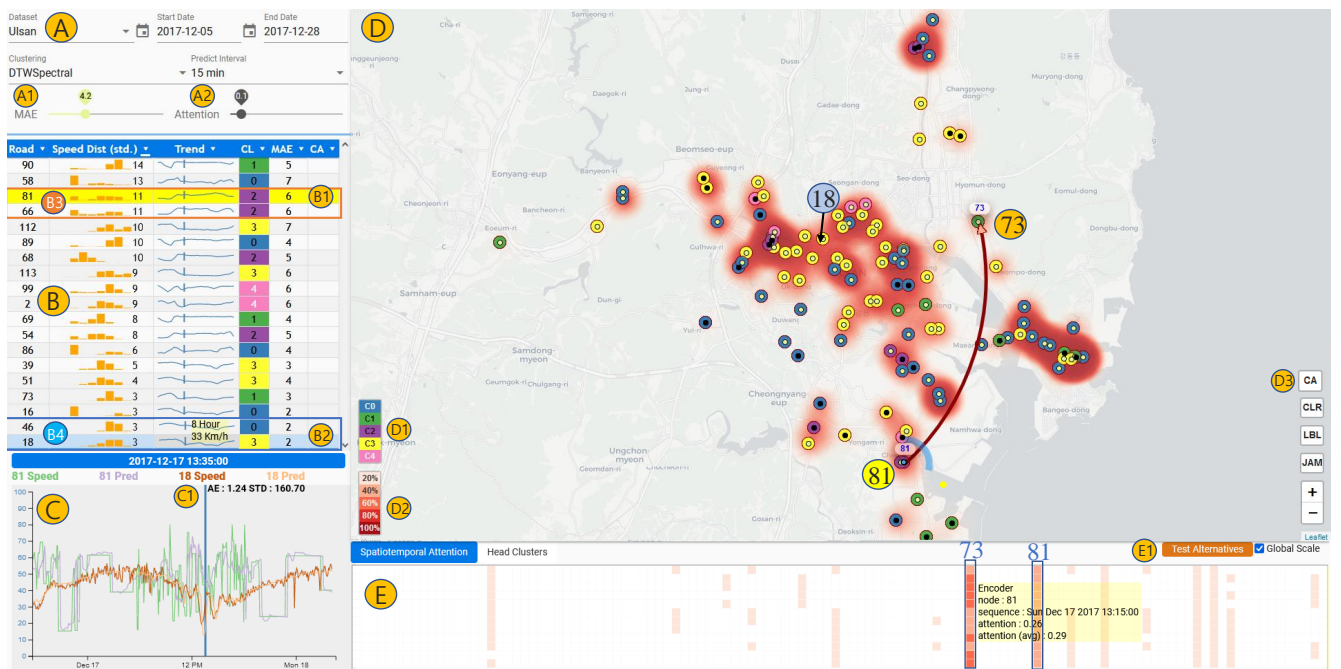


Рис. 4: **AttnAnalyzer**: Моя система визуальной аналитики для анализа того, как модель глубокого обучения с вниманием прогнозирует транспортные заторы. (а) вид фильтра, (б) вид таблицы, (с) сравнение результатов истинных значений и прогнозов, (д) карта с кривыми внимания и кластерами и (е) вид карты внимания в виде тепловой карты.

4 Анализ модели и результаты экспериментов по производительности

4.1 Кейс-исследования, демонстрирующие эффективность AttnAnalyzer

Я провожу два кейс-исследования на разных дорожных сетях реального мира, а именно на городской дорожной сети и сети автодорог, чтобы продемонстрировать эффективность AttnAnalyzer в исследовании поведения модели и улучшении ее производительности. Эти кейс-исследования включают в себя:

1. **Сравнительный анализ:** Я сравниваю поведение модели на разных дорожных сетях, таких как городская и автомагистральная, интегрированных в AttnAnalyzer. Я оцениваю их предсказательную точность с использованием количественных метрик и анализирую матрицы внимания для понимания закономерностей в улавливании пространственно-временных зависимостей.
2. **Анализ влияющих факторов:** Я использую AttnAnalyzer для анализа матриц внимания и выявления влияющих факторов на прогнозы по дорожному движению. Путем изучения весов, назначенных различным дорогам и временным периодам, я могу определить дороги, которые значительно влияют на дорожные условия, и раскрыть основные закономерности или корреляции, вносящие вариации в движение. Этот анализ помогает понять важные факторы, которые следует учитывать при управлении и прогнозировании дорожного движения.
3. **Улучшение модели:** На основе идей, полученных с помощью матриц внимания и анализа влияющих факторов, я демонстрирую, как AttnAnalyzer может использоваться для улучшения производительности моделей прогнозирования движения. Путем включения выявленных значимых факторов или настройки механизма внимания я заменяю матрицу весов моделей и оцениваю их улучшенную производительность с использованием количественных метрик. Это показывает потенциал AttnAnalyzer в оптимизации моделей прогнозирования дорожного движения.

Эти кейс-исследования были выбраны как репрезентативные сценарии использования на основе обратной связи от экспертов в предметной области. Первое кейс-исследование сосредотачивается на городской дорожной сети в Ульсане, Южная Корея, с использованием данных DSRC, в то время как второе кейс-исследование анализирует сеть автодорог с использованием данных METR-LA. Дороги были разделены на группы с высокой и низкой ошибкой на основе их средней абсолютной ошибки (MAE), где группа с высокой ошибкой состояла из дорог с MAE выше третьего квартиля (Q3), а группа с низкой ошибкой включала дороги с MAE ниже первого квартиля (Q1).

4.1.1 Описание данных

В этой работе я использовал данные о дорожном движении двух разных сетей дорог - городской и магистральной, - чтобы исследовать процесс вывода модели для прогнозирования скорости. Для городской сети дорог я использовал данные о дорожном движении на коротком диапазоне (DSRC) [24], сгенерированные в Ульсане, Южная Корея (период: 1 сентября 2017 года - 28 декабря 2017 года), где на 2017 год жило более 1,1 миллиона человек с более чем 540 000 зарегистрированными автомобилями. Всего было использовано 116 сенсоров DSRC для сбора данных, установленных каждые 5,7 км и охватывающих 68 главных дорог. Для магистральной сети дорог я использовал данные METR-LA [25], собранные с 207 петлевых детекторов (период: 1 марта 2012 года - 27 июня 2012 года) на автострадах Лос-Анджелеса. Можно заметить, что данные сети автомагистралей, использованные в данной работе, являются стандартными бенчмарк-данными для задач прогнозирования дорожного движения [26, 27, 28]. После обсуждения с представителями отрасли и обзора результатов обучения, я заменил отсутствующие данные и явные ошибки историческими данными. Также я использовал данные с агрегацией по 5 минут для смягчения возможных эффектов выбросов, как это делалось во многих предыдущих исследованиях (например, [29]).

4.2 Эксперимент по улучшению ST-GRAT с использованием принудительных весов

Резюме результатов, полученных с использованием **AttnAnalyzer**, следующее:

1. **Вывод 1:** Когда скорость дороги испытывает значительные колебания, частота ошибок модели увеличивается.
2. **Вывод 2:** Модель часто испытывает трудности в выявлении актуальных ссылок с предшествующими трендами скорости.
3. **Вывод 3:** Модель теряет важную прошлую информацию о самореференции, рассеивая внимание на менее важные дороги.

Чтобы улучшить производительность модели на основе этих результатов, исследователь применил метод усиления внимания, продемонстрированный в представлении внимания. Сначала она выбрала четыре кластера, показывающих диагональный паттерн в Голове 4, как указано зеленой пунктирной рамкой на рисунке 5 (вверху). Нажав кнопку «Проверить альтернативы», отобразилось новое представление с двумя графиками для сравнения производительности (рисунок 4).

При анализе графика были замечены значительные изменения в производительности исходной модели, что свидетельствует об улучшении. На рисунке 6 показано, как мой подход в целом устраняет ошибки. Например, при изучении графика данных METR-LA было обнаружено уменьшение числа дорог с абсолютной ошибкой (AE) примерно на 30, в то время как увеличилось число дорог с AE около 5. Подобные тенденции были замечены и в данных

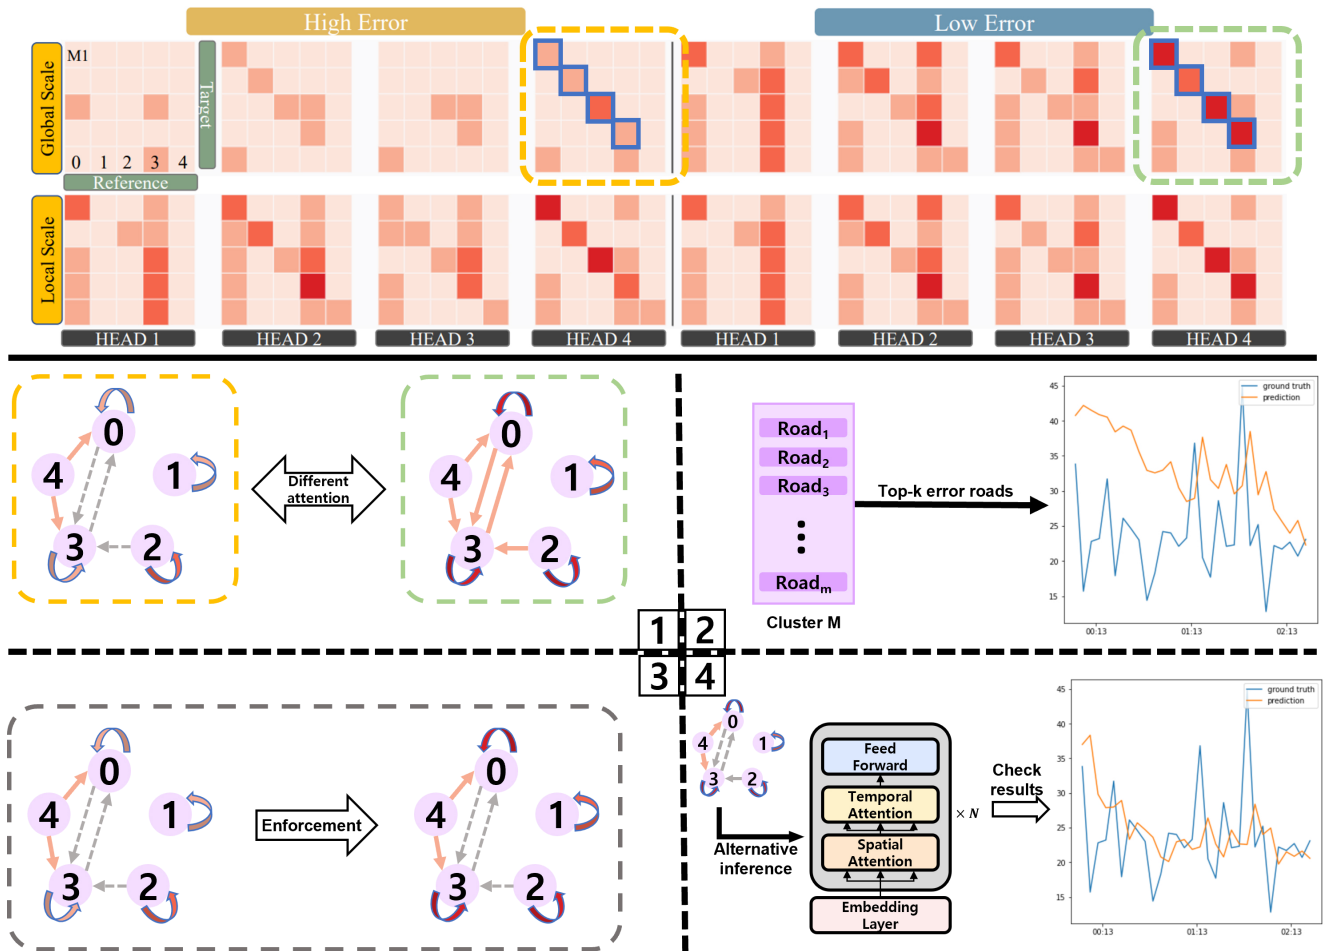


Рис. 5: (Вверху) Вид представления кластера голов с четырьмя внимательными головами, (Внизу) Процесс принудительного внимания - 1) сравнение внимания между случаями с низкой (слева) и высокой (справа) ошибкой, 2) выбор k дорог с наибольшей ошибкой в каждом кластере, 3) замена внимания выбранных дорог на внимание от дорог с низкой ошибкой и 4) проверка альтернатив.

Ульсана, где уменьшилось число дорог с АЕ около 20, и увеличилось число дорог с АЕ около 5.

Эти улучшения были приписаны методу принудительного внимания, который направлял внимание модели на самореференцию и дороги с предшествующими скоростными паттернами в пределах тех же кластеров. Внимание к результатам 2 и 3 исследований значительно улучшило производительность модели, как показано в таблице 1.

4.3 Обратная связь и валидация со стороны экспертов в предметной области

Активно собирая обратную связь и проводя валидацию со стороны экспертов в области, я уделяю особое внимание практической значимости и применимости AttnAnalyzer. Я сотрудничаю с инженерами по машинному обучению в области управления транспортом и аналитиками данных, обладающими опытом в прогнозировании и управлении дорожным движением. Эксперты в области участвуют в процессах проектирования, разработки и оцен-




Рис. 6: Результат применения метода принудительного внимания, представлен распределением ошибок.

Таблица 1: Улучшенная точность с использованием результатов моего визуального анализа. Используется 10% дорог с наивысшей ошибкой.

Набор данных	Метод	15 мин	30 мин	60 мин	Среднее
Ульсан	Графовая WaveNet	9.57	9.87	10.52	9.98
	ST-GRAT	8.70	9.00	9.52	8.98
	Принудительное внимание с DTW	8.23	8.43	8.81	8.39
	Принудительное внимание с DTW + Грейнджер	8.24	8.37	8.76	8.37
METR-LA	Графовая WaveNet	6.68	8.17	11.66	8.83
	ST-GRAT	6.08	7.43	10.61	7.68
	Принудительное внимание с DTW	6.06	7.38	10.24	7.55
	Принудительное внимание с DTW + Грейнджер	6.04	7.28	10.08	7.48

ки AttnAnalyzer.

Провожу исследования с экспертами в области с целью сбора их обратной связи относительно удобства использования, эффективности и интерпретируемости визуальных аналитических возможностей AttnAnalyzer. С помощью интервью, опросов и практических демонстраций я собираю качественные отзывы о том, насколько полезен AttnAnalyzer в их рабочем процессе, какие наработки они получают из анализа, и ограничения или области для улучшения. Эта обратная связь является бесценной для совершенствования и улучшения функционала AttnAnalyzer, чтобы более полно соответствовать потребностям целевой группы пользователей.

Более того, я провожу валидацию результатов и рекомендаций, генерируемых AttnAnalyzer, с помощью экспертов в области. Эта валидация включает в себя сравнение результатов анализа и рекомендаций от AttnAnalyzer с знаниями и экспертизой экспертов в данной области. Их валидация помогает обеспечить точность и надежность AttnAnalyzer в предоставлении наработок и информации для управления транспортом и процессами принятия решений.

Процесс обратной связи и валидации со стороны экспертов в области укрепляет доверие и эффективность AttnAnalyzer как практического инструмента для анализа и прогнозирования транспорта.

Таблица 2: Точность прогнозов ST-GRAT и PM-MemNet на наборе данных Лос-Анджелес

	T	Метрика	GCRNN	DCRNN	GaAN	STGCN	Graph WaveNet	HyperST	GMAN	ST-GRAT	PM-MemNet
METR-LA	15 мин	MAE	2.80	2.73	2.71	2.88	2.69	2.71	2.81	2.60	2.65
		RMSE	5.51	5.27	5.24	5.74	5.15	5.23	5.55	5.07	5.29
		MAPE	7.5%	7.12%	6.99%	7.62%	6.90%	-	7.43%	6.61%	7.01%
	30 мин	MAE	3.24	3.13	3.12	3.47	3.07	3.12	3.12	3.01	3.03
		RMSE	6.74	6.40	6.36	7.24	6.26	6.38	6.46	6.21	6.29
		MAPE	9.0%	8.65%	8.56%	9.57%	8.37%	-	8.35%	8.15 %	8.42%
	1 час	MAE	3.81	3.58	3.64	4.59	3.53	3.58	3.46	3.49	3.46
		RMSE	8.16	7.60	7.65	9.40	7.37	7.56	7.37	7.42	7.29
		MAPE	10.9%	10.43%	10.62%	12.70%	10.01%	-	10.06%	10.01%	9.97%
	Среднее	MAE	3.28	3.14	3.16	3.64	3.09	3.13	3.13	3.03	2.99
		RMSE	6.80	6.42	6.41	7.46	6.26	6.39	6.46	6.23	6.14
		MAPE	9.13%	8.73%	8.72%	9.96%	8.42%	-	8.61%	8.25%	8.27%

5 Заключение

В данной диссертации я предпринял всестороннее исследование улучшения анализа пространственно-временных данных и прогнозирования дорожного движения с помощью разработки и совершенствования новых моделей и инструментов визуализации. Мое исследование привело меня к созданию модели **пространственно-временной графовой нейронной сети с механизмом внимания (ST-GRAT)**, модели, разработанной для улавливания сложных зависимостей в пространственно-временных данных. С многоуровневой архитектурой, объединяющей как пространственные, так и временные механизмы внимания, ST-GRAT проявляет замечательные способности в выявлении паттернов и взаимосвязей в сложных наборах пространственно-временных данных.

Представление инновационной системы анализа с визуализацией **AttnAnalyzer** является значимым шагом в области анализа и улучшения моделей. Через AttnAnalyzer я дал исследователям и практикам возможность получать более глубокое понимание внутренней работы ST-GRAT. Путем визуализации распределения внимания и исследования интерактивных представлений выученных зависимостей пользователи могут не только понимать решения модели, но и выявлять области для улучшения и отладки.

С использованием AttnAnalyzer под моим руководством, я справился с ключевыми задачами в ST-GRAT и ввел новую эру разработки моделей. Как показано в таблице 2, успешная интеграция уроков, полученных из AttnAnalyzer, завершилась созданием **Сетей с Памятью на Основе Сопоставления Паттернов (PM-MemNet)** [30]. Эта передовая версия ST-GRAT использует мощь памяти на основе паттернов, повышая точность и надежность модели в прогнозировании. PM-MemNet является свидетельством потенциала комбинирования передовых нейронных архитектур с инновационными методами визуализации.

Мои вклады выходят за рамки теоретической области и включают в себя практические достижения в области анализа пространственно-временных данных. Объединяя модельный дизайн, анализ и улучшение, я предлагаю исследователям и практикам целостную методику для решения сложностей пространственно-временных данных. Методологии и уроки, представленные в этой диссертации, имеют потенциал революционизировать различные приложения, от городского планирования до управления дорожным движением, предоставляя

точные прогнозы и практические идеи.

Завершая данную диссертацию, я признаю непрерывную природу анализа данных и бесконечные возможности, которые лежат впереди. Путешествие, представленное здесь, лишь является ступенькой в более широком пейзаже исследований и инноваций. На фундаменте, положенном ST-GRAT, AttnAnalyzer и PM-MemNet, я надеюсь вдохновить будущих исследователей исследовать новые горизонты, расширять границы знаний и продолжать формировать будущее анализа пространственно-временных данных и не только.

Список литературы

- [1] Cheonbok Park, Chunggi Lee, Hyojin Bahng, Yunwon Tae, Seungmin Jin, Kihwan Kim, Sungahn Ko, and Jaegul Choo. St-grat: A novel spatio-temporal graph attention networks for accurately forecasting dynamically changing road speed. In *Proceedings of the 29th ACM international conference on information & knowledge management*, pages 1215–1224, 2020.
- [2] Ameet Talwalkar, Sanjiv Kumar, and Henry Rowley. Large-scale manifold learning. In *2008 IEEE Conference on Computer Vision and Pattern Recognition*, pages 1–8. IEEE, 2008.
- [3] Seungmin Jin, Hyunwook Lee, Cheonbok Park, Hyeslin Chu, Yunwon Tae, Jaegul Choo, and Sungahn Ko. A visual analytics system for improving attention-based traffic forecasting models. *IEEE transactions on visualization and computer graphics*, 29(1):1102–1112, 2022.
- [4] David Alexander Tedjopurnomo, Zhifeng Bao, Baihua Zheng, Farhana Murtaza Choudhury, and Alex Kai Qin. A survey on modern deep neural network for traffic prediction: Trends, methods and challenges. *IEEE Transactions on Knowledge and Data Engineering*, 34(4):1544–1561, 2020.
- [5] Renhe Jiang, Du Yin, Zhaonan Wang, Yizhuo Wang, Jiewen Deng, Hangchen Liu, Zekun Cai, Jinliang Deng, Xuan Song, and Ryosuke Shibasaki. Dl-traff: Survey and benchmark of deep learning models for urban traffic prediction. In *Proceedings of the 30th ACM international conference on information & knowledge management*, pages 4515–4525, 2021.
- [6] Yaguang Li and Cyrus Shahabi. A brief overview of machine learning methods for short-term traffic forecasting and future directions. *Sigspatial Special*, 10(1):3–9, 2018.
- [7] Chunggi Lee, Yeonjun Kim, Seungmin Jin, Dongmin Kim, Ross Maciejewski, David Ebert, and Sungahn Ko. A visual analytics system for exploring, monitoring, and forecasting road traffic congestion. *IEEE transactions on visualization and computer graphics*, 26(11):3133–3146, 2019.
- [8] Tianyi Zhang, Cuiyun Gao, Lei Ma, Michael Lyu, and Miryung Kim. An empirical study of common challenges in developing deep learning applications. In *2019 IEEE 30th International Symposium on Software Reliability Engineering (ISSRE)*, pages 104–115. IEEE, 2019.
- [9] Mikhail Belkin, Siyuan Ma, and Soumik Mandal. To understand deep learning we need to understand kernel learning. In *International Conference on Machine Learning*, pages 541–549. PMLR, 2018.
- [10] Chuanpan Zheng, Xiaoliang Fan, Cheng Wang, and Jianzhong Qi. Gman: A graph multi-attention network for traffic prediction. In *Proceedings of the AAAI conference on artificial intelligence*, volume 34, pages 1234–1241, 2020.

- [11] Rongzhou Huang, Chuyin Huang, Yubao Liu, Genan Dai, and Weiyang Kong. Lsgcn: Long short-term traffic prediction with graph convolutional networks. In *IJCAI*, volume 7, pages 2355–2361, 2020.
- [12] Vincent Le Guen and Nicolas Thome. Shape and time distortion loss for training deep time series forecasting models. *Advances in neural information processing systems*, 32, 2019.
- [13] Lei Zhang, Kaiqun Fu, Taoran Ji, and Chang-Tien Lu. Granger causal inference for interpretable traffic prediction. In *2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)*, pages 1645–1651. IEEE, 2022.
- [14] James Thomas and Kristin Cook. *Illuminating the Path: The Research and Development Agenda for Visual Analytics*. National Visualization and Analytics Ctr, 2005.
- [15] Zhuoning Yuan, Xun Zhou, and Tianbao Yang. Hetero-convlstm: A deep learning approach to traffic accident prediction on heterogeneous spatio-temporal data. In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pages 984–992, 2018.
- [16] Gianni Brauwers and Flavius Frasinicar. A general survey on attention mechanisms in deep learning. *IEEE Transactions on Knowledge and Data Engineering*, 2021.
- [17] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. *Advances in neural information processing systems*, 30, 2017.
- [18] Weiwei Jiang and Jiayun Luo. Graph neural network for traffic forecasting: A survey. *Expert Systems with Applications*, page 117921, 2022.
- [19] Cen Chen, Kenli Li, Sin G Teo, Xiaofeng Zou, Kang Wang, Jie Wang, and Zeng Zeng. Gated residual recurrent graph neural networks for traffic prediction. In *Proceedings of the AAAI conference on artificial intelligence*, volume 33, pages 485–492, 2019.
- [20] Qin Zhang, Keping Yu, Zhiwei Guo, Sahil Garg, Joel JPC Rodrigues, Mohammad Mehedi Hassan, and Mohsen Guizani. Graph neural network-driven traffic forecasting for the connected internet of vehicles. *IEEE Transactions on Network Science and Engineering*, 9(5):3015–3027, 2021.
- [21] Gennady Andrienko, Natalia Andrienko, Wei Chen, Ross Maciejewski, and Ye Zhao. Visual analytics of mobility and transportation: State of the art and further research directions. *IEEE Transactions on Intelligent Transportation Systems*, 18(8):2232–2249, 2017.
- [22] Chenyi Chen, Yin Wang, Li Li, Jianming Hu, and Zuo Zhang. The retrieval of intra-day trend and its influence on traffic prediction. *Transportation research part C: emerging technologies*, 22:103–118, 2012.

- [23] Shengmin Guo, Dong Zhou, Jingfang Fan, Qingfeng Tong, Tongyu Zhu, Weifeng Lv, Daqing Li, and Shlomo Havlin. Identifying the most influential roads based on traffic correlation networks. *EPJ Data Science*, 8(1):1–17, 2019.
- [24] John B Kenney. Dedicated short-range communications (dsrc) standards in the united states. *Proceedings of the IEEE*, 99(7):1162–1182, 2011.
- [25] Zonghan Wu, Shirui Pan, Guodong Long, Jing Jiang, and Chengqi Zhang. Graph wavenet for deep spatial-temporal graph modeling. *arXiv preprint arXiv:1906.00121*, 2019.
- [26] Yaguang Li, Rose Yu, Cyrus Shahabi, and Yan Liu. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting. *arXiv preprint arXiv:1707.01926*, 2017.
- [27] Bing Yu, Haoteng Yin, and Zhanxing Zhu. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. In *Proceedings of the 27th International Joint Conference on Artificial Intelligence (IJCAI)*, 2018.
- [28] Tanwi Mallick, Prasanna Balaprakash, Eric Rask, and Jane Macfarlane. Transfer learning with graph neural networks for short-term highway traffic forecasting. In *2020 25th International Conference on Pattern Recognition (ICPR)*, pages 10367–10374. IEEE, 2021.
- [29] Jiani Zhang, Xingjian Shi, Junyuan Xie, Hao Ma, Irwin King, and Dit-Yan Yeung. Gaan: Gated attention networks for learning on large and spatiotemporal graphs. *arXiv preprint arXiv:1803.07294*, 2018.
- [30] Hyunwook Lee, Seungmin Jin, Hyeslin Chu, Hongkyu Lim, and Sungahn Ko. Learning to remember patterns: Pattern matching memory networks for traffic forecasting. In *International Conference on Learning Representations*, 2021.