

## 基于图自编码器和GRU网络的分层交通流预测模型

赵子琪, 杨斌, 张远广

引用本文

赵子琪, 杨斌, 张远广. 基于图自编码器和GRU网络的分层交通流预测模型[J]. 计算机科学, 2024, 51(6A): 230400148-6.

ZHAO Ziqi, YANG Bin, ZHANG Yuanguang. Hierarchical Traffic Flow Prediction Model Based on Graph Autoencoder and GRU Network [J]. Computer Science, 2024, 51(6A): 230400148-6.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[ST-WaveMLP:面向交通流量预测的时空全局感知网络模型](#)

ST-WaveMLP:Spatio-Temporal Global-aware Network for Traffic Flow Prediction  
计算机科学, 2024, 51(5): 27-34. <https://doi.org/10.11896/jsjcx.230100086>

[面向能源感知的虚拟机深度强化学习调度算法研究](#)

Study on Deep Reinforcement Learning for Energy-aware Virtual Machine Scheduling  
计算机科学, 2024, 51(2): 293-299. <https://doi.org/10.11896/jsjcx.230100031>

[基于互信息优化的Option-Critic算法](#)

Option-Critic Algorithm Based on Mutual Information Optimization  
计算机科学, 2024, 51(2): 252-258. <https://doi.org/10.11896/jsjcx.221100019>

[基于轨迹信息量的分层强化学习方法](#)

Hierarchical Reinforcement Learning Method Based on Trajectory Information  
计算机科学, 2023, 50(12): 314-321. <https://doi.org/10.11896/jsjcx.221100096>

[融合门控循环单元及自注意力机制的生成对抗语音增强](#)

Speech Enhancement Based on Generative Adversarial Networks with Gated Recurrent Units and Self-attention Mechanisms  
计算机科学, 2023, 50(11A): 230200203-9. <https://doi.org/10.11896/jsjcx.230200203>

# 基于图自编码器和 GRU 网络的分层交通流预测模型

赵子琪 杨斌 张远广

南华大学电气工程学院 湖南 衡阳 421001

(ztq9885@163.com)

**摘要** 准确的交通流预测信息不仅可以为交通管理人员提供交通决策的坚实基础,还可以减少交通拥堵情况。在交通流预测任务中,获得有效的交通流的时空特性是保证预测效果的前提。现有的方法大多是用未来时刻的数据进行监督学习,提取的特征具有局限性。针对现有预测模型无法充分挖掘交通流的时空特性的问题,提出了基于改进的图自编码器和门控循环单元的分层交通流预测模型。首先使用图注意力自编码器以无监督的方式深度挖掘交通流的空间特性,然后使用门控循环单元进行时间特征提取。分层结构采用分开训练的方式进行时空依赖关系的学习,旨在获取路网天然存在的空间拓扑特征,使其可以兼容不同时间步下的交通流预测任务。大量实验证明,所提出的 GAE-GRU 模型在不同数据集下的交通预测任务中取得了优异的表现,MAE, RMSE 和 MAPE 指标均优于基线模型。

**关键词:** 交通流预测;图自编码器;门控循环单元;分层;时空依赖

**中图分类号** TP391

## Hierarchical Traffic Flow Prediction Model Based on Graph Autoencoder and GRU Network

ZHAO Ziqi, YANG Bin and ZHANG Yuanguang

School of Electrical Engineering, University of South China, Hengyang, Hunan 421001, China

**Abstract** Accurate traffic flow prediction information not only provides traffic administrator with a strong foundation for traffic decisions, but also eases congestion. In traffic flow forecasting tasks, obtaining valid spatiotemporal characteristics of the traffic flow is a prerequisite to ensure the effectiveness of the forecast. Most of the existing methods use data from future moments for supervised learning, and the extracted features have limitations. To address the problem that existing prediction models cannot fully exploit the spatiotemporal characteristics of traffic flows, this paper proposes a hierarchical traffic prediction model based on an improved graph autoencoder and gated recurrent unit. The graph attention autoencoder is first used to deeply explore the spatial characteristics of the traffic flow in an unsupervised manner, and then the gated recurrent unit is used to extract temporal features. The hierarchical structure uses separate training for learning spatio-temporal dependencies, aiming to capture the naturally existing spatial topological features of the road network and make it compatible with traffic flow prediction tasks at different time steps. Extensive experiments demonstrate that the proposed GAE-GRU model achieves excellent performance in traffic prediction tasks on different datasets, with MAE, RMSE and MAPE outperforming the baseline model.

**Keywords** Traffic flow forecasting, Graph autoencoder, Gated recurrent neural unit, Hierarchical, Spatiotemporal dependencies

### 1 引言

近几十年来,交通基础设施的发展取得了巨大进步,然而城市存在的交通拥堵、空气污染以及交通事故等问题直接影响着人们的生活。智能交通系统结合物联网和人工智能算法,极大地改善了交通环境。其中,交通流预测模型能够利用历史时刻的交通流数据对未来时刻的交通信息进行预测,有助于缓解交通拥堵,对城市的可持续性发展有着重大意义<sup>[1]</sup>。

由于交通流数据十分复杂,在时空这两个维度上都表现出了丰富的特性,因此充分挖掘交通流的时空特征来提高预测性能仍然是一个悬而未决的问题。目前在交通流特征提取过程中的热点问题就是如何充分利用隐藏在交通大数据中的

潜在信息来预测交通流量。现有深度学习方法多是针对某一预测任务,通过端到端的训练方式获取交通流时空特性,使得模型无法深度挖掘数据本身的时间和空间特征。在现实世界中,往往希望交通流预测模型能够在不同时间步下的预测任务中都取得较好的表现,具有较强的泛化能力。

针对上述问题,本文提出了一种分层交通流预测模型,旨在最大程度地分别提取交通流本身存在的时间和空间特性。首先将路网的拓扑结构抽象为无向图形式,然后使用改进的图自编码器提取复杂路网的空间特性,以无监督的方式进行空间特征提取,尽可能保留原始数据的重要信息。空间特征提取能够将原始数据嵌入至较低维度,在保留空间信息的同时还能够提高算法效率。然后将低维向量作为时间特征

基金项目:国家自然科学基金(61871210)

This work was supported by the National Natural Science Foundation of China(61871210).

通信作者:杨斌(yangbin01420@163.com)

提取单元输入,利用门控循环单元(Gated Recurrent Unit, GRU)获取交通流存在的时间依赖关系。本文将 GAE-GRU 模型在公开数据集 PeMS04 和 PeMS08 上进行了实验,分别测试其在不同时间步下的交通流预测任务中的表现,结果表明 GAE-GRU 的预测精度优于基线模型。

## 2 相关工作

现有的交通流预测技术主要包括参数化方法、机器学习和深度学习技术。早期的交通流预测任务基于参数化方法进行实现,如差分整合移动平均自回归模型(Autoregressive Integrated Moving Average model, ARIMA)<sup>[2]</sup>、卡尔曼滤波器<sup>[3]</sup>、回归模型<sup>[4]</sup>等。Emami 等结合联网车辆和配备了蓝牙设备的车辆所提供的信息,提出了一种基于自适应卡尔曼滤波技术用于交通流预测<sup>[5]</sup>。Hou 等将非线性小波神经网络和 ARIMA 模型进行结合,用于交通流预测。该框架中两个模型的输出基于模糊逻辑进行结合,将加权结果作为最终预测值,取得了准确可靠的预测结果<sup>[6]</sup>。统计方法模型虽然结构简单,计算成本低,能够拟合一定程度下的交通变化规律,但是静态交通流预测无法应对非常规的交通状况,导致预测精度受到了很大限制;并且,统计学模型对基于先验知识设置的模型参数有很强的依赖,无法应对扰动较大的交通流数据。

与传统技术相比,数据驱动的方法能够有效地提取非线性特征。机器学习具有非线性和随机性的特性,能够提取交通流的非线性特征以及各种动态和静态因素,进而提高了交通流预测的精度。Lin 等提出了一种基于最大信息系数的空间时延交通序列筛选方法,将选择的时延交通序列转换为交通状态向量,并结合支持向量回归和 K 近邻方法进行交通流预测,极大地降低了预测误差<sup>[7]</sup>。Feng 等提出了一种新的基于具有时空相关性的多核 SVM 算法,将其应用于短期交通流预测。该方法将高斯核和多项式核融合形成了自适应多核支持向量机,并且使用自适应粒子群算法来优化模型中的参数,使得混合核的权值能够随着交通流时空相关性的变换而不断进行调整。最后,融合时空依赖特性以及自适应多核支持向量机对短时交通流进行预测。该算法在交通状况快速变化的高峰时段可以进行及时和自适应的预测<sup>[8]</sup>。Liu 等提出了特定的机器学习方法,分别过滤手机定位(Cellphone Location, CL)的数据和提取特定路段的时空交通特征。首先,通过过滤的 CL 数据、提取的时空交通特征以及车牌识别数据来预测单条链路上的交通流量;然后,利用道路的空间特征和相关区域的信息来预测各路段上的交通信息。实验表明这一方法同时保持了高覆盖率和高精度<sup>[9]</sup>。机器学习模型虽然能够从复杂的交通流数据中学习交通变化规律,但是在挖掘交通流时空特性时表现较差,一般只能学习到数据的时间依赖关系,对空间依赖关系的学习性能欠缺。机器学习模型的隐藏层数较少,难以提取高维复杂的交通流特征。

深度学习是机器学习的一个重要分支,在高维数据挖掘任务中有优异的表现,使得许多优秀的模型被应用于预测任务,如卷积神经网络<sup>[10]</sup>、长短期记忆网络(Long Short-Term Memory, LSTM)<sup>[11]</sup>、自编码器<sup>[12]</sup>、图卷积网络(Graph Convolutional Network, GCN)<sup>[13]</sup>等。基于卷积神经网络在特征提取中的优异表现, Zheng 等在卷积神经网络和长短期记忆

网络的基础上提出了基于注意的 Conv-LSTM 模块,用于提取交通流的时空特征<sup>[14]</sup>。Guo 等同时考虑了交通流的时空特性和异质性,通过引入三维卷积,提出了一种端到端的深度学习模型(ST-3DNet),其能够自动捕捉交通流的时空相关性<sup>[15]</sup>。Ma 等使用混合时空特征选择算法(Spatial-Temporal Feature Selection Algorithm, STFS)基于时间连续性和空间特征重构交通速度的时空矩阵,然后利用卷积神经网络的非线性拟合能力,从卷积层和池化层中提取深度特征用于模型训练,最后将捕获数据的定时和长程相关性与正向 GRU 和反向 GRU 融合,进一步提高了预测结果的准确性<sup>[16]</sup>。由于实际的传感器节点是不规则地分布在路网中的,呈现非欧几里得结构,许多研究人员开始将图卷积网络引入交通流预测任务中<sup>[17]</sup>。Zhao 等提出了一种基于神经网络的时间图卷积模型,结合 GCN 与 GRU 分别捕获空间相关性和时间相关性<sup>[18]</sup>。Huang 等设计了一个多模式动态图卷积模块,通过学习两种类型的关系矩阵来捕捉不同交通模式的影响;然后设计了多模式动态图卷积门控递归单元,实现空间和时间相关性的组合;最后使用动态残差模块来整合时空特征,用于交通流预测任务<sup>[19]</sup>。Peng 等提出了一种时空关联动态图神经网络方法,并将其用于城市交通客流预测。首先基于历史交通客流将随时间变化的动态交通站点关系建模为时空关联动态图结构,然后设计了一种新的动态递归图卷积网络,以学习城市交通网络拓扑结构和交通枢纽的时空特征表示。实验结果表明该模型能够有效捕捉时空相关性<sup>[20]</sup>。然而交通流具有复杂的时空特性,如何深入挖掘交通数据潜在的信息是一个值得研究的问题。

## 3 方法

### 3.1 问题描述

交通流预测任务是利用历史时刻的数据去预测未来时刻的交通流信息,表示如下:

$$[X_t, \dots, X_{t+T}] = f(X_{t-m}, \dots, X_{t-1}) \quad (1)$$

其中,  $m$  为历史时间戳的长度,  $T$  为预测的未来时间戳的长度。

交通流的变化受路网的空间拓扑结构影响,不同阶的邻居道路对中心道路的影响程度也不同。本文将路网抽象为无向图  $G=(V, E)$ , 其中  $V$  是路网中部署的监测设备的节点集合,  $E$  是节点之间边的关系集。分别用  $X$  和  $A$  表示节点的特征矩阵和路网的邻接矩阵,这里的特征可以是道路上的速度、流量或密度等。  $X \in R^{N \times D}$ , 其中  $N$  为节点的数量,  $D$  为交通流特征的维度。空间特征提取旨在学习一个映射:  $Z=f(X, A)$ ,  $Z=\{\vec{Z}_1, \vec{Z}_2, \dots, \vec{Z}_N\}$  为经过编码器压缩后的节点的低维表示,  $Z \in R^{N \times d}$ ,  $d$  为压缩后的节点特征维度,压缩后的低维节点特征  $Z$  可以进一步用于交通流时间特征的学习。

### 3.2 空间特征提取单元

自编码器模型能够降低输入数据的维度和计算复杂度,同时可以学习有效的低维嵌入表示,保留有意义的特征。本文使用改进的图自编码器(Graph Autoencoder, GAE)进行交通流的空间特征提取。GAE 的目的是将图的特征提取为一个低维向量,将其应用至下游任务。GAE 使用 GCN 网络作为编码器,能够在保留路网的空间拓扑特性的同时,提高时序

预测任务的效率。

现实世界中,城市道路的交通流状态受附近区域的多条道路的影响,现选取长沙市的部分区域道路为例进行说明。如图1所示,对于中心道路①而言,道路②为①的直接相邻道路,③和④为①的高阶邻居,虽然相邻程度不同,但是②③④的交通情况均会对①有一定的影响。考虑邻居节点对中心节点的影响,本文对图自编码器进行了改进,通过加入节点间共享参数的自注意力机制,基于节点的相关性来对节点进行更新。在第 $k$ 层编码器中,通过式(2)来计算中心节点 $i$ 和邻居节点 $j$ 之间的相关性。

$$v_{ij}^{(k)} = \text{Sigmoid}(V_s^{(k)\top} \sigma(W^{(k)} z_i^{(k-1)}) + V_r^{(k)\top} \sigma(W^{(k)} z_j^{(k-1)})) \quad (2)$$

其中, $V_s^{(k)}$ , $V_r^{(k)}$ 和 $W^{(k)}$ 为第 $k$ 层编码器的可训练参数, $\sigma$ 为激活函数。然后使用Softmax函数对其进行式(3)所示的归一化操作。

$$\alpha_{ij}^{(k)} = \frac{\exp(v_{ij}^{(k)})}{\sum_{l \in \mathcal{N}_i} \exp(v_{il}^{(k)})} \quad (3)$$

其中, $\mathcal{N}_i$ 是中心节点 $i$ 的邻居节点的集合。

然后聚合邻居节点的信息,对中心节点的信息进行更新。

$$z_i^{(k)} = \sum_{j \in \mathcal{N}_i} \alpha_{ij}^{(k)} \sigma(W^{(k)} z_j^{(k-1)}) \quad (4)$$

其中,初始节点的表示即网络的输入节点特征,亦即 $z_i^{(0)} = x_i$ ,最后一层编码层的输出 $z$ 即空间特征提取单元获取的节点嵌入表示,通过多层编码器能够融合高阶邻居节点对中心节点的影响。

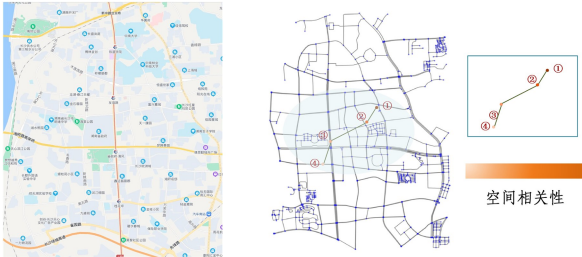


图1 空间拓扑示意图

Fig. 1 Spatial topology diagram

为了深度挖掘交通流的空间拓扑结构,获得有效的低维节点表示,对GAE模块的解码器部分进行了改进,将内积解码器替换为与编码操作相反的解码器。解码器部分基于邻居节点的相关性,使用与编码层数量相同的解码层,获得中心节点的重构表示。通过式(5)和式(6)来计算第 $k$ 层解码层中心节点和邻居节点之间的相关性。

$$\hat{v}_{ij}^{(k)} = \text{Sigmoid}(\hat{V}_s^{(k)\top} \sigma(\hat{W}^{(k)} \hat{z}_i^{(k)}) + \hat{V}_r^{(k)\top} \sigma(\hat{W}^{(k)} \hat{z}_j^{(k)})) \quad (5)$$

$$\hat{\alpha}_{ij}^{(k)} = \frac{\exp(\hat{v}_{ij}^{(k)})}{\sum_{l \in \mathcal{N}_i} \exp(\hat{v}_{il}^{(k)})} \quad (6)$$

其中, $\hat{V}_s^{(k)}$ , $\hat{V}_r^{(k)}$ , $\hat{W}^{(k)}$ 为第 $k$ 层解码器中的可训练参数。第 $k-1$ 层解码器的重构节点表示如式(7)所示:

$$\hat{z}_i^{(k-1)} = \sum_{j \in \mathcal{N}_i} \hat{\alpha}_{ij}^{(k)} \sigma(\hat{W}^{(k)} \hat{z}_j^{(k)}) \quad (7)$$

其中,第一层解码器的输入为编码器的最终输出,最后一层解码器的输出即为重构后的节点表示。

图自编码器使用内积解码器对嵌入向量进行解码,目的是重构邻接矩阵。然而仅重构邻接矩阵会使得编码过程中丢

失节点的特征信息,无法完全学习到节点本身的特征。因此,改进的GAE单元的损失函数由两部分组成,分别重建节点特征和路网的拓扑结构,如式(8)所示。

$$L_s = \sum_{i=1}^N \|x_i - \hat{v}_i\|^2 - \lambda \sum_{j \in \mathcal{N}_i} \log\left(\frac{1}{1 + \exp(-v_i^\top v_j)}\right) \quad (8)$$

其中, $\lambda$ 是超参数,用来平衡图结构重建损失的贡献; $x_i$ 和 $\hat{v}_i$ 分别为节点的特征和重构节点的特征,通过最小化损失函数 $L_s$ 来训练GAE单元,即可获取保留了路网空间结构的高质量节点表示。

GAE单元在使用大量的历史数据进行预训练之后才能够作为空间特征提取器,预训练的过程即重构误差最小化的过程。在训练时,首先初始化编解码器的网络权重,然后使用梯度下降和误差反向传播进行权重训练。本文在进行空间特征提取时并未基于下游预测任务进行端到端的特征提取,而是通过改进的图自编码器获得路网本身的空间特征,具有更强的兼容性。通过历史数据对图自编码器单元进行预训练,然后冻结参数,将编码器部分作为空间特征提取器。

### 3.3 时间特征提取单元

交通流信息在每周、日及每天的不同时间段呈现出一定的规律,因此需要考虑交通流的时间特性。GRU网络<sup>[21]</sup>相比LSTM缺少了输出门,参数量小、学习速度快但性能相近,因此本文选择GRU模块对交通流的时间特征进行提取。

GRU模块包括更新门和重置门。重置门用来对需要记住的历史状态量进行控制,更新门控制有多少新状态是历史状态的保留。更新门和重置门决定了向输出传递什么信息,并且能够保留历史信息,计算方式如式(9)和式(10)所示。

$$z_t = \sigma(Z_t W_{z_z} + h_{t-1} W_{z_h} + b_z) \quad (9)$$

$$r_t = \sigma(Z_t W_{r_r} + h_{t-1} W_{r_h} + b_r) \quad (10)$$

其中, $z_t$ 为 $t$ 时刻输入的保留空间结构的低维特征, $W_{z_r}$ , $W_{z_z} \in \mathbb{R}^{d \times h}$ , $W_{r_r}$ , $W_{r_h} \in \mathbb{R}^{h \times h}$ 均为权重参数, $b_z$ , $b_r$ 为偏置参数, $d$ 和 $h$ 分别是输入的大小和隐藏单元的数量, $h_{t-1}$ 保存了先前 $t-1$ 时刻的信息, $\sigma$ 为激活函数。

GRU引入了一种新的候选隐藏内容,使用重置门来存储相关的历史信息,计算方式如式(11)所示。

$$g_t = \tanh(Z_t W_{g_z} + (r_t * h_{t-1}) W_{g_h} + b_g) \quad (11)$$

其中, $W_{g_z} \in \mathbb{R}^{d \times h}$ , $W_{g_h} \in \mathbb{R}^{h \times h}$ 为权重参数, $b_g \in \mathbb{R}^{1 \times h}$ 为偏置参数。

最后需要考虑更新门 $z_t$ 的影响,这决定了新的隐藏状态 $h_t$ 和历史状态 $h_{t-1}$ 的匹配程度以及 $h_t$ 和候选状态 $g_t$ 的相似程度,最终的更新方式如式(12)所示。

$$h_t = z_t * h_{t-1} + (1 - z_t) * g_t \quad (12)$$

GRU网络的重置门能够捕获时间序列中的短期依赖关系,更新门有助于捕获序列中的长期依赖关系。预测任务的目的是使得预测值尽可能接近真实值,因此时间特征提取模块的训练是使得预测值和真实值之间的预测误差最小化。

$$L_t = \|y_t - \hat{y}_t\| \quad (13)$$

其中, $y_t$ 和 $\hat{y}_t$ 分别为真实值和预测值。

GAE-GRU单元的分层交通流预测模型,旨在最大程度地提取路网天然存在的空间拓扑特性和时间依赖关系,整体

框架如图 2 所示。

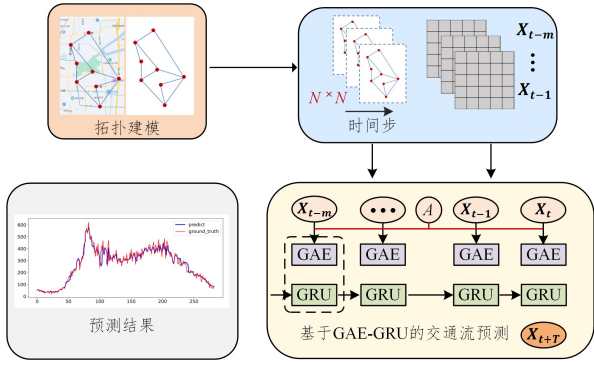


图 2 GAE-GRU 分层模型结构图

Fig. 2 Structural diagram of GAE-GRU hierarchical model

## 4 实验分析

### 4.1 数据集和基线模型

为了验证 GAE-GRU 模型在交通流预测任务中的性能, 本文使用了 PeMSD4 和 PeMSD8 两个数据集进行了实验。

(1)PeMSD4. PeMSD4 来自旧金山 29 条道路上的 3848 个传感器, 时间跨度为 2018 年 1 月至 2 月 28 日, 共 59 天。

(2)PeMSD8. PeMSD8 来自圣贝纳迪诺地区 8 条道路上的 1979 个传感器, 时间跨度为 2016 年 7 月 1 日至 8 月

31 日, 共 62 天。

为了分析本文所提出模型的性能, 选择 HA, ARIMA, GCN, LSTM, SVR, DCRNN, ASTGCN 模型为基线模型进行对比。

### 4.2 评估指标

本文使用了平均绝对误差 (MAE)、均方根误差 (RMSE) 和平均绝对百分比误差 (MAPE) 3 个评价指标来衡量 GAE-GRU 模型的性能。

$$MAE = \frac{1}{n} \sum_{t=1}^n |\hat{Y}_t - Y_t| \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2} \quad (15)$$

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{\hat{Y}_t - Y_t}{Y_t} \right| \quad (16)$$

### 4.3 实验结果分析

在实验过程中, 分别使用本文提出的 GAE-GRU 模型和 7 个基线模型对未来时刻的交通流信息进行了预测, 预测时间为 15 min, 30 min, 60 min。表 1 和表 2 分别为本文模型和基线模型在 PeMS04 和 PeMS08 两个数据集上的表现。从表中可以看出, GAE-GRU 模型在不同时间长度的预测任务中的 3 个评价指标的表现均优于基线模型, 充分说明了 GAE-GRU 模型的有效性和良好的泛化能力。

表 1 GAE-GRU 模型和基线模型在 PeMS04 数据集上的预测结果

Table 1 Prediction results of GAE-GRU model and the baseline models on PeMS04

模型	15 min			30 min			60 min		
	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%
HA	38.91	56.44	22.94	41.57	58.92	25.65	46.24	63.48	29.72
ARIMA	33.09	61.28	21.47	38.44	63.40	24.84	45.81	65.91	29.38
GCN	29.85	42.87	20.16	33.29	45.87	23.56	36.39	49.38	28.98
LSTM	28.72	38.61	19.83	30.18	40.95	22.85	34.85	44.60	26.02
SVR	29.79	41.73	20.75	32.64	44.69	23.53	36.56	49.96	27.41
DCRNN	23.54	37.57	18.97	25.18	38.06	20.06	28.96	41.02	23.28
ASTGCN	22.75	35.92	16.93	24.93	37.04	18.02	27.02	39.15	21.08
GAE-GRU	<b>20.06</b>	<b>31.58</b>	<b>13.81</b>	<b>21.89</b>	<b>33.32</b>	<b>15.05</b>	<b>24.81</b>	<b>36.62</b>	<b>17.13</b>

表 2 GAE-GRU 模型和基线模型在 PeMS08 数据集上的预测结果

Table 2 Prediction results of GAE-GRU model and the baseline models on PeMS08

模型	15 min			30 min			60 min		
	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%
HA	30.47	42.85	17.59	33.79	46.93	19.44	38.71	55.85	25.91
ARIMA	28.96	41.57	17.36	32.83	44.79	18.17	37.59	52.20	24.88
GCN	26.68	36.92	16.79	30.94	40.57	18.04	37.02	47.94	22.46
LSTM	23.97	30.91	15.75	27.68	35.18	17.94	36.78	41.74	21.96
SVR	25.40	33.78	16.26	29.18	37.27	18.18	37.51	42.66	22.17
DCRNN	17.85	28.72	12.77	20.15	30.29	14.28	22.30	32.78	16.79
ASTGCN	18.83	29.21	13.57	21.04	31.04	14.96	23.74	33.18	17.33
GAE-GRU	<b>12.89</b>	<b>23.39</b>	<b>10.82</b>	<b>14.92</b>	<b>25.70</b>	<b>11.65</b>	<b>17.63</b>	<b>28.97</b>	<b>13.68</b>

由表 1 和表 2 分析可知, GAE-GRU 模型在不同时间步的交通流预测任务中均有较好的预测性能。ARIMA 和 HA 这类基于统计理论的模型为线性模型, 很难处理时间步较长且非平稳的数据流, 且只考虑了时间维度的特征, 忽略了空间相关性。HA 模型基于历史信息的平均值进行预测, 完全忽略了交通流的非线性和非平稳性。GRU, LSTM 和 SVR 虽然具有较好的非线性映射能力, 但是由于只考虑了时间特性, 并未考虑路网的空间拓扑特征, 因此并没有最优的预测效果。这说明传统时间序列预测技术仅在简单的预测任务中具有较好的表现, 而对于具有复杂时空特性的交通流预测任务则效果不佳。GCN, ASTGCN, DCRNN 等深度学习模型的预测

效果虽优于传统预测技术, 且 DCRNN 和 ASTGCN 模型也都考虑了交通流的时空特性, 但是由于其基于特定时间步的端到端训练方式, 未能深度挖掘交通流本身存在的空间特征, 所以效果略低于 GAE-GRU 模型, 尤其随着时间步的增加, 预测性能下降十分明显。

图 3 和图 4 是从 PeMS04 和 PeMS08 两个数据集中选出的某一日交通数据中不同模型的预测曲线, 可以看出 HA, ARIMA 和 SVR 的预测效果相较于其他模型表现较差。LSTM, GCN, DCRNN, ASTGCN, GAE-GRU 模型均能学习到一天内的交通变化规律, 但是 GAE-GRU 模型的预测误差较小, 其具有更高的预测精度。这说明 GAE-GRU 模型在特

征挖掘方面优于其他模型,能够学习到更多交通流潜在的特征。同时,因为交通流偶尔会因交通事故、天气等因素导致传感器感知到不常见的数据,而这些数据的特征对于深度学习模型可能会产生干扰。自编码器网络由于具有特征重构的作用,在进行特征学习时能够忽略不重要的信息或一些噪声信息,因此能够很好地处理干扰信号。




图3 多模型在PeMS04数据集上的预测曲线

Fig. 3 Prediction curves of multiple models on PeMS04 dataset





图4 多模型在PeMS08数据集上的预测曲线

Fig. 4 Prediction curves of multiple models on PeMS08 dataset


为了直观展示 GAE-GRU 在不同时间步下的交通流预测表现,图5和图6分别展示了 GAE-GRU 模型在 PeMS04 和 PeMS08 数据集上的预测效果。可以看出,GAE-GRU 的预测结果可以很好地贴合真实的交通数据。对于预测值和真实值之间的误差是必然的,因为每天都会有一些无规律的出行情况,如临时出行行为。但是 GAE-GRU 模型对高峰时段的预测较为精确,其原因在于 GCN 卷积层在 Fourier 域内定义了一个平滑滤波器,能够在 Fourier 域内不断移动,从而捕捉空间特征,这可以使峰值更平滑,对于实际的交通管理有很重要的意义。



注:预测时间分别为 15 min,30 min,60 min

图5 不同时间步下 PeMS04 数据集上的表现

Fig. 5 Performance on PeMS04 dataset at different time steps



注:分别在 15 min,30 min,60 min 下进行预测

图6 不同时间步下 PeMS08 数据集上的表现

Fig. 6 Performance on PeMS04 dataset at different time steps

在分层模型中,空间特征提取器主要通过图卷积层对路网进行空间拓扑特性的学习。图7展示了不同卷积层数对预测性能的影响。




图7 GCN 层数对预测性能的影响

Fig. 7 Impact of the number of GCN layers on prediction performance

从图7可以看出,GAE-GRU 模型在两个数据集上均在层数为3时取得了最佳预测性能。这是因为多层 GCN 虽然能够融合更高阶的邻居节点的信息,但是由于 GCN 模型一般为浅层模型,当堆叠较多的图卷积层时,会出现过平滑现象,因此不仅无法获取更多的空间信息,还会使模型预测的性能降低<sup>[22]</sup>。

**结束语** 本文针对交通流特征挖掘不充分、对于不同时间步交通流预测任务的通用性差的问题,提出了基于分层特征提取的交通流预测模型 GAE-GRU。一方面通过改进的图自编码器对交通流的空间特征进行提取,另一方面基于 GRU 网络对时间依赖关系进行学习。本文在 PeMS04, PeMS08 这两个公开数据集上进行了分析,结果表明 GAE-GRU 模型的预测结果在多项评估指标上均优于基线模型。

分层特征提取的思想不同于以某一预测任务为导向的端到端的监督训练模型,分层结构能更多地提取路网本身的空间特征结构和时间序列特征,将这些特征用于不同时间步的交通流预测任务,均能取得优异的表现。后续将进一步分析现实世界中天气、不同交通因素对交通流预测任务的影响,并考虑交通流的动态性,强化模型的实用性和动态适应能力。

## 参考文献

- [1] MEDINA-SALGADO B, SANCHEZ-DELACRUZ E, POZOS-PARRA P, et al. Urban traffic flow prediction techniques: A review [J]. *Sustainable Computing: Informatics and Systems*, 2022, 35: 100739.
- [2] 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.
- [3] OKUTANI I, STEPHANEDES Y J. Dynamic prediction of traffic volume through Kalman filtering theory [J]. *Transportation Research Part B: Methodological*, 1984, 18(1): 1-11.
- [4] SMITH B L, WILLIAMS B M, OSWALD R K. Comparison of parametric and nonparametric models for traffic flow forecasting [J]. *Transportation Research Part C: Emerging Technologies*, 2002, 10(4): 303-321.
- [5] EMAMI A, SARVI M, BAGLOEE S A. Short-term traffic flow prediction based on faded memory Kalman Filter fusing data from connected vehicles and Bluetooth sensors [J]. *Simulation Modelling Practice and Theory*, 2020, 102: 102025.
- [6] HOU Q, LENG J, MA G, et al. An adaptive hybrid model for short-term urban traffic flow prediction [J]. *Physica A: Statistical Mechanics and its Applications*, 2019, 527: 121065.
- [7] LIN G, LIN A, GU D. Using support vector regression and K-nearest neighbors for short-term traffic flow prediction based on maximal information coefficient [J]. *Information Sciences*, 2022, 608: 517-531.
- [8] FENG X, LING X, ZHENG H, et al. Adaptive multi-kernel SVM with spatial-temporal correlation for short-term traffic flow prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 20(6): 2001-2013.
- [9] LIU Z, LIU Y, MENG Q, et al. A tailored machine learning approach for urban transport network flow estimation [J]. *Transportation Research Part C: Emerging Technologies*, 2019, 108: 130-150.
- [10] ZHANG W, YU Y, QI Y, et al. Short-term traffic flow prediction based on spatio-temporal analysis and CNN deep learning [J]. *Transportmetrica A: Transport Science*, 2019, 15(2): 1688-1711.
- [11] MA C, DAI G, ZHOU J. Short-term traffic flow prediction for urban road sections based on time series analysis and LSTM\_BILSTM method [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 23(6): 5615-5624.
- [12] JIN X B, GONG W T, KONG J L, et al. PFVAE: a planar flow-based variational auto-encoder prediction model for time series data [J]. *Mathematics*, 2022, 10(4): 610.
- [13] CHEN Z, ZHAO B, WANG Y, et al. Multitask learning and GCN-based taxi demand prediction for a traffic road network [J]. *Sensors*, 2020, 20(13): 3776.
- [14] ZHENG H, LIN F, FENG X, et al. A hybrid deep learning model with attention-based conv-LSTM networks for short-term traffic flow prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 22(11): 6910-6920.
- [15] GUO S, LIN Y, LI S, et al. Deep spatial-temporal 3D convolutional neural networks for traffic data forecasting [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 20(10): 3913-3926.
- [16] MA C, ZHAO Y, DAI G, et al. A novel STFSA-CNN-GRU hybrid model for short-term traffic speed prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 24(4): 3728-3737.
- [17] BAO Y, HUANG J, SHEN Q, et al. Spatial-temporal complex graph convolution network for traffic flow prediction [J]. *Engineering Applications of Artificial Intelligence*, 2023, 121: 106044.
- [18] ZHAO L, SONG Y, ZHANG C, et al. T-gcn: A temporal graph convolutional network for traffic prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(9): 3848-3858.
- [19] HUANG X, YE Y, DING W, et al. Multi-mode dynamic residual graph convolution network for traffic flow prediction [J]. *Information Sciences*, 2022, 609: 548-564.
- [20] PENG H, WANG H, DU B, et al. Spatial temporal incidence dynamic graph neural networks for traffic flow forecasting [J]. *Information Sciences*, 2020, 521: 277-290.
- [21] RAJEH T M, LI T, LI C, et al. Modeling multi-regional temporal correlation with gated recurrent unit and multiple linear regression for urban traffic flow prediction [J]. *Knowledge-Based Systems*, 2023, 262: 110237.
- [22] LI Q, HAN Z, WU X M. Deeper insights into graph convolutional networks for semi-supervised learning [C] // *Proceedings of the AAAI Conference on Artificial Intelligence*, 2018, 32(1).



**ZHAO Ziqi**, born in 1998, postgraduate. His main research interests include traffic flow prediction and intelligent transportation.



**YANG Bin**, born in 1980, Ph.D supervisor. His main research interests include information fusion, pattern recognition, and image processing.