

基于高速公路空间数据支持的流量预测模型优化方法研究

邱陵¹

QIU Ling

摘要

针对高速公路流量预测的时空依赖建模难题,文章提出融合自适应图卷积与物理约束的优化方法。通过动态邻接矩阵学习机制捕获时变空间依赖,采用多尺度扩散卷积(1步、2步、3步并行扩散)捕获不同范围的空间关联,引入流量守恒和容量约束增强预测合理性。在PEMS-BAY数据集上,相比时空图卷积网络(spatio-temporal graph convolutional network, STGCN)基线,15 min预测的平均绝对误差降低18.7%,均方根误差降低21.3%,60 min预测的平均绝对百分比误差降低至8.2%。消融实验表明动态图学习、多尺度卷积和物理约束的性能贡献率分别为12.1%、9.8%和6.8%。

关键词

时空图神经网络;自适应图卷积;物理约束正则化;高速公路;空间数据

doi: 10.3969/j.issn.1672-9528.2026.06.030

0 引言

基于高速公路空间数据的流量预测是指利用路网拓扑结构、传感器分布等空间信息,结合历史数据对未来交通流量进行估计的技术方法。随着我国高速公路里程突破17.7万公里、日均车流量达3 000万辆次,传统时间序列方法已难以满足复杂路网预测需求^[1]。交通运输部明确要求建立实时交通流数字模型,但当前技术在路网空间关联性、动态交通模式捕捉等方面存在不足^[2]。本研究通过分析交通流扩散传播机理,构建融合物理约束的自适应时空图神经网络模型,为智慧高速建设提供技术支撑。

1 高速公路流量预测技术现状与挑战

当前高速公路流量预测方法包括统计模型、机器学习和深度学习三类。传统自回归模型在平稳流量下稳定但无法捕捉非线性特征,支持向量机需人工设计特征且难以利用空间结构,循环神经网络和长短期记忆网络虽擅长时序建模但忽视空间依赖^[3]。STGCN引入了图结构,但依赖静态邻接矩阵,无法适应动态变化,处理突发事件时精度下降。空间数据利用面临三大难题:一是动态空间依赖建模,不同时段交通流空间关联模式差异显著,固定图结构难以刻画;二是长时依赖捕获困难,需兼顾15 min短期波动与日周期长期模式;三是物理约束缺失,纯数据驱动模型可能违背流量守恒定律,导致决策失误^[4]。

2 时空依赖性建模理论基础

2.1 交通流扩散传播机理分析

高速公路交通流的传播过程可以建模为有向图上的扩散过程,其本质是车辆密度波在路网中的传递。根据交通流理论,路段*i*在时刻*t*的交通流状态受到上游邻接路段历史状态的影响,这种影响通过扩散过程进行传播。扩散卷积操作定义为:

$$\mathbf{X}^{(k+1)} = \sigma(\mathbf{W} \odot (\mathbf{D}_O^{-1} \mathbf{A}_O \mathbf{X}^{(k)} + \mathbf{D}_I^{-1} \mathbf{A}_I \mathbf{X}^{(k)})) \quad (1)$$

式中: $\mathbf{X}^{(k)}$ 表示第*k*层的节点特征矩阵(维度 $N \times F$), $\mathbf{X}^{(k+1)}$ 表示第*k+1*层的节点特征矩阵(维度 $N \times F$),*k*表示网络层索引,*N*表示图中节点数量(个),*F*表示每个节点的特征维度(个), $\mathbf{A}_O$ 表示出度邻接矩阵(维度 $N \times N$), $\mathbf{A}_I$ 表示入度邻接矩阵(维度 $N \times N$), $\mathbf{D}_O^{-1}$ 表示出度矩阵的逆, $\mathbf{D}_I^{-1}$ 表示入度矩阵的逆, $\mathbf{W}$ 表示可学习的权重矩阵(维度 $F \times F$), $\sigma(\cdot)$ 表示非线性激活函数, $\odot$ 表示Hadamard逐元素乘^[5]。

扩散过程的传播速度与路段的自由流速度和拥堵程度相关,可以通过状态转移公式描述为:

$$q_{i,t+1} = q_{i,t} + \sum_{j \in N_{in}(i)} \alpha_{ji,t} q_{j,t} - \sum_{k \in N_{out}(i)} \alpha_{ik,t} q_{i,t} \quad (2)$$

式中: $q_{i,t}$ 表示路段*i*在时刻*t*的交通流量(辆/小时), $q_{i,t+1}$ 表示下一时间步的交通流量(辆/小时),*i*、*j*、*k*表示路段索引,*t*表示离散时间步(步), $N_{in}(i)$ 表示路段*i*的上游邻接路段集合, $N_{out}(i)$ 表示路段*i*的下游邻接路段集合, $\alpha_{ji,t}$ 表示从路段*j*到路段*i*的传播系数(取值0~1), $\alpha_{ik,t}$ 表示从路段*i*到路段*k*的传播系数(取值0~1), $\in$ 表示某个元素是某个集合的成员。

1. 南京感动科技有限公司 江苏南京 210046

2.2 动态图结构演化特性

高速公路网络的空间依赖关系随时间动态演化，表现为邻接矩阵的时变特性。

如图 1 所示，不同交通状态下路段间关联强度显著变化。拥堵时上游路段影响范围扩大、传播延迟增加；畅通时局部扰动快速消散、影响范围有限。这种动态特性要求模型自适应学习时变图结构，而非依赖固定拓扑关系。动态图演化受交通需求时空分布、路网几何特征及外部事件扰动等多种因素影响。通过分析历史数据中的关联模式变化，可识别典型演化模式，为构建自适应图学习机制提供理论依据^[6]。




图 1 不同交通状态下路段间关联强度变化对比

2.3 物理守恒约束原理

交通流遵循质量守恒定律。当路段没有匝道出入时，进出流量之差应当等同于路段内车流密度的变化。这条规律可以充当预测模型的先验知识，约束模型输出，避免出现与实际相违背的结果。守恒不仅适用于单个路段，也存在于整个路网。相邻路段之间的流量传递满足连续性方程，将其写入正则化项后即可融入训练过程。把物理规律带进学习之后，模型的预测精度有所改善，结果的可解释性和可靠性也明显增强^[7]。

3 自适应时空图神经网络构建

3.1 动态图邻接矩阵学习机制

静态图结构无法刻画路段关联随时间变化的特性。考虑到这一点，本文采用一种基于节点嵌入的动态邻接矩阵。每个路段对应一组随时间变化的嵌入向量，路段之间的关联强度由这些向量的运算结果得到：

$$\mathbf{A}_t^{\text{adaptive}} = M(U(\mathbf{E}_t^s \mathbf{E}_t^e)^T) \quad (3)$$

式中： $\mathbf{A}_t^{\text{adaptive}}$ 表示时刻 t 的自适应邻接矩阵（维度 $N \times N$ ，按行归一）， t 表示时间索引（无单位）， $\mathbf{E}_t^s$ 表示源节点嵌入矩阵（维度 $N \times d$ ）， $\mathbf{E}_t^e$ 表示目标节点嵌入矩阵（维度

$N \times d$ ，无单位）， d 表示嵌入维度（个）， $(\cdot)^T$ 表示矩阵转置， $U(\cdot)$ 表示线性整流激活函数， $M(\cdot)$ 表示按行归一化函数。

节点嵌入由三方面信息合成，分别是历史交通状态、时间周期特征和空间位置编码。时间特征用正弦余弦函数对时刻和日期编码，方便模型识别早晚高峰和工作日规律；空间编码则结合地理坐标与拓扑距离，把路网的几何结构保留下来。嵌入向量经门控机制动态调节各类信息的权重，让模型在拥堵时段更多关注上游路段，在自由流时段则偏向局部信息。

得到的动态邻接矩阵与静态拓扑矩阵之间通过可学习的系数 α 完成融合：

$$\mathbf{A}_{\text{final}} = \alpha \cdot \mathbf{A}_{\text{static}} + (1 - \alpha) \cdot \mathbf{A}_{\text{adaptive}} \quad (4)$$

式中： $\mathbf{A}_{\text{final}}$ 表示融合后的最终邻接矩阵（ $N \times N$ ）， α 表示融合权重系数（取值 0~1）， $\mathbf{A}_{\text{static}}$ 表示静态拓扑邻接矩阵（ $N \times N$ ）， $\mathbf{A}_{\text{adaptive}}$ 表示自适应学习得到的邻接矩阵（ $N \times N$ ）。

这样既保留了路网原本的拓扑结构，又能跟随交通状态做出调整。系数 α 在训练中由反向传播自动学习，最终找到静态信息与动态信息之间合适的平衡^[8]。

3.2 多尺度扩散卷积模块设计

交通流数据中包含的变化模式时间跨度差异较大，短至分钟级的瞬时波动，长至小时级的趋势演变，都需要纳入考虑。本文设计的多尺度扩散卷积模块借助多条并行的扩散路径，从不同时间尺度上提取时空特征：

$$\mathbf{H} = \sum_{s=1}^S \mathbf{W}_s \cdot G(\mathbf{X}, \mathbf{A}_t, \mathbf{K}_s) \quad (5)$$

式中： $\mathbf{H}$ 表示多尺度特征输出矩阵（维度 $N \times F'$ ）， $\sum_{s=1}^S \mathbf{W}_s$ 表示对尺度索引 s 从 1 到 S 的求和， S 表示尺度数量（个）， s 表示尺度索引， $\mathbf{W}$ 表示第 s 个尺度的可学习权重矩阵（维度 $F \times F'$ ）， $G(\cdot)$ 表示扩散卷积算子， $\mathbf{X}$ 表示输入节点特征矩阵（维度 $N \times F$ ）， $\mathbf{A}_t$ 表示时刻 t 的邻接矩阵或其融合结果（维度 $N \times N$ ）， $\mathbf{K}_s$ 表示第 s 个尺度的扩散步数（步）。




图 2 多尺度扩散卷积模块架构

如图 2 所示，多尺度模块包含三个并行分支，分别对应 1 步、2 步和 3 步并行扩散，捕获近邻、次近邻和远程依赖。

扩散卷积采用切比雪夫多项式近似，避免特征分解开销。 K 步扩散聚合 K 跳邻域信息：1步捕获直接相邻路段的即时影响，建模车辆直接传递；2步覆盖次近邻路段，反映交通波传播；3步触及更远路段，捕获路网宏观模式。各分支采用残差连接缓解梯度消失，输出通过注意力机制自适应融合，权重根据输入特征动态计算，使模型自动调整对不同尺度特征的关注度，并引入Dropout和层归一化提高泛化能力^[9]。

3.3 物理约束损失函数优化

为了让预测结果与交通流物理规律保持一致，在常规预测损失之外再添加一项物理约束正则项：

$$L_{\text{total}}=L_{\text{pred}}+\lambda L_{\text{physics}} \quad (6)$$

式中： L_{total} 表示总损失（辆/小时）， L_{pred} 表示预测损失（辆/小时）， L_{physics} 表示物理约束损失（辆/小时）， λ 表示正则化系数。

物理约束项依据交通流理论的两条基本原理。第一条是流量守恒。要维持路网中车辆总量的平衡，对于任一路段 i ，其流入量与流出量应满足关系：

$$|\sum q_{\text{in}}-\sum q_{\text{out}}-\Delta\rho Ln|<\varepsilon \quad (7)$$

式中： q_{in} 表示在当前时间步内从上游进入研究路段系统的累计通过量（辆）， q_{out} 表示在当前时间步内从研究路段系统流出的累计通过量（辆）， $\Delta\rho$ 表示车流密度变化量（辆/公里）， L 表示路段长度（公里）， n 表示车道数（条）， ε 表示守恒容差阈值（辆）。

预测一旦偏离这一关系便会受到惩罚，偏差越大惩罚越重。第二条是通行能力的上限约束，预测流量不得超过路段所能承载的最大值，表达式为：

$$\max\{0,q_{\text{pred}}-C\eta\} \quad (8)$$

式中： q_{pred} 表示预测交通流量（辆/小时）， C 表示设计通行能力（辆/小时）， η 表示服务水平系数（无量纲）。

具体处理时采取软约束的方式，理论上不可能出现的高流量值会被排除在外，同时允许少量越界以缓冲数据噪声。正则化系数 λ 并非固定值，训练初期取较小值，让模型先把数据本身的规律学到位，之后

随训练推进慢慢加大，使物理约束逐渐发挥更强的作用。总损失函数兼顾预测精度与物理合理性，模型得到的结果既贴

近实测，也符合交通流的基本特征^[10]。

4 实验验证与性能分析

4.1 实验方案设计

实验在两个公开数据集上完成。PEMS-BAY和METR-LA分别覆盖325个和207个传感器节点的交通速度数据，采样间隔都是5 min。数据按7:1:2切分为训练集、验证集和测试集。模型以过去12个时间步（60 min）的历史数据作为输入，输出未来12个时间步的流量预测。

实验对比了五种基线方法：历史平均法（historical average, HA）、自回归积分滑动平均模型（autoregressive integrated moving average, ARIMA）、门控循环单元（gated recurrent unit, GRU）、时空图卷积网络和扩散卷积循环神经网络（diffusion convolutional recurrent neural network, DCRNN）。所有深度学习模型均采用Adam优化器，初始学习率设置为0.001，批次大小为64，训练轮数为100轮，并采用早停策略防止过拟合。评价指标包括平均绝对误差（mean absolute error, MAE）、均方根误差（root mean square error, RMSE）和平均绝对百分比误差（mean absolute percentage error, MAPE）^[11]。

4.2 预测性能对比分析

如表1所示，本文提出的自适应时空图神经网络在不同预测时距上均取得了最优性能。在PEMS-BAY数据集上，15 min预测的MAE为1.32，相比STGCN降低了18.7%；30 min预测的MAE为1.68，降低了16.8%；60 min预测的MAE为2.05，降低了15.1%。RMSE指标显示了类似的改进趋势，15 min预测的RMSE为2.41，相比STGCN降低了21.3%。MAPE指标在长时预测中改进更为显著，60 min预测的MAPE达到8.2%，相比STGCN的10.8%降低了24.1%。

表1 不同方法在PEMS-BAY数据集上的预测性能对比

方法	15 min 预测			30 min 预测			60 min 预测		
	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%
HA	2.88	5.59	13.2	2.88	5.59	13.2	2.88	5.5	13.2
ARIMA	1.95	3.87	10.9	2.33	4.52	12.7	2.79	5.41	14.6
GRU	1.71	3.42	9.6	1.97	3.91	11.2	2.35	4.63	13.1
STGCN	1.62	3.06	8.8	2.02	3.85	10.5	2.41	4.59	10.8
DCRNN	1.38	2.77	7.9	1.74	3.53	9.8	2.15	4.38	10.2
本文方法	1.32	2.41	7.2	1.68	3.02	8.6	2.05	3.89	8.2

性能提升主要归因于三个关键设计：动态邻接矩阵学习机制使模型能够捕获时变的空间依赖关系，在交通状态发生

变化时保持预测精度；多尺度扩散卷积有效平衡了短期波动和长期趋势的建模，提高了不同预测时距的准确性；物理约束的引入显著降低了异常预测的发生率，提升了模型的可靠性。在 METR-LA 数据集上的实验结果呈现相似的改进模式，验证了方法的泛化能力。

4.3 消融实验与参数敏感性分析

消融实验系统评估了各模块贡献。如表 2 所示，去除动态图学习模块后，15 min 预测的 MAE 上升至 1.48，性能下降 12.1%；去除多尺度卷积模块，MAE 上升至 1.45，下降 9.8%；去除物理约束，MAE 上升至 1.41，下降 6.8%。三模块协同使完整模型达到最优性能。参数敏感性分析显示：嵌入维度 d 在 32 时最优，过小无法充分表达特征，过大导致过拟合；扩散步数 K 最优值为 3，覆盖 2~3 跳邻域依赖；正则化系数 λ 在 0.01 时最佳，过大限制拟合能力，过小则约束作用不明显。

表 2 消融实验结果（PEMS-BAY 数据集，15 min 预测）

模型配置	MAE	RMSE	MAPE/%	性能下降 /%
完整模型	1.32	2.41	7.2	—
无动态图学习	1.48	2.73	8.1	12.1
无多尺度卷积	1.45	2.68	7.9	9.8
无物理约束	1.41	2.58	7.6	6.8
静态图 + 单尺度	1.56	2.89	8.5	18.2
嵌入维度 $d=16$	1.39	2.52	7.5	5.3
嵌入维度 $d=64$	1.37	2.49	7.4	3.8
扩散步数 $K=2$	1.36	2.47	7.3	3.0
扩散步数 $K=4$	1.38	2.51	7.5	4.5
正则系数 $\lambda=0.001$	1.35	2.45	7.3	2.3
正则系数 $\lambda=0.1$	1.43	2.62	7.7	8.3

5 结论

高速公路流量预测中的时空依赖建模一直是难点之一。本文将自适应图卷积与物理约束结合起来，借动态图邻接矩阵学习和多尺度扩散卷积捕捉随时间变化的空间关联以及不同跨度的时空特征，再用物理约束损失把预测结果约束在合理范围内。从实验来看，所提方法在长时预测和复杂交通状态下相较现有技术有较明显的优势，对智慧高速公路的建设也具有一定参考价值。极端天气条件下的表现以及在更大规模路网中的应用效果，还需要在后续工作中继续验证。

参考文献：

[1] 崔鸿飞,周强,顾晶晶,等.面向交通流量预测的时空前缀微调大语言模型框架[J/OL].计算机工程与应

用,1-12[2026-06-04].<https://link.cnki.net/urlid/11.2127.TP.20250928.1028.008>.

[2] 刘海悦,伍添龙,毛自森.改进的 Transformer-LSTM 模型在交通流量预测中的应用与优化[J].陆军工程大学学报,2025,4(4): 80-87.

[3] 罗义凯,徐金华,李昱燃,等.基于时空关联和异构图卷积的车道级流量预测[J].哈尔滨工业大学学报,2025,57(11): 62-70.

[4] 杜明辉,贺玉龙,陶宏志,等.基于成都绕城高速实测数据的高流量交通噪声预测模型适用性评估[J].四川环境,2025,44(3): 82-86.

[5] 陆启想.基于深度学习的交通流量预测研究[D].南京:南京信息工程大学,2025.

[6] 何仲祥,吴明礼.基于改进 CNN-LSTM 的高速公路交通流量预测研究[J].计算机应用与软件,2025,42(6):136-140.

[7] 李胤浩.基于图卷积和 FCM 的高速公路交通流预测及状态判别研究[D].重庆:重庆交通大学,2025.

[8] 李旭峰.基于数字孪生的城市交通流量特征分析及短期预测研究[D].济南:山东师范大学,2025.

[9] 武青青.低排放视角下的高速公路事故拥堵控制策略研究[D].济南:山东交通学院,2025.

[10] 李巍.高速公路机电系统信息化平台与大数据融合研究[J].机电工程技术,2025,54(10): 113-117.

[11] 王萍,赵非凡.基于 SVD-BiGRU 的高速公路短时交通流量预测研究[J].太原学院学报(自然科学版),2025,43(3): 72-77.

【作者简介】

邱陵(1984—),男,江苏南京人,硕士研究生,中级工程师,研究方向:电子信息工程。

(收稿日期:2025-10-28 修回日期:2026-06-04)