

面向大规模交通网络的时空关联挖掘方法

范晓亮， 彭朝鹏， 郑传潘， 王 程

(厦门大学 信息学院，计算机科学与技术系，厦门 361005)

摘要：时空关联挖掘是智能交通领域的关键技术之一。大规模交通网络中的交通流量数据具有高度非线性和复杂特征，故精准地预测交通流量面临巨大挑战。现有方法大多设计2个独立模块来分别捕获交通流量的时间和空间相关性，故无法精准地对流量数据中的复杂时空相关性建模。该文提出一种时空组合图卷积神经网络(STCGCN)，以更好地预测交通流量。STCGCN通过构建自适应时空组合图，并提出时空组合图卷积，来有效揭示交通流量数据动态和复杂的时空相关性。在美国加利福尼亚州高速公路流量公开数据集上进行了实验，结果表明STCGCN的预测效果优于11个现有方法。

关键词：交通流量预测；时空数据挖掘；图卷积网络；大数据融合分析

中图分类号：TP311 **文献标志码：**A

DOI：10.16511/j.cnki.qhdxxb.2023.22.029

智能交通系统是解决当前城市交通拥堵顽疾的常用技术方案，而交通流量预测是构建智能交通系统的基础。在城市管理中，准确地预测交通流量不仅有助于交通管理部门对道路拥堵进行预判从而提早疏导，而且有助于提升道路通行效率，减少交通事故，并节约人们的出行时间^[1]。

交通流量预测是典型的时空数据预测问题。图1是交通流量数据的时空相关性示意图，其中时间维度上包含2个连续时间切片，空间维度上包含3个节点表示道路网结构。在时间维度上，某个节点的流量会受到其历史流量数据的影响；在空间维度上，某个时刻不同节点的流量之间也会互相影响。因此，研究人员提出使用循环神经网络^[2]或者一维卷积神经网络^[3]来捕获时间相关性，并使用二维卷积神经网络^[4]或者图卷积网络^[5]来捕获空间相关性。然而，现有工作忽略了某时刻某节点流量数据也将影响未来某时刻其他节点流量的情况。因此，当前主流的分别使用2个模块捕获时间和空间相关性的方法，不能有效地捕获交通流量数据中的动态和复杂的时空相关性。

为了应对交通流数据中处于不同时间步的不同节点之间的时空相关性难以有效建模的挑战，本文




图1 交通流量数据的时空相关性

提出了时空组合图卷积网络(spatio-temporal combinational graph convolutional networks, STCGCN)模型。首先，根据时空嵌入向量构建跨时间切片的自适应时空组合图邻接矩阵，该邻接矩阵能够在训练过程中自动学习参数，以适应节点之间的复杂时空相关性。然后，设计时空组合图卷积，捕获交通流量数据中的时空相关性，融合历史时间步的时空特征，输出预测结果。最后，在真实的公开数据集上进行了实验验证。本文的主要贡献为：1) 构建了自适应时空组合图，同时包含了动态的时间相关性、空间相关性、跨时空相关性；2) 提出了STCGCN模型，能够捕获交通流量数据中动

态和复杂的时空相关性; 3) 在真实的高速公路流量数据集上进行实验, 验证了本文模型的预测效果优于 11 个现有预测方法。

1 相关工作

交通流量预测是交通领域的一个传统问题, 经过几十年的研究, 取得了大量的研究成果^[6]。早期的研究工作主要基于统计学方法, 包括历史平均模型、差分自回归滑动平均模型、向量自回归模型等^[7], 这类方法无法有效地处理非线性的交通流量数据。为了对复杂的交通流量数据进行建模, 传统的机器学习模型被应用到交通流量预测领域, 如 K 近邻模型、支持向量机模型等^[8], 但这些机器学习方法无法对交通流量数据中的时空相关性进行有效建模, 而且需要大量的特征。随着深度学习技术的发展, 研究人员提出使用深度置信网络、堆栈自编码器模型、长短时记忆网络等来预测交通流量。但是, 这类早期的基于神经网络的方法主要关注交通流量数据在时间维度上的相关性。为了捕获空间相关性, Zhang 等^[4]基于残差卷积网络设计了时空残差网络 (spatio-temporal residual networks, ST-ResNet)。但是, ST-ResNet 只能用于规则的网格数据, 而无法应用于复杂的城市道路、高速路网的交通流量预测^[9]。

近年来, 图卷积神经网络开始兴起^[10]。不同于传统的卷积神经网络只能应用于规则的网格数据, 图卷积神经网络可以直接在图结构数据上实现卷积操作。图卷积神经网络的强大图结构数据建模能力在交通流量预测领域引起了广泛关注。研究人员使用图卷积网络捕获不同节点之间的空间相关性, 使用门控循环单元 (gated recurrent unit, GRU) 网络^[2] 或者一维卷积神经网络 (one-dimensional convolutional neural network, 1D CNN)^[3] 捕获节点在时间维度上的相关性。这些代表性工作包括扩散卷积循环神经网络 (diffusion convolutional recurrent neural network, DCRNN)^[2]、时空图卷积网络 (spatio-temporal graph convolutional networks, STGCN)^[3]、基于波形网络的图卷积神经网络 (Graph WaveNet)^[11]、基于注意力机制的时空图卷积网络 (attention based spatial-temporal graph convolutional networks, ASTGCN)^[12]、时空同步图卷积网络 (spatial-temporal synchronous graph convolutional networks, STSGCN)^[13]、图多注意

力网络 (graph multi-attention network, GMAN)^[14]、自适应图卷积循环网络 (adaptive graph convolutional recurrent network, AGCRN)^[15]、时间感知“之”字形图卷积网络 (time zigzags at graph convolutional networks, Z-GCNETs)^[16] 等。这些基于图神经网络的方法大多设计 2 个模块来分别对交通流量数据的时间和空间相关性建模, 并在交通流量预测中取得了良好性能, 但是由于将时间相关性和空间相关性分开建模, 无法有效地捕获交通流量数据中的动态和复杂的时空相关性。

2 问题定义

假设道路网中有 N 个节点, 每个节点每间隔一定时间 (如 5 min) 都会采集 C 个交通状态类型数据 (如车流量、平均车速、平均车道占有率等)。 t 时刻所有节点的交通流量数据可以表示为 $\mathbf{X}_t \in \mathbb{R}^{N \times C}$ 。

交通流量预测的目标是给定历史上 P 个时刻所有 N 个节点的交通流量数据 $\mathbf{x} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_P) \in \mathbb{R}^{P \times N \times C}$, 预测未来 Q 个时刻 N 个节点的数据 $\hat{\mathbf{y}} = (\hat{\mathbf{X}}_{P+1}, \hat{\mathbf{X}}_{P+2}, \dots, \hat{\mathbf{X}}_{P+Q}) \in \mathbb{R}^{Q \times N \times C}$ 。其中: $\hat{\mathbf{X}}_{P+i} \in \mathbb{R}^{N \times C}$ 表示 $P+i$ ($i=1, 2, \dots, Q$) 时刻的预测值, C' 表示每个节点需要预测的交通状态类型个数。

3 时空组合图卷积网络

图 2 展示了本文提出的 STCGCN 的总体架构。STCGCN 由 3 个模块组成: 时空组合图构建模块、时空组合图卷积模块、预测模块。

3.1 时空组合图构建模块

现有基于图卷积的交通流量预测方法大多使用预定义的图结构^[2-3], 其主要缺陷是难以捕获交通网络中节点之间蕴含的潜在时空相关性^[11, 15]。一些研究提出了使用自适应的图结构, 通过端到端训练学习邻接矩阵, 取得了较好的预测结果^[11, 15], 但由于仅使用了空间维度上的图结构, 依然无法对动态的空间相关性有效建模。为此, 本文提出了时空组合图构建模块, 以同时挖掘动态的时间相关性、空间相关性以及跨时空相关性 (如图 1 所示)。该模块包括 2 个子模块:

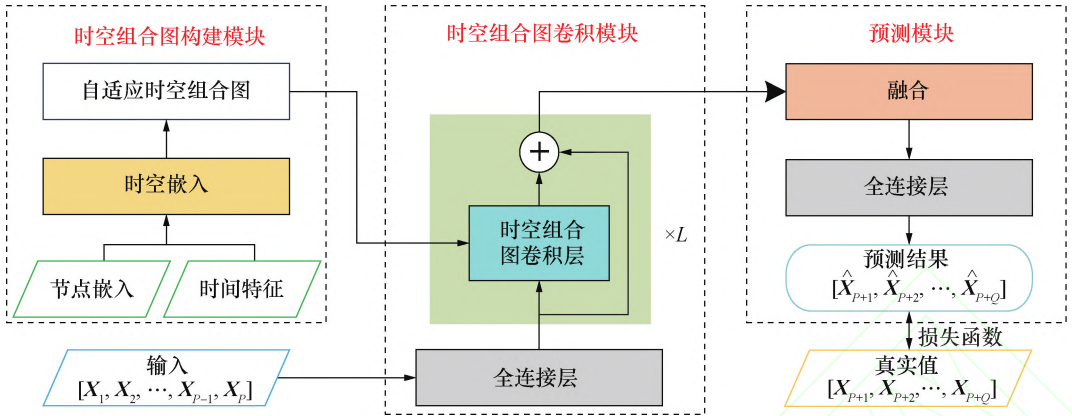


图2 时空组合图卷积网络

1) 时空嵌入。

(1) 节点嵌入。首先为每个节点随机初始化一个节点嵌入向量, 然后使用全连接网络把节点嵌入向量映射至 D 维空间中。

(2) 时间特征。由于交通流量具有明显的周期性, 因此本文引入时间特征来构建时空嵌入向量。本文考虑 2 个时间特征, 分别是当前时刻 t 处于一天中的第几个时刻(time-of-day)和当天处于一周中的第几天(day-of-week)。首先将 2 个时间特征转化为独热编码并进行拼接, 得到时间特征向量, 然后使用另一个全连接网络把它映射至 D 维空间中。

(3) 时空嵌入。在每个时刻每个节点, 把节点嵌入向量和时间特征向量相加, 得到所有节点在每个时刻的时空嵌入向量 $E_t \in \mathbb{R}^{N \times D}$, 它可以在模型训练的过程中进行更新。

2) 自适应时空组合图。

(1) 潜在空间建模方法^[17]。给定一个图, 假设所有节点均处在一个潜在空间中, 节点在这个空间中的向量表示以及向量各个元素之间的交互关系共同影响着节点之间的关联关系。具体地, 需要学习 2 个矩阵: $E \in \mathbb{R}^{N \times D}$ 表示 N 个节点在潜在空间中的 D 维向量, $B \in \mathbb{R}^{D \times D}$ 表示 D 维向量各个元素之间的交互关系。 EBE^T 可以表示节点之间的连接关系。

(2) 自适应时空组合图邻接矩阵。基于时空嵌入和潜在空间建模方法, 自适应时空组合图邻接矩阵可以定义为:

$$\tilde{A}_t = \text{softmax}[\psi(E_t B E_t^T)]. \quad (1)$$

$$\psi(x) = \begin{cases} x, & x \geq \delta; \\ 0, & \text{其他}. \end{cases} \quad (2)$$

式(2)的 $\psi(x)$ 用于丢弃邻接矩阵中的弱连接(小于

指定阈值 δ), 式(1)中的 softmax 函数用于规范化操作。 \tilde{A}_t 表示 t 时刻 N 个节点之间的连接关系。为了建立跨时间的节点连接关系, 对式(1)进行扩展得到

$$\tilde{A}_{t-1:t} = \text{softmax}[\psi(E_{t-1} B E_t^T)]. \quad (3)$$

式中: $\tilde{A}_{t-1:t}$ 表示相邻 2 个时刻之间的规范化自适应时空组合图邻接矩阵。

3.2 时空组合图卷积模块

基于 3.1 节的时空组合图构建模块, 本节提出了时空组合图卷积模块。通过定义自适应的时空组合图卷积算子, 构建自适应时空组合图卷积层, 以从输入的交通流量序列中提取时空特征。

1) 时空组合图卷积算子。

Kipf 等^[18]提出的空间图卷积算子的定义为

$$Z = \phi(\tilde{A} X W + b). \quad (4)$$

式中: $X \in \mathbb{R}^{N \times D_1}$ 和 $Z \in \mathbb{R}^{N \times D_2}$ 分别是图卷积算子的输入和输出信号, $W \in \mathbb{R}^{D_1 \times D_2}$ 和 $b \in \mathbb{R}^{D_2}$ 是模型参数, $\phi(\cdot)$ 表示激活函数, $\tilde{A} \in \mathbb{R}^{N \times N}$ 是规范化邻接矩阵。

基于时刻 $t-1$ 和时刻 t 之间的时空组合图邻接矩阵 $\tilde{A}_{t-1:t}$ 和 \tilde{A}_t , 本文定义时空组合图卷积算子为

$$Z_t = \phi(\tilde{A}_{t-1:t} X_{t-1} W_1 + \tilde{A}_t X_t W_2 + b). \quad (5)$$

式中: $\tilde{A}_{t-1:t} X_{t-1} W_1$ 表示聚合 $t-1$ 时刻所有邻居节点的信息, $\tilde{A}_t X_t W_2$ 表示聚合 t 时刻所有邻居节点的信息。

2) 时空组合图卷积层。

基于时空组合图卷积算子, 可以构建时空组合图卷积层。如图 3 所示, 首先使用全连接网络把输

入的交通流量数据映射至 D 维空间中, 然后输入到多层时空组合图卷积层中。时空组合图卷积算子构建了相邻 2 个时刻一阶邻居的时空相关性, 通过堆叠多层的时空组合图卷积层, 可以捕获更长期更高阶邻居范围内的时空相关性。为了减缓梯度消失的问题, 堆叠的时空组合图卷积层中采用了残差连接^[19]。

3.3 预测模块

经过 L 层的时空组合图卷积层捕获时空相关性, 得到了所有历史 P 个时刻的隐藏状态 $\mathbf{Z}_i^{(L)} \in \mathbb{R}^{N \times D}$ 。如图 3 所示, 为了对长期的时间依赖性建模, 首先融合所有历史 P 个时刻的信息, 然后使用

全连接网络输出最终预测结果。

$$\tilde{\mathbf{Z}} = [\mathbf{Z}_1^{(L)}, \mathbf{Z}_2^{(L)}, \dots, \mathbf{Z}_P^{(L)}], \quad (6)$$

$$\hat{\mathbf{X}} = \mathbf{W}_4(\phi(\mathbf{W}_3\tilde{\mathbf{Z}} + \mathbf{b}_3)) + \mathbf{b}_4. \quad (7)$$

式(6)中 $[\cdot, \cdot]$ 表示拼接操作, 式(7)中 $\hat{\mathbf{X}}$ 表示最终的预测结果。

本文使用平均绝对误差函数(mean absolute error, MAE)作为损失函数:

$$\mathcal{L}(\Theta) = \frac{1}{Q} \sum_{i=1}^Q |\hat{\mathbf{X}}_{P+i} - \mathbf{X}_{P+i}|. \quad (8)$$

式中: Θ 表示网络中的所有可学习参数, $\hat{\mathbf{X}}_{P+i}$ 和 \mathbf{X}_{P+i} 分别表示 $P+i$ 时刻的预测值和真实值。

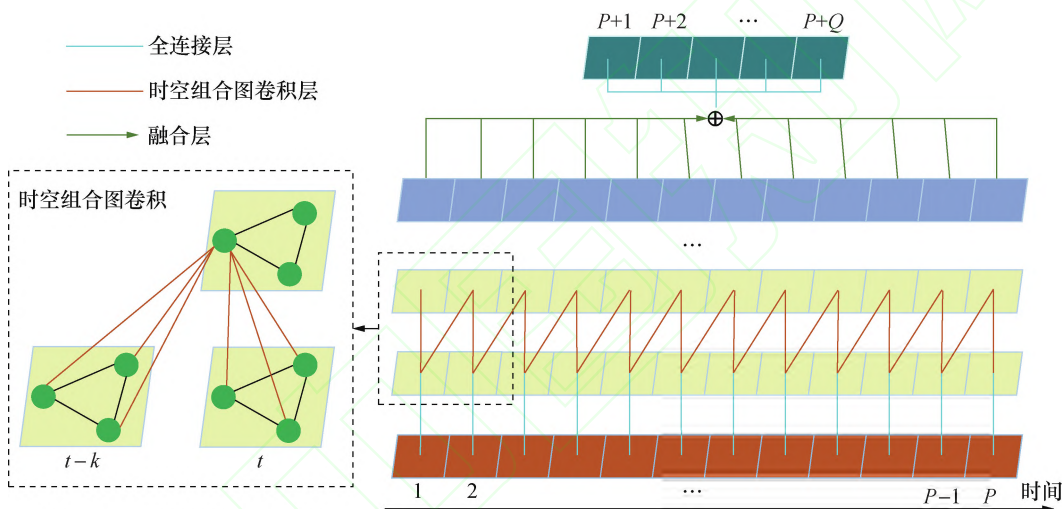


图 3 时空组合图卷积模块与预测模块

4 实验分析

4.1 实验数据

本文使用美国加利福尼亚州交通局性能测量系统(Caltrans performance measurement system, PeMS)采集的 2 个高速公路数据集 PeMSD4 和 PeMSD8 来开展实验^[12-13]。2 个数据集的基本情况如表 1 所示。

表 1 实验数据集

数据集	时间范围	时间间隔/ min	传感器 个数
PeMSD4	2018-01-01—2018-02-28	5	307
PeMSD8	2016-07-01—2016-08-31	5	170

4.2 评价指标及基准模型

本文使用均方误差(root mean square error, RMSE)和 MAE 2 个常用的指标来评价模型性能:

$$\text{RMSE} = \sqrt{\frac{1}{Q} \sum_{i=1}^Q (\hat{\mathbf{X}}_{P+i} - \mathbf{X}_{P+i})^2}, \quad (9)$$

$$\text{MAE} = \frac{1}{Q} \sum_{i=1}^Q |\hat{\mathbf{X}}_{P+i} - \mathbf{X}_{P+i}|. \quad (10)$$

本文使用以下 11 个已有的交通流量预测方法作为基准模型进行对比:

1) 向量自回归(vector autoregressive, VAR)模型^[7]: 传统的时间序列模型, 可以捕获多个时间序列之间的相关性。

2) 支持向量机回归(support vector regression, SVR)^[8]: 将支持向量机应用于回归任务的方法。

3) 全连接的长短期记忆递归(fully connected long-short term memory, FC-LSTM)神经网络^[20]: 基于长短期记忆递归神经网络的编码器-解码器框架。

4) DCRNN^[2]: 基于扩散图卷积和 GRU 的编码器-解码器框架。

5) STGCN^[3]: 基于 Chebyshev 图卷积和一维卷积构建的时空图卷积网络。

6) ASTGCN^[12]: 基于注意力机制的时空图卷积网络。

7) Graph WaveNet^[11]: 构建了自适应邻接矩阵的时空图卷积网络。

8) STSGCN^[13]: 在局部时空子图上建模时空相关性的时空图卷积网络。

9) AGCRN^[15]: 使用自适应邻接矩阵建模空间相关性、使用 GRU 建模时间相关性的时空图网络。

10) GMAN^[14]: 完全使用注意力机制的多重注意力时空图网络。

11) Z-GCNETs^[16]: 基于“之”字形持久性理论的时空图网络。

4.3 实验方法

本文对原始数据进行 0 均值标准化, 并按照 6:2:2 的比例划分训练集、验证集和测试集。依据现有方法^[15-16]的设定, 本文使用历史 1 h (12 个时刻, $P=12$) 的数据预测未来 1 h ($Q=12$) 的数据。每次实验运行 200 轮, 并保存在验证集上表现最好的模型作为最终预测模型。每个实验重复 5 次, 记录平均误差和标准差。

模型训练使用的优化器为自适应矩估计优化器 (adaptive moment estimation, Adam), 初始学习率为 0.001。模型中的激活函数使用修正线性单元 (rectified linear unit, ReLU) 激活函数, 并且在每个 ReLU 之前添加批规范层 (batch normalization layer, BN)。STCGCN 中的超级参数有 3 个: 时空

组合图卷积层的层数 L 、自适应时空组合图邻接矩阵中的阈值 δ 和隐藏状态的维度 D 。表 2 列出了模型在 PeMSD4 和 PeMSD8 数据集上的超级参数设置。

表 2 2 个数据集上的超级参数设置

参数	PeMSD4 数据集	PeMSD8 数据集
L	7	6
δ	0.3	0.2
D	64	64

4.4 实验结果与分析

4.4.1 与基准方法的性能对比

1) 总体性能对比。表 3 列出了 STCGCN 与基准方法在 2 个数据集上的实验结果对比。可以看出, 传统的时间序列预测方法无法有效地对交通数据中复杂的时空相关性建模, 预测性能不理想; 相比于传统方法, 机器学习和深度学习方法可以取得更好的预测结果, 基于图神经网络的方法在时空相关性的建模上优于一般的深度学习方法, 有效降低了误差; 本文提出的 STCGCN 模型使用统一的组件有效挖掘了交通流量数据中动态的时间相关性、空间相关性和跨时空相关性, 取得了最优预测结果。

2) 各个时刻的性能对比。图 4 展示了在 PeMSD4 (如图 4a 所示) 和 PeMSD8 (如图 4b 所示) 这 2 个数据集上, 随着预测时长增加, Graph WaveNet 等 6 种方法的 RMSE 和 MAE 变化情况。从图 4 中 RMSE 和 MAE 的走势可以看出, 随着预

表 3 不同方法在 PeMSD4 和 PeMSD8 数据集上的性能对比

模型	PeMSD4 数据集		PeMSD8 数据集	
	RMSE	MAE	RMSE	MAE
VAR	37.76	24.44	19.83	29.24
SVR	38.91	26.18	20.92	31.23
FC-LSTM	37.11±0.50	23.60±0.52	21.18±0.27	31.88±0.43
DCRNN	37.48±0.10	24.42±0.06	18.49±0.16	27.30±0.22
STGCN	36.43±0.22	23.90±0.17	18.79±0.49	28.23±0.36
ASTGCN	35.59±0.35	22.90±0.20	18.72±0.16	28.99±0.11
Graph WaveNet	31.06±0.17	19.91±0.10	15.57±0.12	24.32±0.21
STSGCN	31.02±0.29	19.62±0.16	16.12±0.25	24.89±0.52
AGCRN	32.01±0.17	19.74±0.09	15.92±0.19	25.31±0.25
GMAN	30.85±0.21	19.25±0.06	14.87±0.15	24.06±0.16
Z-GCNETs	31.33±0.11	19.54±0.07	16.12±0.08	25.74±0.13
STCGCN	30.38±0.05	18.86±0.03	14.47±0.05	23.66±0.06

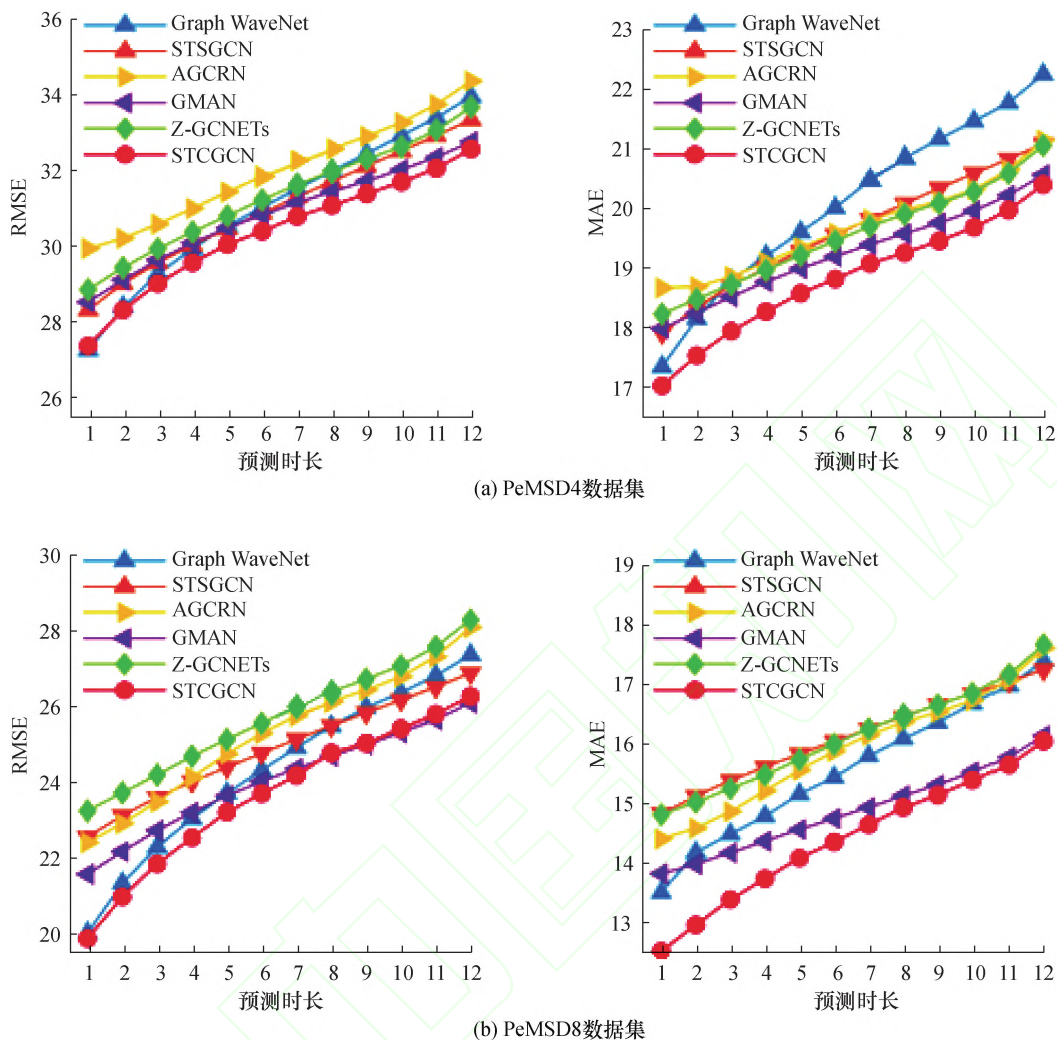


图 4 不同方法随着预测时长的性能变化

测时长增加, 预测难度增大, 各个模型的预测误差增大。但是, 本文提出的 STCGCN 在各个预测时刻都取得了最好的预测结果, 不仅在短期预测中取得了较高的预测精度, 而且预测误差随着预测时长增大得更加缓慢。这说明本文提出的时空组合图卷积网络能够有效挖掘交通流量数据中的时空关联性。

4.4.2 超级参数设置的影响

图 5 和 6 分别展示了在 PeMSD4、PeMSD8 这 2 个数据集上时空组合图卷积层的层数 L 、自适应时空组合图邻接矩阵中的阈值 δ 和隐藏状态的维度 D 3 个超级参数设置对模型性能的影响。

1) L 的影响。从图 5a 和 6a 中可以看出, 随着层数 L 的增大, 预测误差减小, 这是因为层数更大的网络能够提取更丰富的时空特征。但是, 当网络层数过大时, 网络可能面临梯度消失的问题, 因此


模型性能开始下降。

2) δ 的影响。从图 5b 和 6b 中可以看出, 随着 δ 的增大, 预测误差先减小后增大, 这是因为太小的阈值会导致邻接矩阵过于稀疏, 丢失节点之间的连接关系, 而太大的阈值则会引入不必要的信息, 导致模型性能下降。


3) D 的影响。从图 5c 和 6c 中可以看出, 当隐藏状态维度 D 较小时, 模型复杂度较低, 无法有效地对复杂的交通流量数据建模。随着维度的增大, 模型预测误差开始减小。但是, 当隐藏状态维度太大时, 模型可能面临过拟合的问题, 导致性能快速下降。

4.4.3 模型参数量和运算时间的对比


表 4 列出了 DCRNN 等 9 种方法在 2 个数据集上的模型参数量和运算时间的对比。




(a) 时空组合图卷积积层数 L




(a) 时空组合图卷积积层数 L




(b) 自适应时空组合图邻接矩阵中的阈值 δ



(b) 自适应时空组合图邻接矩阵中的阈值 δ



(c) 隐藏状态的维度 D



(c) 隐藏状态的维度 D

图 5 PeMSD4 数据集上 3 个超级参数设置对模型性能的影响

图 6 PeMSD8 数据集上 3 个超级参数设置对模型性能的影响

表 4 不同方法在 PeMSD4 和 PeMSD8 数据集上的模型参数数量和运算时间对比

模型	PeMSD4 数据集			PeMSD8 数据集		
	模型参数数量/ 10^6	训练时间/ (s · 轮 ⁻¹)	推断时间/ s	模型参数数量/ 10^6	训练时间/ (s · 轮 ⁻¹)	推断时间/ s
DCRNN	0.37	69.55	11.97	0.37	46.41	8.81
STGCN	0.38	6.54	13.44	0.30	4.24	9.37
ASTGCN	0.45	53.51	14.67	0.18	47.07	14.01
Graph WaveNet	0.31	32.40	2.60	0.31	20.48	1.72
STSGCN	2.87	56.18	6.03	1.66	31.23	3.09
AGCRN	0.75	37.05	5.55	0.75	21.74	3.04
GMAN	0.57	82.40	9.16	0.57	32.27	4.06
Z-GCNETs	0.52	88.41	11.84	0.52	52.51	7.36
STCGCN	0.24	42.00	4.90	0.21	19.63	2.26

1) 模型参数数量。STCGCN 拥有几乎最少的模型参数数量。

2) 训练时间。STGCN 的训练时间最少, STCGCN 与 Graph WaveNet、AGCRN 次之且相近。

3) 推断时间。推断时间指模型在验证集上的

运行时间, STCGCN 与 Graph WaveNet、AGCRN 所用的时间最少。

综合预测精度和算法效率 2 个因素, 本文所提出的 STCGCN 具有明显优势: 1) STCGCN 与所有基准方法相比, 具有最高的预测精度(表 3); 2) STCGCN 与 STGCN 和 Graph WaveNet 等方法

在训练和推断时均具有近似的算法效率(表 4)。

5 军事领域应用前景分析

本文提出的面向大规模交通网络的时空关联挖掘方法 STCGCN 在军事领域的应用前景如下:

- 1) STCGCN 能够在战前对目标区域的交通状态进行有效建模,并准确定位城市交通枢纽和关键通道,以辅助战术部队对关键目标进行有效打击,从而达到战前瘫痪敌方交通运输网络的效果。
- 2) STCGCN 能够在战后对城市的交通态势进行有效分析,并迅速检测城市的异常交通行为,以辅助城市的反恐工作,达到战后快速恢复城市生产生活秩序的效果。

6 总结

本文提出了时空组合图卷积网络模型 STCGCN,通过构建时空组合图来有效揭示大规模交通网络中的复杂时空关联特性,并设计时空组合图卷积,同时挖掘数据中动态的时间相关性、空间相关性和跨时空相关性。首先,根据时空嵌入向量构建跨时间切片的自适应时空组合图邻接矩阵,该邻接矩阵能够在训练过程中自动学习参数,以适应节点之间的复杂时空相关性。然后,设计时空组合图卷积捕获交通流量数据中的时空相关性。最后,融合历史时间步的时空特征,输出预测结果。在真实的高速公路流量数据集上的实验结果表明,本文提出的模型的预测效果优于其他 11 个已有的交通预测方法,验证了该模型在大规模交通网络的时空关联挖掘方面具有显著优势。未来,将把该模型应用到其他多源异构数据融合任务中来进一步拓展模型的适用场景。

参考文献 (References)

- [1] VERES M, MOUSSA M. Deep learning for intelligent transportation systems: A survey of emerging trends [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(8): 3152–3168.
- [2] LI Y G, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting [C]//Proceedings of the 6th International Conference on Learning Representations. Vancouver, Canada: OpenReview.net, 2018: 1–16.
- [3] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting [C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. Stockholm, Sweden: ijcai.org, 2018: 3634–3640.
- [4] ZHANG J B, ZHENG Y, QI D K. Deep spatio-temporal residual networks for citywide crowd flows prediction [C]//Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence. San Francisco, USA: AAAI Press, 2017: 1655–1661.
- [5] 冯宁, 郭晟楠, 宋超, 等. 面向交通流量预测的多组件时空图卷积网络 [J]. 软件学报, 2019, 30(3): 759–769.
FENG N, GUO S N, SONG C, et al. Multi-component spatial-temporal graph convolution networks for traffic flow forecasting [J]. Journal of Software, 2019, 30(3): 759–769. (in Chinese)
- [6] ZHENG C P, WANG C, FAN X L, et al. STPC-Net: Learn massive geo-sensory data as spatio-temporal point clouds [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(8): 11314–11324.
- [7] BOX G, JENKINS G, REINSEL G, et al. Time series analysis: Forecasting and control [M]. 5th ed. Hoboken, USA: John Wiley and Sons, 2015.
- [8] WU C H, HO J M, LEE D T. Travel-time prediction with support vector regression [J]. IEEE Transactions on Intelligent Transportation Systems, 2004, 5(4): 276–281.
- [9] ZHENG C P, FAN X L, WEN C L, et al. DeepSTD: Mining spatio-temporal disturbances of multiple context factors for citywide traffic flow prediction [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3744–3755.
- [10] 徐冰冰, 岑科廷, 黄俊杰, 等. 图卷积神经网络综述 [J]. 计算机学报, 2020, 43(5): 755–780.
XU B B, CEN K T, HUANG J J, et al. A survey on graph convolutional neural network [J]. Chinese Journal of Computers, 2020, 43(5): 755–780. (in Chinese)
- [11] WU Z H, PAN S R, LONG G D, et al. Graph wavenet for deep spatial-temporal graph modeling [C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence. Macao, China: AAAI Press, 2019: 1907–1913.
- [12] GUO S N, LIN Y F, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting [C]//Proceedings of the Thirty-Third AAAI Conference on Artificial Intelligence and Thirty-First Innovative Applications of Artificial Intelligence Conference and Ninth AAAI Symposium on Educational Advances in Artificial Intelligence. Honolulu, USA: AAAI Press, 2019: 114.
- [13] SONG C, LIN Y F, GUO S N, et al. Spatial-temporal synchronous graph convolutional networks: A new framework for spatial-temporal network data forecasting [C]//Proceedings of the Thirty-Fourth AAAI Conference on Artificial Intelligence. New York, USA: AAAI Press, 2020: 914–921.
- [14] ZHENG C P, FAN X L, WANG C, et al. GMAN: A graph multi-attention network for traffic prediction [C]//Proceedings of the Thirty-Fourth AAAI Conference on Artificial Intelligence. New York, USA: AAAI Press, 2020: 1234–1241.
- [15] BAI L, YAO L N, LI C, et al. Adaptive graph convolutional recurrent network for traffic forecasting [C]//Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver, Canada: Curran Associates, 2020: 1494.

- [16] CHEN Y Z, SEGOVIA-DOMINGUEZ I, GEL Y R. Z-GCNets: Time zigzags at graph convolutional networks for time series forecasting [C]//Proceedings of the 38th International Conference on Machine Learning. Held Virtually; PMLR, 2021: 1684–1694.
- [17] DENG D X, SHAHABI C, DEMIRYUREK U, et al. Latent space model for road networks to predict time-varying traffic [C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, USA: ACM, 2016: 1525–1534.
- [18] KIPF T N, WELLMING M. Semi-supervised classification with graph convolutional networks [C]//Proceedings of the 5th International Conference on Learning Representations. Toulon, France: OpenReview.net, 2017: 1–14.
- [19] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 770–778.
- [20] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks [C]//Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal, Canada, 2014: 3104–3112.

Spatio-temporal correlation mining method for large-scale traffic networks

FAN Xiaoliang, PENG Zhaopeng, ZHENG Chuanpan, WANG Cheng

(Department of Computer Science and Technology, School of Informatics, Xiamen University, Xiamen 361005, China)

Abstract: [Objective] Spatio-temporal correlation mining is a key technology in intelligent transportation systems and is usually applied to spatio-temporal data prediction problems such as traffic flow prediction. Accurately predicting traffic flows in urban management is extremely important for alleviating urban traffic congestion, improving traffic efficiency, and reducing traffic accident occurrences. However, it is extremely challenging to accurately predict traffic flows in large-scale traffic networks due to the high nonlinearity and complexity of the massive traffic flow data. Most existing methods usually conduct two separate components to capture the spatial and temporal correlations. A static spatial graph is constructed for each time step in the spatial dimension; furthermore, the same nodes on different time steps are connected to build a spatio-temporal graph in the temporal dimension. However, the potential correlations between the traffic flow data of different nodes at different time steps are ignored and the complex spatio-temporal correlations in the traffic flow data cannot be effectively modeled. [Methods] In this paper, we proposed a spatio-temporal combinational graph convolutional network (STCGCN) to address the issue of traffic flow prediction. STCGCN consisted of three modules: the spatio-temporal combinational graphs (STCG) construction module, the spatio-temporal combinational graph convolution (STCGC) module, and the prediction module. The STCG construction module constructed an adaptive STCG adjacency matrix across temporal slices based on spatio-temporal embedding vectors, which could automatically learn parameters during training, accommodate complex spatio-temporal correlations between nodes, and solve the problem that existing prediction methods hardly captured the potential spatio-temporal correlation between nodes. The STCGC module designed adaptive STCGC operators and adaptive STCGC layers to extract spatio-temporal features from historical traffic data of nodes and the constructed adaptive STCG. Finally, the prediction module aggregated the hidden layer representation of all historical time steps obtained using the STCGC module and outputted the prediction result via fully connected layer mapping. We evaluated STCGCN on PeMSD4 and PeMSD8, two public datasets from Caltrans performance measurement system (PeMS), by comparing it with 11 baseline methods: vector autoregressive (VAR), support vector regression (SVR), fully connected long-short term memory (FC-LSTM) neural network, diffusion convolutional recurrent neural network (DCRNN), spatio-temporal graph convolutional networks (STGCN), attention based spatial-temporal graph convolutional networks (ASTGCN), Graph WaveNet, spatial-temporal synchronous graph convolutional networks (STSGCN), adaptive graph convolutional recurrent network (AGCRN), graph multi-attention network (GMAN), and time zigzags at graph convolutional networks (Z-GCNets). We adopted two widely used metrics for evaluation: mean absolute error and root mean squared error. [Results] The experimental results revealed that using a unified component, the proposed STCGCN model effectively modeled the dynamic temporal correlation, spatial correlation, and cross-spatio-temporal correlation in the traffic flow data. Furthermore, the model achieved the best prediction results at each moment, and its error growth was slower than other baseline methods as the prediction time increased. We also explored the effect of three hyperparameter settings in STCGCN on model performance, and the experiments demonstrated differential model performance under different hyperparameter settings. The number of parameters and training times of all models, including STCGCN and 11 baseline methods, were compared at the end of the experiment. The results showed that the STCGCN achieved the best model performance with the least number of model parameters and training time, and the algorithm efficiency was close to the best. [Conclusions] Experiments on the public datasets show that the STCGCN model outperforms 11 baseline methods in prediction accuracy.

Key words: traffic flow prediction; spatio-temporal data mining; graph convolutional networks; big data fusion and analysis