МЕТОД ПРОГНОЗИРОВАНИЯ ТРАФИКА ПУТЕМ МУЛЬТИМОДАЛЬНОГО АГРЕГИРОВАНИЯ ПРОСТРАНСТВЕННО-ВРЕМЕННЫХ ИСХОДНЫХ КАРТ С ПОМОЩЬЮ ГЕТЕРОГЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Х. Се[1], В.С. Смолин[2], Х. Шэн[1]

[1]*МГУ имени М.В. Ломоносова, г. Москва*
[2]*ИПМ им. М.В. Келдыша РАН, г. Москва*

hajhaose@gmail.com, smolin@keldysh.ru, haoyuishen@yandex.ru

При прогнозировании дорожного движения необходимо учитывать топологические ограничения дорожной сети и динамические пространственно-временные закономерности, но традиционные методы, такие как STGCN [1] (Spatio-temporal Graph Convolutional Networks), основаны на статических матрицах смежности, с помощью которых трудно уловить динамические связи, вызванные трудно прогнозируемыми факторами, такими как изменения погоды и дорожно-транспортные происшествия. Также традиционные методы не учитывают ограничения физической структуры [2]. В качестве пути преодоления указанных ограничений в настоящей работе предлагается использовать мультимодальный метаграф с расширенной структурой моделирования пространственно-временной неоднородности, который объединяет функциональные атрибуты объектов, погодные явления и данные о дорожном движении в реальном времени для построения динамической графовой структуры семантического восприятия. В частности, разработан мультимодальный пространственно-временной генератор метаграфов, использующий сеть graph attention network (GATv2 [3]) для кодирования функционального сходства узлов (например, весов взаимодействия коммерческих районов и станций метро) в сочетании с диффузионной сверткой для сопоставления интенсивности осадков с коэффициентом замедления дорожной сети. Также предлагается динамически корректировать матрицу смежности с помощью стробирующего механизма для реализации моделирования связи физической топологии и внешних событий. Формула выражается следующим образом:

$$A'_{ij} = A_{ij}^{\text{phys}} \odot \sigma\left(W_g\left[w_{ij}^{\text{poi}} || h_i^{\text{rain}} || h_j^{\text{rain}}\right]\right)$$

A'_{ij} – динамические веса соседства между узлами i и j. A_{ij}^{phys} – матрица физических соседств (например, физически связаны дороги или нет). $\odot$ – произведение Адамарда (умножение на элемент) для объединения физических кварталов с динамическими поправочными коэффициентами. σ – сигмоидальная функция, которая сжимает выход в диапазон [0,1] в качестве коэффициента корректировки веса. W_g – обучаемая матрица весов для отображения признаков. || – операция сращивания векторов (конкатенация). w_{ij}^{poi} – сходство POI (точек интереса) между узлом и местоположением

(например, совпадение распределения коммерческих и жилых районов). h_i^{rain} – характеристики осадков (например, интенсивность осадков, влияние осадков в прошлом и т. д.) для узла i. В графовых нейронных сетях узлы i и j обычно представляют две сущности или места в сети в зависимости от сценария применения. В нашем методе прогнозирования трафика каждый узел представляет местоположение датчика трафика (например, геосоты, камеры), дорожный перекресток).

Исходя из этого мы внедряем модуль пространственно-временного внимания с учетом каналов, используем внимание к многоглавому графу в пространственном измерении для усиления функциональной зависимости узлов (например, для распространения заторов в коммерческих районах [4]) и интегрируем деформируемую свертку и глобальное внимание во временном измерении [5], чтобы фиксировать локальные изменения, периодические колебания погоды и события и моделировать эффекты межмодальной связи с помощью механизмов перекрестного внимания (таких как ассоциация «сильный дождь – деловой район – вечерний час пик»).

Чтобы преодолеть ограничения традиционной статической графовой структуры, она заменяется динамической гетерогенной графовой структурой, строятся семантические мета-пути (такие как «раздел A – период времени-погода – раздел B») для управления неявным корреляционным анализом, а также используется гетерогенный граф. Нейронные сети (HGNN [6]) позволяют изучать динамические веса границ и объединять механизмы реагирования на события в реальном времени (такие как обнаружение дорожно-транспортных происшествий) для обновления матрицы смежности. С помощью физико-семантического моделирования с двумя модальностями этот метод позволяет четко различать функциональные характеристики дорожной сети и дифференцированные последствия чрезвычайных ситуаций, таких как проливные дожди, которые приводят к значительному увеличению коэффициента распространения заторов вокруг эпицентра события.

В работе предполагается, что механизм иерархического внимания оптимизирует учет разнородных знаний за счет двойного динамического моделирования на уровне узлов и на уровне траектории: на уровне узлов различаются разнородные типы узлов, такие как датчики дорожного движения, метеостанции и кластеры POI (например, ограничение участия узлов метеостанций только в связанных с погодой процессах взаимодействия) и динамический расчет корреляционных весов перекрестных типов узлов (например, количественная оценка коэффициента влияния станций метро на вечерний пик трафика близлежащих участков) для достижения точного семантического выравнивания мультимодальных узлов; на уровне путей он присваивает динамическую важность таким метапутям как «участок дороги – погодные условия – событие» (например, увеличение веса маршрута «авария – затор» в сценариях сильного дождя), в то время как поддержка мультимодальных узлов, основанных на семантическом метапутешествии сцены, выбирается адаптивно (например, маршрут пригородного сообщения

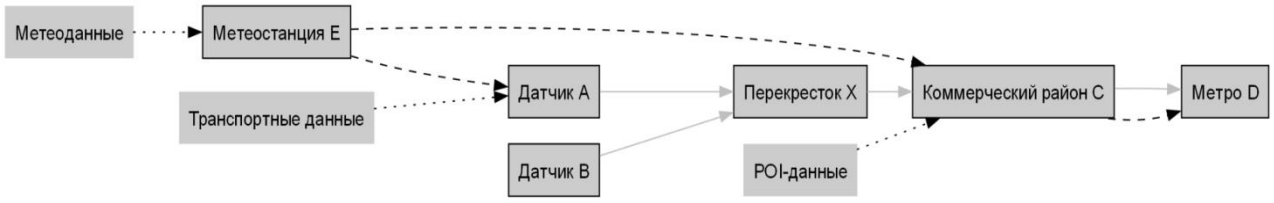

Рис. 1. Пример пространственно-временной диаграммы элементов.

в будние дни и маршрут делового района по праздникам), чтобы явно смоделировать взаимосвязь между физической топологией и внешними событиями и завершить динамическую реконструкцию и семантическое расширение структуры знаний пространственного гетерогенного графа.

Основное новшество настоящей работы заключается в оптимизации мультимодального объединения пространственно-временных метадиаграмм и разработке механизма учета разнородных знаний, который не только сохраняет преимущества моделирования свертки графа в топологии, но и повышает адаптивность сложных пространственно-временных моделей за счет динамического распределения весов.

На рисунке 1 представлены: метеостанция E – узел-источник погодных данных для анализа влияния погоды на другие сценарии (например, дорожное движение); датчики A и B – отвечают за сбор данных о трафике (например, транспортный поток, скорость и т.д.) и являются конечным пунктом сбора информации о трафике; перекресток X – узел транспортного узла, он напрямую связан с датчиками трафика, что отражает связь с физическим местоположением; коммерческая зона C – ассоциированные данные POI (Point of Interest), используемые для описания функциональных атрибутов зоны (например, коммерческой деятельности, распределения объектов); станция метро D – представляет собой узел транспортной инфраструктуры, интегрированный в мультимодальный метаграф.

В дальнейших работах планируется изучить систематическое усовершенствование исследовательской структуры в многоинтеллектуальной архитектуре, объединяющей нейронные сети с гетерогенными графами (HGNN) и теорию динамических игр. В нашей архитектуре статические элементы, такие как расположение светофора и топология дороги, и динамические элементы, такие как характеристики движения транспортных средств и пешеходов [7], единообразно кодируются как узлы гетерогенного графа, что является частью архитектуры, представляющей гетерогенные элементы. Другой важной частью архитектуры является моделирование динамических игр, которое представляет эволюционную теорию игр для анализа интересующих взаимодействий между транспортными средствами и пешеходами и различными режимами движения (например, правоповоротные транспортные средства, конкурирующие с пешеходами за право проезда) [8], и устанавливает механизм поминутного обновления стратегии путем количественной оценки эволюционных законов группового поведения (например, равновесия Нэша). Точность и своевременность прогнозов для многоинтеллектуальных систем

взаимодействия тел при внезапных перегрузках (например, во время крупномасштабных мероприятий) можно дополнительно повысить за счет гетерогенной характеристики элементов и динамического игрового моделирования.

Список литературы:

1. Bing Yu, Haoteng Yin, 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. Pp. 3634–3640. https://doi.org/10.24963/ijcai.2018/505
2. Song C., Lin Y., Guo S., Wan H. Spatial-Temporal Synchronous Graph Convolutional Networks: A New Framework for Spatial-Temporal Network Data Forecasting // Proceedings of the AAAI Conference on Artificial Intelligence. 2020. Vol. 34. Issue 01. Pp. 914–921. https://doi.org/10.1609/aaai.v34i01.5438
3. Brody S., Alon U., Yahav E. How Attentive are Graph Attention Networks? // 2022. arXiv:2105.14491. https://doi.org/10.48550/arXiv.2105.14491
4. Zhang J., Chen Y., Wang T. [et al.]. Mixture of Spatial–Temporal Graph Transformer Networks for urban congestion prediction using multimodal transportation data // J. Expert Systems with Applications. 2025. Vol. 268 Issue 2. P. 126108. https://doi.org/10.1016/j.eswa.2024.126108
5. Ronghui Xu, Hanyin Cheng, Chenjuan Guo, Hongfan Gao, Jilin Hu, Sean Bin Yang, Bin Yang. MM-Path: Multi-modal, Multi-granularity Path Representation Learning – Extended Version. // 2024. arXiv:2411.18428 https://doi.org/10.48550/arXiv.2411.18428
6. Zhao J., Wang X., Shi C., Hu B., Song G., Ye Y. Heterogeneous Graph Structure Learning for Graph Neural Networks // Proceedings of the AAAI Conference on Artificial Intelligence. 2021. Vol. 35. Issue 5. Pp. 4697–4705. https://doi.org/10.1609/aaai.v35i5.16600
7. Meng Chen, Zechen Li, Weiming Huang, Yongshun Gong, Yilong Yin. Profiling urban streets: A semi-supervised prediction model based on street view imagery and spatial topology // In KDD '24: Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining 2024. Pp. 319–328. https://doi.org/10.1145/3637528.3671918
8. Шмыглёв Д.Н., Судаков В.А. Модель обучения с подкреплением для оптимизации автопарка предприятия // Препринты ИПМ им. М.В.Келдыша. 2024. № 39. 13 с. https://keldysh.ru/papers/2024/prep2024_39.pdf