

城市交通路网动态短时推理与精准预测研究

覃缘琪¹, 季青原², 葛俊¹, 戴星原³, 陈圆圆³, 王晓^{3,4}

(1. 之江实验室, 浙江 杭州 310000; 2. 银江技术股份有限公司, 浙江 杭州 310030;

3. 中国科学院自动化研究所复杂系统管理与控制国家重点实验室, 北京 100190; 4. 青岛智能产业技术研究院, 山东 青岛 266000)

摘要: 城市路网结构对于交通拥堵的形成及其在时空上的传播过程具有重要的影响。然而, 在基于传统交通模型或深度学习模型的研究中, 交通模式的生成与传播往往并未考虑路网特征, 且只能通过交通特征指标进行间接刻画, 使得难以动态描述其在时间及空间维度上的特征, 导致交通模式传播预测精度不高且缺乏针对性。为了解决上述问题, 提出了一种新型的基于交通模式推理的交通预测框架 TP²。该框架将拥堵传播模式建模为一个随时间变化的时序知识图谱, 并使用一种包含了全新聚合函数 RGrAN 的推理框架进行时序推理, 以捕捉交通拥堵的动态时变传播模式, 将路段和与其存在交通模式关联的路段进行组合, 并构建时空关联路网子区域, 然后基于图神经网络的交通短时预测模块充分挖掘子区内的交通流时空相关性, 并预测子区内各个路段的未来速度变化情况。与现有方法相比, TP² 预测精度相比 A3T-GCN 模型有 1%~2% 的提升。

关键词: 路网结构; 传播模式; 交通状态推理与预测; 时序知识图谱; 图神经网络

中图分类号: U495

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202233

Short-term traffic state reasoning and precise prediction in urban networks

QIN Yuanqi¹, JI Qingyuan², GE Jun¹, DAI Xingyuan³, CHEN Yuanyuan³, WANG Xiao^{3,4}

1. Zhejiang Lab, Hangzhou 310000, China

2. Enjoyor Technology Co., Ltd., Hangzhou 310030, China

3. The State Key Laboratory for Management and Control of Complex Systems, Institute of Automation,
Chinese Academy of Sciences, Beijing 100190, China

4. Qingdao Academy of Intelligent Industries, Qingdao 266000, China

Abstract: The structure of urban traffic network has a significant impact on the formation and spatio-temporal pattern propagation of traffic congestions. However, in studies based on traditional traffic models or deep learning models, the generation of traffic mode can only be described indirectly by traffic indicators, without considering the traffic network feature. This makes it very difficult to accurately describe the propagation dynamics both in temporal and spatial dimensions and lacks specificity. To tackle the above-mentioned problems, a novel traffic state prediction approach based on traffic pattern reasoning (TP²) framework was proposed. The framework modeled congestion propagation as a dynamically evolving temporal knowledge graph (TKG), and applied an inferencing framework (TPP-TKG) that was based on a novel aggregator called RGrAN. TPP-TKG captured the spatial-temporal propagation pattern of traffic congestion, and combined related road links to a given link, and constructed correlated sub region of the traffic network. Then a traffic state predicting based on graph neural network was employed to predict short-term speed evolution of road links in this sub region. Comparing to the state-of-the-art benchmark models, TP² achieves 1% ~ 2% higher accuracy.

Key words: traffic network structure, propagation mode, traffic mode reasoning and prediction, temporal knowledge graph, graph neural network.

收稿日期: 2022-05-18; 修回日期: 2022-07-10

通信作者: 王晓, x.wang@ia.ac.cn

基金项目: 国家重点研发计划基金资助项目 (No.SQ2019YFE012476)

Foundation Item: The National Key Research and Development Program of China (No.SQ2019YFE012476)

0 引言

在我国社会主义现代化建设进程中，城市交通运输业已逐渐成为支撑国家发展的重要基建之一，但伴随而来的汽车保有量剧增、温室气体排放过量、城市交通拥堵愈演愈烈等情况，在一定程度上降低了城市生活品质，引起了城市居民和主管部门的高度关注。对城市交通状态进行精准预测，并配合适当的交通管控手段，能够有效减少因交通事故或交通拥堵导致的 CO_2 排放^[1]。

交通管控的成效性依赖于对未来交通状态的准确预测，当交通路网的状态发生变化后，及时高效的交通管控是提高交通通行效率、降低碳排放以及保障通行安全的有效手段^[2]。

交通路网本身时空关联的复杂性、多样性导致在不同的交通场景下，通常呈现出差异化的交通模式传播规律。例如当单一路段的车流量超过其负载能力时，该路段往往会发生拥堵，并根据交通转向运动的规律对与之关联的路段产生复杂的时空影响，使得拥堵极易从当前路段传播至与之空间上相邻的多个路段，造成大范围的交通延误。因此，交通模式传播情况（例如模式的传播方向、模式在传播的过程中加剧或消散）的短时预测能够辅助交通运营人员预判路网交通状态走势，进而针对性地调整城市交通运营方案，对于城市交通的管控、运营与拥堵疏导具有重要的意义。

图1展示了两种城市交通路网在发生拥堵时的时空传播模式及特征。其中，图1(a)刻画了多个路段对单个路段能够产生拥堵传播关系的场景；与之对应，图1(b)刻画的是一个路段对多个路段产

生拥堵传播关系的场景。通常，交通状态预测模型是在单一交通场景和固定的交通模式下构建的^[3]，而不同交通模式下的特定交通状态预测模型的能力会有所不同，例如相比于传统模型（以城市全局路网为对象），对局部空间范围内存在拥堵传播关系的路段进行拥堵预测可能获得更高的预测精度。因此充分理解和挖掘交通模式传播规律的交通状态预测模型能够有效提升交通短时预测效果。

知识图谱和深度图神经网络技术逐渐被应用于各个领域，是目前填补该领域研究短板的潜在可行方案。其中，知识图谱技术有助于捕获宏观深层次的信息（例如发掘存在较强关联性的路段），而深度图神经网络则可以对目标特征进行精准预测（例如对短时速度的预测）。将两者结合，可以对城市路网中的重点区域（路网子图）进行高精度交通状态短时预测。

基于此，本文融合知识图谱和深度图神经网络算法，设计了基于交通模式推理的交通预测（traffic state prediction based on traffic pattern reasoning, TP^2 ）框架（以下简称 TP^2 ）。该框架可更准确地预测交通路网的短时状态，且更充分地挖掘和理解交通模式的传播规律。具体实现方式如下。将拥堵传播建模为一个会动态演化且包含多种关系的时序知识图谱（temporal knowledge graph, TKG），利用基于时序知识图谱的交通模式挖掘（traffic pattern propagation based on temporal knowledge graph, TPP-TKG ）模块（以下简称 TPP-TKG ）对其进行挖掘，定位交通模式的路网空间传播范围；基于一种循环神经网络（recurrent neural network, RNN）架构^[4]，创新性地提出了一种全新的关系图注意力




图1 交通拥堵模式传播示例

网络 (relational graph attention network, RGraAN) 聚合函数, 对 TPP-TKG 上基于不同类型的边信息进行聚合; 在任意时刻, 针对任意中心路段, TP^2 可以通过 TPP-TKG 的推理进一步推理出与之存在模式传播关系的所有路段, 将这些路段组合成局部交通关联子区域; 运用图神经网络 (graph neural network, GNN) 进行建模, 充分考虑子区域的时空关联性, 对局部路网中的路段速度进行短时预测。经过对不同模型结果的对比分析, TP^2 很好地提升了预测精准度。

本文结构如下, 第1节介绍城市路网短时交通预测的相关研究及方法, 第2节阐述 TP^2 及预测方法, 第3节描述实验设置并解释相关实验结果, 第4节对全文工作进行总结。

1 城市路网短时交通预测的相关研究

近年来, 随着终端数据感知设备的广泛普及, 用于交通状态预测的特征数据逐渐丰富, GPS 轨迹数据^[5-7]、交通流量数据^[8-9]、速度数据^[10-11]等常被用来预测短时交通状态。与此同时, 随着网约车服务向居民出行领域的不断渗透, 浮动车数据^[12]在城市环境的交通状态监测与拥堵预测上的应用已十分广泛。

根据已有的学术研究, 城市路网短时交通预测方法往往被分为以下几类: 基于统计分析的预测模型、非线性理论模型、基于仿真的预测模型、智能预测模型及混合预测模型^[13]。在交通工程领域, 基于统计分析的预测模型、非线性理论模型、基于仿真的预测模型等传统方法已经普遍用于对交通拥堵进行建模与理解, 代表性的时间序列模型包括历史平均值模型 (historic average, HA)^[14-15]、差分自回归移动平均模型 (autoregressive integrated moving average model, ARIMA model) (以下简称 ARIMA)^[16-18]、XGBoost 模型^[19-20]、向量自回归模型 (vector autoregression model, VAR)^[21]、基于子图的方法^[22]、拥堵聚类^[23]等。但是这些方法无法有效地捕获城市路网交通流的空间依赖关系与时间相关性。

而随着智能算法和混合预测模型的迭代, 深度学习模型在交通预测中得到了广泛应用^[24-30]。运用神经网络对数据深层特征进行提取的方法在交通态势感知^[31]、交通流以及拥堵预测^[32]等研究领域取得了显著进展。这类模型主要聚焦于交通流量的精

准预测和拥堵路段的实时识别, 主要包括 ST-GCN (spatial temporal graph convolutional network)^[33]、AST-GCN (attention-based spatial temporal graph convolutional network)^[34]、GMAN (graph multi-attention network)^[35]等。此外, 部分研究考虑到交通模式传播的时空关联性, 尝试对交通模式的传播规律进行探索, 并将其运用于交通状态预测模型。Nagy A M 等人^[36]基于交通传播提出一种交通预测模型 CTPM (congestion-based traffic prediction model), 对交通状态进行预测时考虑了拥堵在路网上的传播。张阳等人^[37]提出一种考虑时空关联的深度学习短时交通流预测方法, 该方法利用长短期记忆 (long short-term memory, LSTM) 提取数据间的时间关联性, 实现同时考虑时空关联性的交通流预测。

由于传统的图神经网络模型在对路网进行预测时将完整路网的特征作为输入, 训练这些模型极其消耗计算资源, 在对模型成果进行转化时往往面临计算资源与开发部署等多重难题。尽管目前关于短时交通状态预测的研究相对深入, 但同步考虑交通拥堵、交通模式和状态传播时空因素影响的研究相对较少。已有的学术研究多关注于对交通拥堵时间、传播方向和范围预测的单因素影响的研究。陈美林等人^[38]提出基于因果关联的交通拥堵传播分析方法, Nagy A M 等人^[39]提出了拥堵传播模型算法 (congestion propagation modeling algorithm, CPMA), 运用马尔可夫链对任意传播模式的传播时间及传播概率进行预测。此外, 运用知识图谱进行推理的研究虽然在多个领域得到了验证^[40-41], 但在交通状态预测领域的应用仍较为局限, 加之交通拥堵传播不仅在时间维度上具有极高的关联性, 还在空间维度存在高度的动态性和偶发性, 导致时间序列模型和深度学习模型均无法在空间上有效模拟拥堵传播并挖掘交通拥堵在时空上的相关性, 因此在实践中表现欠佳。同时, 时间序列模型及深度学习模型的研究及应用更多地聚焦于拥堵发生及加剧的场景, 而忽略了拥堵随时间消散的场景, 但在实际的交通运营管理中, 准确理解及预测拥堵消散对于交管部门精准决策同样重要^[42]。

针对上述难题与挑战, 本文提出基于交通模式推理的交通预测框架。该框架综合运用知识图谱及深度图神经网络算法, 考虑拥堵的聚集和消散的表达式, 研究交通状态在时间和空间维度的模式传

播特征，并对短时交通状态的演化过程进行精准预测，为交通管控方案的制订提供辅助建议。

2 基于交通模式推理的交通预测框架

TP² 基于交通模式和状态处理模块，对采集到的交通状态数据进行数据预处理，通过地理信息数据映射构建交通路网拓扑结构；然后，TPP-TKG 将交通模式传播建模为时序知识图谱的动态演化过程，挖掘交通模式的传播规律，将与任意路段存在交通模式关联的路段组合起来，构建时空关联的路网子区域；再运用基于图神经网络的交通短时预测（traffic state prediction based on graph neural network, TSP-GNN）模块（以下简称 TSP-GNN），充分挖掘子区域内的时空状态变化情况，预测子区域内各个路段的短时交通状态，进而实现对城市路网重点关注区域进行短时交通流预测工作，并辅助交通管控部门，对其提供决策支持。TP² 流程框架如图 2 所示。

2.1 交通模式传播的时序知识图谱构建

由于路网交通状态是一个时序变化的过程，因此将交通模式传播的知识图谱 G 定义为一个时序知识图谱，其本质上是一个有序的图切片集合： $G = \{G_1, G_2, \dots, G_t, \dots, G_T\}$ 。每一个图切片 G_t 是一个四元组（事件）集合，即 $G_t = \{(s, p, o, t)\}$ 。其中， s 、 o 、 t 分别表示头实体（路段）、尾实体（路段）、时刻。将事件 (s, p, o, t) 定义为在时刻 t ，路段 s 对路段 o 具有交通模式传播关系 p （ $p \in P$ ，而 P 是有可能关系的集合），这样就可以把对 G 进行时序推理的过程定义为给定不完整的四元组 $(s, p, ?, t)$ ，预测问号代表的路段 o 。

TP² 通过构建一种循环神经网络架构^[4]来捕获历史事件之间的时间相关性。其时序知识图谱的核心包括 3 种循环神经网络事件编码器（如图 3 所示）以及 1 种基于自注意力机制的 RGrAN 聚合函数。

2.1.1 循环神经网络事件编码器

假设 G_t 中事件的条件概率分布只和过去 m 个时刻发生的事件有关（ m 为预先定义的超参数），因此使用循环神经网络架构来实现事件编码器。条件概率被定义为：

$$\begin{aligned} P(s_t, p_t, o_t | G_{t-m:t-1}) = \\ P(s_t | G_{t-m:t-1}) \cdot P(p_t | s_t, G_{t-m:t-1}) \cdot P(o_t | s_t, p_t, G_{t-m:t-1}) = \\ \sigma^1(H_{t-1}) \cdot \sigma^2(e_s \parallel h_{t-1}(s)) \cdot \sigma^3(e_p \parallel h_{t-1}(s, p)) \end{aligned} \quad (1)$$

其中， $\parallel$ 代表向量拼接， e_s 与 e_p 为 s 和 p 的可学习嵌入式向量表示。 H_t 是全局隐藏向量。 H_t 编码了 G 直到 t 时刻的全局信息，反映 G 对接下来发生事件的全局偏好。 $h_t(s)$ 以及 $h_t(s, p)$ 是局部隐藏向量，编码了直到 t 时刻的关于实体与关系的局部信息。通过定义全局隐藏向量与局部隐藏向量，模型以一种互补的方式来编码 G 中的历史信息。 σ^1 、 σ^2 和 σ^3 是不同的线性 Softmax 分类器。在实际计算过程中，本文采用了门控循环单元（gated recurrent unit, GRU）^[43]来实现循环神经网络架构，隐藏向量的动态变化规律由 3 个 GRU 捕捉：

$$H_t = \text{GRU}^1 \left(g(G_t), H_{t-1} \right) \quad (2)$$

$$h_t(s) = \text{GRU}^2 \left(g(O_t^{(s)}), H_t, h_{t-1}(s) \right) \quad (3)$$




图 2 TP² 流程框架




图3 交通模式传播的时序知识图谱的基本架构

$$h_t(s, p) = \text{GRU}^3(g(O_t^{(s)}), H_t, h_{t-1}(s, p)) \quad (4)$$

其中, $O_t^{(s)}$ 是发生于时刻 t 且与 s 有关的所有事件集合。聚合函数 $g(\cdot)$ 以 $O_t^{(s)}$ 为输入, 捕获图中的局部邻域信息。GRU² 与 GRU³ 用于更新局部隐藏向量 $h_t(s)$ 和 $h_t(s, p)$ 。局部信息将会被进一步聚合到全局范围, 得到全局信息 $\dot{g}(G_t)$, 并输入 GRU¹ 以更新全局隐藏向量 H_t 。

2.1.2 RGrAN 聚合函数

RGrAN 聚合函数 $g(\cdot)$ 本质上是一个多层的图卷积神经网络。给定头实体, $g(\cdot)$ 依赖于关系类型 (relation-wise) 对邻域信息进行编码。其实现方式为将自注意力机制与关系图卷积网络 (relational graph convolutional network, RGCN) 聚合器中的消息传递机制^[37]结合, 具体如下:

$$h_s^{(l+1)} = \sigma \left(W_0^{(l)} h_s^{(l)} + \sum_{p \in P} \sum_{o \in O_t^{(s,p)}} \alpha_{s,p,o}^{(l)} W_p^{(l)} h_o^{(l)} \right) \quad (5)$$

$$\alpha_{s,p,o}^{(l)} = \frac{\exp(\text{Leaky ReLU}(a_p^{(l)} [W_p^{(l)} h_o^{(l)} \parallel W_p^{(l)} h_s^{(l)}]))}{\sum_{k \in O_t^{(s,p)}} \exp(\text{Leaky ReLU}(a_p^{(l)} [W_p^{(l)} h_o^{(l)} \parallel W_p^{(l)} h_k^{(l)}]))} \quad (6)$$

$$g(O_t^{(s)}) = h_s^{(L)} \quad (7)$$

$$\dot{g}(G_t) = \max \left(\left\{ g(O_t^{(s)}) \right\}_s \right) \quad (8)$$

其中, $l \in \{0, 1, 2, \dots, L-1\}$ 表示当前层数, L 表示 RGrAN 聚合函数总的层数; $h_s^{(l)} \in R^{d^{(l)}}$ 以及 $h_o^{(l)} \in R^{d^{(l)}}$ 表示第 l 层的 s 与 o 的隐藏层向量, 例如第 0 层的向量表示为 $h_s^{(0)}$ 与 $h_o^{(0)}$, 它们被初始化为 e_s 与 e_o ; $\alpha_{s,p,o}^{(l)}$ 是第 l 层针对 s 、 p 、 o 的自注意力系

数; $O_t^{(s,p)}$ 是时刻 t 下, 与头实体 s 存在关系 p 的尾实体的集合; $W_0^{(l)}$ 是第 l 层的可训练权重矩阵; $a_p^{(l)}$ 与 $W_p^{(l)}$ 分别是第 l 层的可训练权重向量与矩阵; σ 是 ReLU 激活函数。

针对 $(s, p, ?, t)$ 的时序图谱推理任务可以被看作一个多分类问题, 其中要预测的尾实体 (路段) 对应一个类。使用交叉熵损失函数, 其包含 3 个损失项:

$$L = - \sum_{(s,p,o,t) \in G} (\log(P(o_t | s_t, p_t, G_{t-m:t-1})) + \lambda_1 \log(P(p_t | s_t, G_{t-m:t-1})) + \lambda_2 \log(P(p_t | s_t, G_{t-m:t-1}))) \quad (9)$$

根据式 (1) 可知, 计算 $P(s_t, p_t, o_t | G_{t-m:t-1})$ 需要用到 3 个条件概率项, 而交叉熵损失函数中的每一项正好对应 1 个条件概率项。例如损失项中的 $\log(P(p_t | s_t, G_{t-m:t-1}))$ 对应条件概率项 $P(p_t | s_t, G_{t-m:t-1})$, λ_1 和 λ_2 是可以被调节的超参数。

2.1.3 交通模式知识图谱生成器

算法 1 阐述了基于路段拥堵状态的时间序列数据生成交通模式传播知识图谱 (knowledge graph for traffic pattern propagation, KG-TPP) 的过程。其中, T 代表所有需要被考虑的时刻集合, R 表示路段集合。考虑到交通拥堵及交通模式的传播需要经历一段时间, 因此定义 ω 为时间窗口超参数, 用于限定传播时间 (即交通模式传播会在 ω 分钟内完成)。算法 1 将会循环每个时刻 t , 并检查该时刻下路段 r_a 到 r_b 是否存在关系, 且限定 r_b 必须在 r_a 的 hop 距离 (网络中的拓扑距离) 3 的邻域内 (即从 r_a 经过至多 3 个路口可以到达 r_b)。如果 r_a 在时刻 t 处于拥堵, 且 r_b 在时间区间 $[t, t + \omega]$ 的拥堵频率超过 80%, 则认为在时刻 t , 从 r_a 到 r_b 存在模式传播关系。拥堵频率是路段在时间区间内的拥堵时刻数量与总时刻数量的比值 (例如假设时间区间共包含 10 个时刻, 而路段在其中 8 个时刻发生了拥堵, 则拥堵频率为 80%)。定义传播前状态 s_a 与传播后状态 s_b 分别是 r_a 在时刻 t 的状态以及 r_b 在 $[t, t + \omega]$ 中发生频率最高的状态, 即可生成模式传播关系 $p(a, b)$ 与对应的四元组 $(r_a, p(a, b), r_b, t)$, 并以此更新 KG-TPP。

算法 1 KG-TPP 的生成过程

- 1: 初始化时间窗口 ω ;
- 2: 初始化 KG-TPP 为空;
- 3: for $t \in T$ do

- 4: for $r_a \in R$ do
- 5: for $r_b \in R$ and $\text{hop_distance}(r_a, r_b) \leq 3$ do
- 6: If $\text{congest}(r_a, t)$ is TRUE and $\text{congest_freq}(r_b, [t, t + \omega]) \geq 80\%$ then
- 7: $s_a = \text{traffic_state}(r_a, t)$;
- 8: $s_b = \text{most_frequent_state}(r_b, [t, t + \omega])$
- 9: 使用 s_a 与 s_b 计算交通模式传播关系 $p(a, b)$;
- 10: 使用四元组更新 KG-TPP;
- 11: end if
- 12: end for
- 13: end for
- 14: end for

给定时刻 t , 针对某一个路段 r_c (以下用中心路段表示), 可以获得一系列与之存在传播关系的 k 个关联路段 $\{r_1, r_2, \dots, r_k\}$ 。需要注意的是, 这些关联路段的传播关系可以指向 r_c , 也可以从 r_c 指向其他路段。在获取了 r_c 与 k 个关联路段之后, 可以从路网中将这一些路段提取出来, 同时进一步提取与它们相连的一些路段, 使得提取出来的路段可以形成一个连通图 (single connected component)。这一过程被称为针对中心路段的交通子图挖掘, 如图 4 所示。

本文将交通子图 (而非整个原始路网) 作为输入, 使用深度图神经网络模型, 获得了更好的表现。在研究过程中, 需要对历史数据进行相应的切分 (切分的方法参考算法 1), 并构建训练集。首先, 将每个路段作为中心路段 r_c , 根据关联路段的情况进行划分。例如对于某个中心路段 r_c , 出现了 $\{r_1, r_2, r_3\}$ 、 $\{r_1, r_3, r_4, r_5\}$ 、 $\{r_2, r_3, r_4\}$ 3 种可能的关联路段集合, 那么将该中心路段 r_c 的数据划分成 3 份, 并针对每一份数据开发一个速度预测模型。

2.2 基于图神经网络的交通短时预测模型

2.2.1 数据处理

在进行模型预测之前, 需要进行数据采集与数据预处理工作。首先, 对历史交通数据、路网信息、路段交通状态和信号配时数据进行采集并入库。然后, 对获取的数据进行预处理, 包括数据归集、时空对齐和速度趋势聚类等。其中, 速度趋势聚类的目的是将所有历史数据划分为多个聚类, 使每个聚类在时空格局上都有其独有的特征。在完成这两步工作之后, 利用基于生成式对抗网络 (generative adversarial networks, GAN) 的交通预测框架对每




图4 针对中心路段的交通子图挖掘

个聚类中的数据进行路网的短时速度预测。

2.2.2 基于图神经网络的路网建模

为了进行路网的短时交通预测，需要建立一个深度神经网络模型 f_{dnn} ，该模型可以预测与信号交叉口相关联的路段速度向量。每个信号周期的数据都将用于下一个预测步骤，对历史数据的观测包括关联交叉口及其邻近交叉口的路段速度和信号配时。

分别使用 $\mathbf{x}_t$ 、 $\boldsymbol{\sigma}_t$ 和 $\mathbf{y}_t$ 表示 t 时刻的交通输入向量、信号配时向量和路段速度向量，假设该模型使用从过去的 α 个周期中收集的数据来预测 θ 信号周期的连接速度。则 t 时刻对应的预测问题可表示为：

$$Y = [\mathbf{y}_{t+1}, \dots, \mathbf{y}_p, \dots, \mathbf{y}_{t+\theta}] = f_{\text{dnn}}(\mathbf{x}_{t-\alpha+1}, \dots, \mathbf{x}_k, \dots, \mathbf{x}_t, \boldsymbol{\sigma}_{t-\alpha+1}, \dots, \boldsymbol{\sigma}_m, \dots, \boldsymbol{\sigma}_t) \quad (10)$$

其中， $f_{\text{dnn}}(\cdot)$ 为深度神经网络模型， $1 \leq p \leq \theta$ ，

$$1 < k < \alpha, 1 < m < \alpha。$$

基于 GAN 的交通预测框架模型如图 5 所示，该模型由一个生成器（生成神经网络）和一个判别器（判别神经网络）构成。这里，输入生成器的数据是指历史交通模式，包括路段交通数据和交叉口交通信号数据。该模型训练生成器产生预测的路段速度，使判别器相信它们是真值。本文同时训练生成器和判别器，并通过最小极大对策的优化过程调整模型参数。对基于 GAN 的交通预测框架模型进行数据训练后，使用生成器进行路段的短时速度预测。

生成神经网络采用包含微观建模单元和宏观建模单元的混合架构。这两种类型的单元格采用不同的输入数据。微观建模单元使用交叉数据来捕获交叉的效果，而宏观建模单元使用网络范围内的数




图5 基于 GAN 的交通预测框架模型

据对相邻交叉口之间的影响进行建模。每个建模单元包括3个技术组成部分: 时空注意力 (spatial-temporal attention, STA)、图卷积网络 (graph convolutional network, GCN) 和递归神经网络 (recurrent neural network, RNN)。STA 用于调整不同时空背景的重要性; GCN 用于学习复杂的拓扑结构, 以获取空间关系; RNN 用于学习交通数据的时间变化。

2.2.3 基于 GAN 的交通预测框架

由于 GAN 擅长学习任何数据分布^[44-47], 而实际数据采集的过程中无法穷尽速度数据和信号数据的组合, 因此运用 GAN 提升对未知数据分布预测的准确性和稳定性, 最终实现预测目标。


在对路网和交叉口的时空交通信息进行聚合时, 宏观建模单元用于描述聚合后的交通状态, 微观建模单元用于捕捉单个交叉口的交通特征。然后, 通过全连接层对宏观建模单元和微观建模单元的输出特征进行集成, 即对于同一交叉口, 将宏观建模单元的隐藏状态信息与微观建模单元的隐藏状态信息融合。全连接层的融合操作如下:

$$f = f_c(h_{\text{macro}}, h_{\text{micro}}, w_{\text{macro}}, w_{\text{micro}}, b_c) \quad (11)$$

其中, $f_c(\cdot)$ 为全连接层神经网络, h_{macro} 和 h_{micro} 分别为宏观建模单元和微观建模单元的输出特征向量状态, w_{macro} 、 w_{micro} 、 b_c 均为可训练参数。

在 TSP-GNN 的训练过程中, 判别器不会直接将生成器预测的路段流量速度作为输入。相反, 受 TrafficGAN^[45] 的启发, 流量矩阵蕴含了路网连接信息、交通通行方向信息等更丰富的信息, 因此将每次路段流量速度转换为流量矩阵进行计算。为了构造流量矩阵, 需要整个路网的路段实时速度以及网络拓扑结构。如图6所示, 该示例说明了如何用交通矩阵表示一个有4个路段的路网交通速度。本质上, 给定一个有 N 个路段的路网, 生成流量矩阵 $M^{N \times N}$ (路网中的任意两个路段之间是否存在流量的表示)。如果路段 i 没有连接到上游路段 j , 则 $M_{i,j}$ 取值为 0; 如果路段 i 连接到上游路段 j , 则 $M_{i,j}$ 为路段 i 的速度值。本例中 $M_{2,1}$ 为路段 2 的速度, 流量矩阵包含了比路段流量速度更多的信息 (即网络拓扑结构和移动方向), 因此对于判别器而言, 输入了更加丰富的交通数据特征, 有助于提高判别器的性能。

使用不同时刻的流量矩阵可以为判别器构造真实样本 ($\text{Sample}^{\text{real}}$) 和虚假样本 ($\text{Sample}^{\text{fake}}$):



(a) 路网拓扑以及某时刻路段速度示意图

(节点代表路段, 箭头值代表路段间的有向连接)

0	0	0	20
23	0	0	0
27	0	0	27
0	25	0	0

(b) 对应的流量矩阵

图6 使用路网状态生成流量矩阵的示例

$$\text{Sample}^{\text{real}} = \{M_1^{\text{real}}, M_2^{\text{real}}, \dots, M_T^{\text{real}}, M_{T+1}^{\text{real}}\} \quad (12)$$

$$\text{Sample}^{\text{fake}} = \{M_1^{\text{real}}, M_2^{\text{real}}, \dots, M_T^{\text{real}}, M_{T+1}^{\text{pred}}\} \quad (13)$$

真实样本和虚假样本都是长度为 $T+1$ 的序列 (序列中的每一个元素是某一时刻的流量矩阵)。真实样本和虚假样本唯一的区别在于最后一个元素, 对应的矩阵分别由真实的或预测的路段交通速度生成。对于真实样本数据或者虚假样本数据, 判别器会利用卷积神经网络和 GRU 进行处理, 并最终由自注意力机制通过加权求和过程计算输出:

$$O = \sum_{t=1}^{T+1} w_t \cdot O_t \quad (14)$$

其中, w_t 为自注意力权重, 可以通过自注意力机制进行训练; 最终的隐藏向量表示 O 被传递给全连接层, 用产生的得分表示样本是否为真。

3 实验和结果

由于 TP² 包含了两个部分, 基于知识图谱的交通模式挖掘模块和基于图神经网络的交通短时预测模块。因此本文采用了对应的两项实验, 而在模型分析结果中, 统一用 TP² 对两个部分的表现进行阐述。

3.1 实验设置

笔者选取了位于杭州市的2个区域: 郊区 (区域1) 与市中心 (区域2) 作为 TP² 的测试区域。区域1与区域2的路段总数分别为1494与1370, 路段密度分别为9.83/km²和10.7/km²。实验使用的路段速度数据由第三方互联网平台获取 (高德地图 API), 路口信号配时数据来源于 SCATS^[48] (一种自适应的信号控制系统)。数据时段为2020年1月1日至2020年6月1日, 采样间隔为5 min, 预测响应时间为15 min。按照70%、10%、20%的比例将数据划分成训练集、验证集、测试集, 具体的实验数据样例见表1, 其中速度指该路段在一段时间 (比如5 min) 内所有车辆的平均车速。

表1 实验数据样例

路段ID	时间戳	速度/(km·h ⁻¹)	信号周期/s
R0001	2020-01-01 08:00:00	35	180
R0001	2020-01-01 08:05:00	32	180
R0001	2020-01-01 08:10:00	28	135

3.1.1 交通状态的设置

对于每一个路段来说,其交通状态由平均车速 v 与拥堵率 cr 共同决定。拥堵率(取值在0到1之间)反映了拥堵的严重程度(越靠近1越严重)。基于3个车速区间以及5个拥堵率区间,本文定义了15种交通状态(状态1至状态15),具体见表2。需要注意的是,本文定义的交通状态不适用于道路完全通畅($cr=0$)或者平均车速较快($v \geq 40$ km/h)的情况,因为本文认为拥堵不可能在这两种情况下发生。本文定义的15种交通状态与主流的交通状态指标(traffic state index, TSI)^[49]相对应,从而能描述畅通、基本畅通、轻度拥堵、中度拥堵、严重拥堵5种拥堵等级。

表2 根据平均车速与拥堵率定义的15种交通状态

拥堵率	$0 < v < 10$	$10 < v < 20$	$20 < v < 40$
$0 < cr < 0.2$	1	6	11
$0.2 < cr < 0.4$	2	7	12
$0.4 < cr < 0.6$	3	8	13
$0.6 < cr < 0.8$	4	9	14
$0.8 < cr < 1.0$	5	10	15

3.1.2 交通模式传播关系的定义

本文定义了9种交通传播模式关系(见表3中的 $p_0 \sim p_8$)。当拥堵从路段 r_a 传播到路段 r_b ,通过给定 r_a 在拥堵传播前的交通状态 s_a ,以及 r_b 在拥堵传播后的交通状态 s_b ,可以确定拥堵传播模式关系 $p(a,b)$ 。 $p(a,b)$ 由 s_a 与 s_b 对应的 v 与 cr 决定。

表3 9种交通传播模式关系

交通传播模式关系	具体解释
p_0	cr 相同, v 相同
p_1	cr 相同, v 更高
p_2	cr 更低, v 更高
p_3	cr 更低, v 相同
p_4	cr 更低, v 更低
p_5	cr 相同, v 更低
p_6	cr 更高, v 更低
p_7	cr 更高, v 相同
p_8	cr 更高, v 更高

综上所述,本文分别为宏观建模单元和微观建模单元定义了节点及其特征。当一个路段在宏观建模单元被建模为一个图节点时,其特征如下:

$$X_l^{\text{macro}}(t) = [v_l^{\text{avg}}(t), v_l^{\text{max}}(t), v_l^{\text{min}}(t), v_{\text{agg}}^{\text{avg}}(t), v_{\text{agg}}^{\text{max}}(t), v_{\text{agg}}^{\text{min}}(t)] \quad (15)$$

其中, $v_l^{\text{avg}}(t)$ 、 $v_l^{\text{max}}(t)$ 和 $v_l^{\text{min}}(t)$ 分别表示路段 l 在一个时间间隔(通常为15 min)内的平均速度、最大速度和最小速度, $v_{\text{agg}}^{\text{avg}}(t)$ 、 $v_{\text{agg}}^{\text{max}}(t)$ 和 $v_{\text{agg}}^{\text{min}}(t)$ 是对应的平均速度、最大速度和最小速度的聚合平均值。为每个道路交叉口构建一个微观图模型来描述同一交叉口内车道之间的拓扑连接。一个节点表示一条车道,可用的转弯运动决定了车道之间的连通性。节点的特征不仅包含车道速度统计信息,还包含交通信号信息。微观建模单元时间间隔由信号周期决定,总共使用30个周期的数据来构建模型输入 X_{micro} 。微观图模型的特征表示为:

$$X_{\text{micro}}^{\alpha}(t) = [v_{\text{avg}}^{\alpha}(t), v_{\text{max}}^{\alpha}(t), v_{\text{min}}^{\alpha}(t), v_{\text{agg,avg}}^{\alpha}(t), v_{\text{agg,max}}^{\alpha}(t), v_{\text{agg,min}}^{\alpha}(t), g_{\text{increase}}^{\alpha}(t), g_{\text{decrease}}^{\alpha}(t)] \quad (16)$$

其中, $v_{\text{avg}}^{\alpha}(t)$ 、 $v_{\text{max}}^{\alpha}(t)$ 和 $v_{\text{min}}^{\alpha}(t)$ 分别表示 t 时刻车道 α 的平均速度、最大速度和最小速度,类似于宏观图模型, $v_{\text{agg,avg}}^{\alpha}(t)$ 、 $v_{\text{agg,max}}^{\alpha}(t)$ 和 $v_{\text{agg,min}}^{\alpha}(t)$ 是车道 α 的平均速度、最大速度和最小速度的聚合平均值。 $g_{\text{increase}}^{\alpha}(t)$ 和 $g_{\text{decrease}}^{\alpha}(t)$ 是两个虚拟变量,分别表示车道 α 的绿色信号时间增加量和减少量。

3.2 交通模式推理结果

3.2.1 交通模式推理基准模型

本文将 TP^2 与以下8个交通模式推理基准模型(包括非知识图谱模型及知识图谱模型)进行了比较。非知识图谱模型包括HA、ARIMA、ST-GCN^[50]、AST-GCN^[51]。知识图谱模型包括T-TransE、TA-TransE、TA-DistMult、RE-NET(recurrent event network)(均为时序图谱推理模型)^[43]。两类模型的预测方式有着本质区别,非知识图谱模型需要针对平均车速 v 以及拥堵率 cr 分别进行预测,然后根据表1计算交通状态,进而生成未来时刻的交通模式知识图谱。与之相反, TP^2 以一种端到端的方式进行预测。对于每一个基准模型,在数据集上对基于神经网络基准模型(除HA与ARIMA外的模型)的超参数进行了测试,并选取了最佳的超参数,具体见表4。

对于本文提出的 TP^2 , 拥堵传播时间窗口 ω 取值为 10, 嵌入式向量 e_s 、 e_p 、 e_o 的维度为 200, 使用两层的 RGraAN 聚合函数, 块对角分解使用两个块对角矩阵, λ_1 与 λ_2 都设置成 0.1。

3.2.2 模型比较

在模型测试阶段, 本文选取了一系列的测试四元组 (s, p, o, t) , 并且将每一个四元组的尾实体 o 移除, 计算真实的尾实体 o 在模型预测出的所有可能的尾实体中的排名。 TP^2 与其他基准模型在早高峰与晚高峰时段上的时序预测表现见表 5, 将 Hit@1、Hit@3、Hit@10 和平均倒数排名 (mean reciprocal rank, MRR) 作为评价指标, 其中, Hit@ K 表示实

际被预测的尾实体 o 占排名前 K 位的百分比。MRR 的表达式为:

$$MRR = \frac{1}{N} \sum_{i=1}^N \frac{1}{\text{rank}_i} \quad (17)$$

其中, rank_i 表示第 i 个用于评测的四元组 (s, p, o, t) 中, 真实的尾实体 o 在预测的所有尾实体中的排名。

总体而言, 相比于非知识图谱模型, 知识图谱模型拥有更高的 Hit@1 值, 这主要因为非知识图谱模型的工作过程是分段的。因此, 在速度和拥堵频率的预测中, 即使只存在细微的预测误差, 也会对最终的 TP^2 的预测结果造成显著影响。相反, 知识图谱模型以端到端的方式运作, 精度更高。此外,

表 4

交通模式推理基准模型超参数设置

基准模型	基准模型最佳超参
ST-GCN	ST-Conv 的通道数分别为 64、16、64。图卷积核数量 K 与时间卷积核数量 K_t 均设为 3
AST-GCN	所有的图卷积层和时间卷积层使用了 64 个卷积核
T-TransE	负采样率为 1, 间隔为 1
TA-TransE	负采样率为 1, 间隔为 1
TA-DistMult	使用交叉熵损失, 负采样率为 1, 间隔为 1
RE-NET	RGCN 聚合函数层数为 2, 使用两个块对角矩阵, 隐藏向量维度为 200

表 5

 TP^2 与其他基准模型在早高峰与晚高峰时段上的时序预测表现

区域	类别	模型	早高峰				晚高峰			
			Hit@1	Hit@3	Hit@10	MRR	Hit@1	Hit@3	Hit@10	MRR
区域 1	非知识图谱模型	HA	13.2				11.6			
		ARIMA	18.6				16.4			
		ST-GCN	19.6				17.5			
		AST-GCN	19.4				20.3			
	知识图谱模型	T-TransE	28.0	55.3	69.3	35.1	25.1	39.7	58.2	32.2
		TA-TransE	35.6	52.7	76.7	48.9	23.9	62.1	75	38.6
		TA-DistMult	57.1	61.8	83.1	57.5	41.0	65.1	72.8	52.8
		RE-NET	64.3	71.5	85.8	72.1	51.2	75.6	81.9	58.7
		TP^2	66.1	72.9	87.2	74.3	52.9	77.3	83.6	60.2
区域 2	非知识图谱模型	HA	11.2				14.2			
		ARIMA	14.5				16.6			
		ST-GCN	16.7				18.5			
		AST-GCN	22.7				21.1			
	知识图谱模型	T-TransE	32.5	32.5	47.8	24.3	27.2	45.7	66.2	33.4
		TA-TransE	29.6	47.7	51.3	41.3	28.8	53.3	69.1	48.9
		TA-DistMult	42.5	58.4	73.5	52.8	43.0	57.9	76.3	57.9
		RE-NET	57.1	68.7	78.4	62.4	56.5	70.3	84.8	69.6
		TP^2	58.9	68.5	80.1	65.3	57.7	74.4	86.7	71.8

TP² 中的关系分布越不均匀, 对其进行时序预测也越难(例如预测区域 2 的早高峰时段(06:30~09:00)比晚高峰时段(06:30~09:00)更困难)。但在不同情况下, 本文提出的 TP² 仍在绝大多数指标中取得了比其他知识图谱模型更好的表现, 这表明在拥堵传播模式预测中, TP² 的预测更有效, 且 RGrAN 聚合器比原始的 RGCN 聚合器表现更佳。

3.2.3 模型分析

本文从杭州市中心选取了 1 个小范围路网来进一步检验模型的有效性。对于该路网, TP² 预测结果在 2020 年 5 月 26 日晚高峰 16 min 内的拥堵变化如图 7 所示。在此时间段内, 拥堵从西南、东南、东北 3 个方向向中心扩散。基于模型预测结果, 路段 r_d 和 r_e 都与 r_f 存在关联关系, 而路段 r_i 和 r_h 都与 r_j 存在关联关系, TP² 框架能有效地捕捉这种关系。

最后, 本文对 KG-TPP 构建的超参数(时间窗口以及拥堵频率)进行了测试, 对比了 TP² 模型在不同超参数组合下的预测结果(MRR), 具体见表 6。实验结果表明, 本文使用的超参数组合(时间窗口 10 min 以及拥堵频率 80%)能够获得最好的推理精度。

3.3 短时预测模型结果

在模型实验中, 本文从模型性能和有效性等方面将所提出的 TP² 模型与 8 个选定的模型进行了比较。其中, 前 5 个是基本模型, 后 3 个是用于交通预测的深度学习模型。

- HA: 用过去 12 个时刻的速度预测接下来 1 个时刻的速度。

- ARIMA: 传统的时间序列模型。
- SVR: 支持向量回归模型是目前比较流行的监督学习模型。
- GRU: 典型的时序模型, 专门研究时间动态。
- GCN: 一种能够从非结构化数据中捕获结构信息的图神经网络模型。
- T-GCN: 综合应用 GCN 和 GRU, 同时捕获数据的空间和时间依赖性。
- ST-GCN: 应用 GCN 和门控 CNN 来捕获交通数据中的空间和时间依赖性。
- A3T-GCN: 遵循与 T-GCN 类似的结构, 但该模型通过注意力机制进行了扩展, 以学习数据的时间变化。

针对基准模型中基于神经网络的模型, 本文测试了其超参数, 并且选择了最佳超参数, 具体见表 7。

表 7 短时预测基准模型超参数设置

基准模型	基准模型最佳超参
SVR	使用线性核函数, 惩罚因子为 0.001
GRU	使用单层 GRU 网络, 隐藏向量维度为 64
GCN	使用双层 GCN, 隐藏向量维度为 64
T-GCN	隐藏向量维度为 64
ST-GCN	ST-Conv 的通道数分别为 64、16、64; 图卷积核数量 K 与时间卷积核数量 K_t 均设为 3
A3T-GCN	隐藏向量维度为 64

在模型效果评估时, 本文选用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean




图 7 区域 2 的一个局部路网对应的 TP² 时序预测

表 6

TP² 模型在不同超参数组合下的推理精度 (MRR/Hit@1/Hit@3/Hit@10)

拥堵频率	时间窗口 5 min	时间窗口 10 min	时间窗口 20 min
60%	67.3/55.4/58.2/66.5	70.3/58.5/64.1/69.2	70.9/57.2/61.5/68.5
80%	71.7/59.2/62.1/69.8	74.3/60.2/65.3/71.8	72.1/59.3/63.5/70.2
90%	70.4/57.2/59.3/67.5	72.1/59.8/63.7/69.7	71.2/58.1/62.5/67.7

squared error, RMSE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE) 3 项指标进行模型评估, 计算式如下:

$$MAE = \frac{\sum_{i=1}^{T_{\text{tot}}} \sum_{j=1}^{N_l} |Y_{i,j} - Y_{i,j}^{\text{pred}}|}{T_{\text{tot}} N_l} \quad (18)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{T_{\text{tot}}} \sum_{j=1}^{N_l} (Y_{i,j} - Y_{i,j}^{\text{pred}})^2}{T_{\text{tot}} N_l}} \quad (19)$$

$$MAPE = \frac{100\%}{T_{\text{tot}} N_l} \sum_{i=1}^{T_{\text{tot}}} \sum_{j=1}^{N_l} \left| \frac{Y_{i,j} - Y_{i,j}^{\text{pred}}}{Y_{i,j}} \right| \quad (20)$$

其中, T_{tot} 表示预测的总时长, N_l 表示预测路段数, Y 表示路段实际速度, Y^{pred} 表示路段预测速度。

不同模型预测结果见表 8。根据表 8 的实验结果, TP^2 在所有选定指标方面都实现了最佳预测性能。 TP^2 拥有最低的 RMSE、MAE 和 MAPE 指标。 TP^2 的 TSP-GNN 模块受益于 wasserstein GAN^[52] 学习策略的优势, 并产生更通用的预测模型, 更不容易出现过拟合的问题。不同模型效率见表 9, 表 9 展示了用于训练和测试的所有模型的计算效率结果。本文对比了 TP^2 与表现最好的基准模型 (A3T-GCN) 的计算效率。 TP^2 先通过时序推理进行子图挖掘, 然后再进行子图路网的短时交通流预测, 因此在计算耗时方面明显优于基于全局路网预测的基准模型 (A3T-GCN), 同时 TP^2 仍然能维持高的预测精度。因此, 预测和计算性能都证明了 TP^2 在实际应用中的优越性。

表 8 不同模型预测结果 (15 min / 30 min / 60 min)

模型	MAE	RMSE	MAPE
HA	7.61/9.14/12.0	8.87/11.4/16.5	21.8%/25.7%/33.9%
SVR	7.32/8.72/11.6	8.63/10.5/14.3	16.5%/19.8%/23.5%
ARIMA	5.18/6.79/9.27	6.02/7.11/9.74	14.8%/17.5%/20.1%
GCN	6.46/7.78/9.19	6.94/8.54/9.81	11.6%/13.2%/15.4%
GRU	5.34/5.87/7.27	6.48/6.88/8.53	11.2%/12.4%/14.0%
T-GCN	4.42/4.86/5.62	5.60/5.91/6.52	10.7%/11.5%/12.8%
ST-GCN	3.88/4.41/4.99	5.27/5.45/5.86	9.5%/9.8%/10.9%
A3T-GCN	3.65/3.89/4.24	4.62/4.93/5.34	9.2%/9.6%/10.5%
TP^2	2.99/3.21/3.39	4.05/4.40/4.59	8.6%/8.9%/9.3%

表 9 不同模型计算效率

模型	训练时间/s	推理时间/s
A3T-GCN	8 532	115
TP^2	2 480	26

在实验区域中, 古墩路—三墩路口与其相邻的路口 (包括古墩路—灯彩街路口、三墩路—紫荆花路口、古墩路—秀里街口、三墩路—长阳路口) 被构建为宏观图模型的一个子集。图 8 提供了具有 17 个路段的宏观图模型示例, 每个路段由一个节点和从古墩路—三墩路口传输的微观建模图表示。其中 $L0$ 到 $L16$ 表示 17 个不同的路段, 而 $a1$ 到 $a33$ 表示 33 个不同的车道。图 9 进一步显示了与任意选择的 2019 年 11 月 7 日相对应的路段的预测和观察到的交通状况。

为了展示模型在不同交通条件下的性能, 本文随机选择 3 个路段 (路段 1、路段 7 和路段 9) 对一天的不同时间段 (早高峰、晚高峰和非高峰) 的数据进行实验, 发现这些路段在不同时期表现出不同的速度模式。例如, 在非高峰期 (11:00~13:00) 和晚高峰期 (17:00~19:00), 所有路段的速度曲线都相对稳定。在早期高峰期, 3 个路段的速度模式具有显著差异, 即路段 1 的速度逐渐降低, 路段 7 和路段 9 的曲线波动更大。然而, TP^2 可以处理上述的复杂情况, 并在大部分情况下都实现了相对准确的预测 (预测误差小于 2 km/h)。

4 结束语

本文提出的基于交通模式推理的交通预测框架可被用于城市交通主动式管控, 将预测得到的结果提前部署于特定交通路网结构的管控策略中, 可为城市交通信号控制和可变车道控制提供实时性更高的控制策略与方案。

TP^2 框架对路段级别的速度预测分为两个步骤: 首先, TP^2 将路网中的模式传播建模为一个可以随时间演化的多关系时序知识图谱, 使用一种关系图注意力网络 RGraAN 对知识图谱中复杂的时空相关性进行编码, 将推理结果用于挖掘某一中心路段的交通子图 (包含与中心路段存在传播关系的关联路段)。然后, 通过训练相应的基于生成式对抗网络的交通预测模型, 对交通子图上的路段速度进行预测。通过对比一系列基准模型, TP^2 可以获得更佳的计算性能和更高的预测精度。

城市道路交通状态的演变是一个动态更迭的过程, 交通模式传播的短时预测能够实现对于区域路网变化趋势的提前捕捉, 帮助运营人员提前锁定预警路段, 并及时进行信号调控和拥堵疏导, 使路网通行状态保持在较为通畅的水平, 避免形成局部




图8 实验路口宏观和微观变换示例




图9 路段1、7、9的预测速度与真实速度

拥堵并减缓拥堵的蔓延。本文提出的基于交通模式推理的交通预测框架在预警响应和拥堵消散等方面具有广阔的应用前景,为缓解城市交通拥堵、提升道路交通治理水平提供了思路 and 方向。

参考文献:

- [1] WANG H H, CAO R X, ZENG W H. Multi-agent based and system dynamics models integrated simulation of urban commuting relevant carbon dioxide emission reduction policy in China[J]. *Journal of Cleaner Production*, 2020, 272: 122620.
- [2] CHEN S H, ZHU F H, WANG F Y. An erlang-based simulation approach of artificial transportation systems[C]//*Proceedings of 2016 IEEE 19th International Conference on Intelligent Transportation Systems*. Piscataway: IEEE Press, 2016: 24-28.
- [3] JIN J C, MA X L. A non-parametric Bayesian framework for traffic-state estimation at signalized intersections[J]. *Information Sciences*, 2019, 498: 21-40.
- [4] WU J P, CAO M, CHEUNG J C K, et al. TeMP: temporal message passing for temporal knowledge graph completion[J]. *arXiv preprint*, 2020, arXiv:2010.03526.
- [5] SUN S M, CHEN J, SUN J. Traffic congestion prediction based on GPS trajectory data[J]. *International Journal of Distributed Sensor Networks*, 2019, 15(5): 155014771984744.
- [6] 贺冬冬. 基于出租车轨迹数据的短时交通流预测模型研究[D]. 大连: 大连海事大学, 2013.
HE D D. The short-time prediction model of traffic flow based on taxi trajectory data[D]. Dalian: Dalian Maritime University, 2013.
- [7] ZHOU X Y, WANG W J, YU L. Traffic flow analysis and prediction based on GPS data of floating cars[M]//*Lecture notes in electrical engineering*. Heidelberg: Springer, 2012: 497-508.
- [8] FOULADGAR M, PARHAM M, ELMASRI R, et al. Scalable deep traffic flow neural networks for urban traffic congestion prediction[C]//*Proceedings of 2017 International Joint Conference on Neural Networks*. Piscataway: IEEE Press, 2017: 2251-2258.
- [9] ZHU J W, HAN X, DENG H H, et al. KST-GCN: a knowledge-driven spatial-temporal graph convolutional network for traffic forecasting[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022: 1-11.
- [10] PETTY K F, MOYLAN A J. Traffic bottleneck detection and classification on a transportation network graph: US9330565[P]. 2016-05-03.
- [11] CUI Z Y, KE R M, PU Z Y, et al. Deep bidirectional and unidirectional LSTM recurrent neural network for network-wide traffic speed prediction[J]. *arXiv preprint*, 2018, arXiv:1801.02143.
- [12] 宋珊珊. 基于浮动车数据的短时交通流预测研究[D]. 大连: 大连理工大学, 2019.
SONG S S. Short-term traffic flow prediction based on floating car data[D]. Dalian: Dalian University of Technology, 2019.
- [13] 赵宏, 翟冬梅, 石朝辉. 短时交通流预测模型综述[J]. *都市轨道交通*, 2019, 32(4): 50-54.
ZHAO H, ZHAI D M, SHI C H. Review of short-term traffic flow forecasting models[J]. *Urban Rapid Rail Transit*, 2019, 32(4): 50-54.
- [14] CHIABAUT N, FAITOUT R. Traffic congestion and travel time prediction based on historical congestion maps and identification of consensual days[J]. *Transportation Research Part C: Emerging Technologies*, 2021, 124: 102920.
- [15] PAN B, DEMIRYUREK U, SHAHABI C. Utilizing real-world transportation data for accurate traffic prediction[C]//*Proceedings of 2012 IEEE 12th International Conference on Data Mining*. Piscataway: IEEE Press, 2012: 595-604.
- [16] WILLIAMS B M, HOEL L A. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: theoretical basis and empirical results[J]. *Journal of Transportation Engineering*, 2003, 129(6): 664-672.
- [17] ALGHAMDI T, ELGAZZAR K, BAYOUMI M, et al. Forecasting traffic congestion using ARIMA modeling[C]//*Proceedings of 2019 15th International Wireless Communications & Mobile Computing Conference*. Piscataway: IEEE Press, 2019: 1227-1232.
- [18] CHEN C Y, HU J M, MENG Q, et al. Short-time traffic flow prediction with ARIMA-GARCH model[C]//*Proceedings of 2011 IEEE Intelligent Vehicles Symposium*. Piscataway: IEEE Press, 2011: 607-612.
- [19] DU Q B, YIN F M, LI Z C. Base station traffic prediction using XGBoost-LSTM with feature enhancement[J]. *IET Networks*, 2020, 9(1): 29-37.
- [20] SUN B, SUN T, JIAO P P. Spatio-temporal segmented traffic flow prediction with ANPRS data based on improved XGBoost[J]. *Journal of Advanced Transportation*, 2021, 2021: 5559562.
- [21] VLAHOIANNI E I, KARLAFTIS M G, KOPELIAS P. Modeling freeway travel speed across lanes: a vector autoregressive approach[C]//*Proceedings of the 13th International IEEE Conference on Intelligent Transportation Systems*. Piscataway: IEEE Press, 2010: 569-574.
- [22] ANWAR T, LIU C F, VU H L, et al. Capturing the spatiotemporal evolution in road traffic networks[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 30(8): 1426-1439.
- [23] REMPE F, HUBER G, BOGENBERGER K. Spatio-temporal congestion patterns in urban traffic networks[J]. *Transportation Research Procedia*, 2016, 15: 513-524.
- [24] LYU Y S, DUAN Y J, KANG W W, et al. Traffic flow prediction with big data: a deep learning approach[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2015, 16(2): 865-873.
- [25] LI Z S, XIONG G, CHEN Y Y, et al. A hybrid deep learning approach with GCN and LSTM for traffic flow prediction[C]//*Proceedings of 2019 IEEE Intelligent Transportation Systems Conference*. Piscataway: IEEE Press, 2019: 1929-1933.
- [26] CHEN Y Y, CHEN H Y, YE P J, et al. Acting as a decision maker: traffic-condition-aware ensemble learning for traffic flow prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(4): 3190-3200.
- [27] DAI X Y, FU R, ZHAO E M, et al. DeepTrend 2.0: a light-weighted multi-scale traffic prediction model using detrending[J]. *Transportation Research Part C: Emerging Technologies*, 2019, 103: 142-157.
- [28] LIN Y L, DAI X Y, LI L, et al. Pattern sensitive prediction of traffic flow based on generative adversarial framework[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 20(6): 2395-2400.

- [29] ZHANG W, ZHU F H, CHEN Y Y, et al. Differential time-variant traffic flow prediction based on deep learning[C]//Proceedings of 2020 IEEE 23rd International Conference on Intelligent Transportation Systems. Piscataway: IEEE Press, 2020: 1-6.
- [30] LIN Y L, DAI X Y, LI L, et al. An efficient deep reinforcement learning model for urban traffic control[J]. arXiv preprint, 2018, arXiv:1808.01876.
- [31] CHEN Y W, WANG X, LI L X, et al. Traffic situational awareness research and development enhanced by social media data: the state of the art and prospects[J]. Chinese Journal of Intelligent Science and Technology, 2022, 4(1): 1-14.
- [32] XU X J, GAO X B, XU Z Z, et al. TCPModel: a short-term traffic congestion prediction model based on deep learning[M]//Communications in computer and information science. Singapore: Springer Singapore, 2019.
- [33] ZHANG X Y, HUANG C, XU Y, et al. Traffic flow forecasting with spatial-temporal graph diffusion network[J]. arXiv preprint, 2021, arXiv:2110.04038.
- [34] ZHU J W, WANG Q J, TAO C, et al. AST-GCN: attribute-augmented spatiotemporal graph convolutional network for traffic forecasting[J]. IEEE Access, 2021, 9: 35973-35983.
- [35] ZHENG C P, FAN X L, WANG C, et al. GMAN: a graph multi-attention network for traffic prediction[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(1): 1234-1241.
- [36] NAGY A M, SIMON V. Improving traffic prediction using congestion propagation patterns in smart cities[J]. Advanced Engineering Informatics, 2021, 50: 101343.
- [37] 张阳, 胡月, 辛东嵘. 一种考虑时空关联的深度学习短时交通流预测方法[J]. 智能科学与技术学报, 2021, 3(2): 172-178.
- ZHANG Y, HU Y, XIN D R. A deep learning short-term traffic flow prediction method considering spatial-temporal association[J]. Chinese Journal of Intelligent Science and Technology, 2021, 3(2): 172-178.
- [38] 陈美林, 郑治豪, 郭宝, 等. 基于因果关联的交通拥堵传播分析[J]. 中南大学学报(自然科学版), 2020, 51(12): 3575-3583.
- CHEN M L, ZHENG Z H, GUO B, et al. Traffic congestion spreading analysis based on causal nexus[J]. Journal of Central South University (Science and Technology), 2020, 51(12): 3575-3583.
- [39] NAGY A M, SIMON V. A novel congestion propagation modeling algorithm for smart cities[J]. Pervasive and Mobile Computing, 2021, 73: 101387.
- [40] 陆浩, 王飞跃, 刘德荣, 等. 基于科研知识图谱的近年国内外自动化学科发展综述[J]. 自动化学报, 2014, 40(5): 994-1015.
- LU H, WANG F Y, LIU D R, et al. Analytics of latest research progress in automation discipline based on academic knowledge mapping[J]. Acta Automatica Sinica, 2014, 40(5): 994-1015.
- [41] 赵学亮, 王涛, 王晓, 等. 基于文献指标与合著网络的《自动化学报》2011-2016年发表论文分析研究[J]. 自动化学报, 2017, 43(12): 2232-2243.
- ZHAO X L, WANG T, WANG X, et al. A literature study on Acta Automatica Sinica during 2010 to 2016 with bibliographic and coauthorship analysis[J]. Acta Automatica Sinica, 2017, 43(12): 2232-2243.
- [42] JIN J C, GUO H F, XU J, et al. An end-to-end recommendation system for urban traffic controls and management under a parallel learning framework[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(3): 1616-1626.
- [43] JIN W, QU M, JIN X S, et al. Recurrent event network: autoregressive structure inference over temporal knowledge graphs[J]. arXiv preprint, 2019, arXiv:1904.05530.
- [44] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [J]. arxiv preprint, 2014, arXiv:1406.1078.
- [45] ZHANG Y X, WANG S Z, CHEN B, et al. TrafficGAN: network-scale deep traffic prediction with generative adversarial nets[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(1): 219-230.
- [46] JIN J C, RONG D D, ZHANG T, et al. A GAN-based short-term link traffic prediction approach for urban road networks under a parallel learning framework[J]. IEEE Transactions on Intelligent Transportation Systems, 2022(99): 1-12.
- [47] LIU K H, YE Z H, GUO H Y, et al. FISS GAN: a generative adversarial network for foggy image semantic segmentation[J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(8): 1428-1439.
- [48] SIMS A G, DOBINSON K W. The Sydney coordinated adaptive traffic (SCAT) system philosophy and benefits[J]. IEEE Transactions on Vehicular Technology, 1980, 29(2): 130-137.
- [49] CHEN Z H, YANG Y J, HUANG L P, et al. Discovering urban traffic congestion propagation patterns with taxi trajectory data[J]. IEEE Access, 2018, 6: 69481-69491.
- [50] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting[C]// Proceedings of the 27th International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2018.
- [51] GUO S N, LIN Y F, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33: 922-929.
- [52] ADLER J, LUNZ S. Banach wasserstein GAN[J]. arxiv preprint, 2018, arXiv:1806.06621.

[作者简介]



覃缘琪(1992—),女,之江实验室智能社会治理研究中心研究专员,主要研究方向为智能交通控制、智能社会治理等。



季青原(1989—),男,银江技术股份有限公司博士后,主要研究方向为交通预测、图神经网络、知识图谱。



葛俊（1989- ），男，之江实验室智能社会治理研究中心高级研究专员，主要研究方向为强化学习、群体智能。



陈圆圆（1989- ），男，博士，中国科学院自动化研究所复杂系统管理与控制国家重点实验室副研究员，主要研究方向为社会交通、数据驱动的交通建模与预测。



戴星原（1993- ），男，中国科学院自动化研究所复杂系统管理与控制国家重点实验室博士生，主要研究方向为智能交通系统、机器学习和深度学习。



王晓（1988- ），女，博士，中国科学院自动化研究所复杂系统管理与控制国家重点实验室副研究员，主要研究方向为群体行为的激发与汇聚激励、群体智能和社交网络挖掘与分析。