

基于两级筛选机制及深度学习组合模型 实现短时交通流预测

徐先峰¹, 杨凡¹, 刘状壮^{2†}, 李陇杰¹, 夏振¹

(1. 长安大学 电子与控制工程学院, 西安 710064; 2. 长安大学 公路学院, 西安 710064)

摘要: 准确实时的短时交通流预测对现代交通管理服务体系的构建至关重要. 为了充分挖掘并利用不同路段短时交通流交互作用而表现出的时空特性, 构建由自相关函数、互相关函数和KNN算法组成的两级筛选机制评估与目标路段的相关性优化路段组合, 实现空间信息深度挖掘; 提出一种GCN-GRU组合预测模型, 利用图卷积网络(GCN)全局处理路段拓扑信息的优势进一步捕捉短时交通流的空间特性, 并借助门控循环单元(GRU)对时间信息的长时记忆能力提取其时间特性. 利用实测高速公路短时交通流数据进行验证, 仿真结果表明, 采用两级筛选机制对路段进行有效筛选并引入深度学习组合模型, 预测性能明显改善, 优于堆栈式自编码网络(SAEs)和GRU等经典模型.

关键词: 智能交通; 预测精度; 两级筛选机制; 短时交通流; 图卷积网络; 门控循环单元

中图分类号: U491.1+4

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.0929

引用格式: 徐先峰, 杨凡, 刘状壮, 等. 基于两级筛选机制及深度学习组合模型实现短时交通流预测[J]. 控制与决策, 2023, 38(1): 84-92.

Combination model of short-term traffic flow prediction based on two-level screening mechanism

XU Xian-feng¹, YANG Fan¹, LIU Zhuang-zhuang^{2†}, LI Long-jie¹, XIA Zhen¹

(1. School of Electronics and Control Engineering, Chang'an University, Xi'an 710064, China; 2. School of Highway, Chang'an University, Xi'an 710064, China)

Abstract: Accurate and real-time short-term traffic flow prediction is critical for the construction of modern traffic management service systems. In order to fully exploit and utilize the spatial-temporal characteristics of traffic flow interaction in different road sections, a two-level screening mechanism composed of the autocorrelation functions, the cross-correlation functions and the KNN algorithm is constructed to evaluate the correlation between the target road section and optimize the combination of road sections, and realize deep mining of spatial information. One of the GCN-GRU combination forecasting model is proposed. The spatial characteristics of short-term traffic flow are captured by using the advantage of the graph convolutional network (GCN) in the global processing of section topology information, and the time characteristics are extracted by using the long-term memory ability of the gated recurrent unit (GRU) for time information, which are verified by the measured short-term traffic flow data of expressway. The results show that using the two-level screening mechanism to effectively screen the road sections and introducing a deep learning combination model, the prediction performance will be significantly improved, which is better than the commonly used models such as the stacked autoencoders network (SAEs) and the temporal convolutional network (TCN).

Keywords: intelligent transportation; prediction accuracy; two-level screening mechanism; short-term traffic prediction; graph convolutional network; gated recurrent unit

0 引言

近年来,智能交通系统(intelligent transportation system, ITS)^[1]凭借先进的人工智能、计算机通信技

术等手段成为提高交通管理质量和解决交通拥堵等问题的有效途径. 短时交通流预测作为智能交通系统应用中的一项重要功能,能够为系统提供及时准确

收稿日期: 2021-05-25; 录用日期: 2021-09-22.

基金项目: 中央高校基本科研业务费专项资金项目(300102321504, 300102321501, 300102321503); 西安市智慧高速公路信息融合与控制重点实验室基金项目(ZD13CG46); 陕西省重点研发计划项目(2021GY-098).

责任编辑: 郭戈.

†通讯作者. E-mail: zzliu@chd.edu.cn.

的交通状态信息^[2].然而,各个路段短时交通流由于相互作用呈现出复杂的时空特性.因此,在高质量交通管理服务需求的背景下,探索能够有效挖掘短时交通流时空特性的方法成为智能交通领域的研究热点与难点.

从数据驱动的角度^[3],短时交通流预测模型大致分为统计模型、浅层机器学习模型和深度学习模型3类.自回归差分移动平均(autoregressive integrated moving average, ARIMA)模型^[4]、卡尔曼滤波^[5]是统计模型中的主要方法.然而这类模型在海量数据下的参数估计精度提升有限,无法应对如今短时交通流高度的时变性与复杂性.随着统计模型的不断改进,包括贝叶斯估计^[6]、支持向量回归(support vector regression, SVR)模型^[7]和随机森林模型^[8]等在浅层机器学习方法因其具备一定的泛化能力以及较低的维护成本而在短时交通流预测中显示出了良好的应用前景.但是,这类模型在特征提取与处理大规模数据方面存在着局限性,而深度学习模型凭借着对海量数据的适应能力和计算能力得到了更加广泛的应用.由传统的循环神经网络(recurrent neural network, RNN)发展起来的门控循环单元(gated recurrent unit, GRU)通过利用门控机制实现时间序列的长时记忆,并借助多序列向量^[9]和特征选择^[10]等不同策略在短时交通流预测中均表现良好.但是,由于未考虑短时交通流的空间特性,GRU无法从根本上提高预测精度.卷积神经网络(convolutional neural network, CNN)借助卷积与池化结构为短时交通流空间特征的提取提供了途径,文献[11]将CNN与GRU相结合,并采用交互式交通网络转换策略来学习交通流的时空相关性.文献[12]在相同方法下运用多模态注意力辅助策略来提高预测精度.然而CNN本质上适用于图像与规则网格,对于处理复杂拓扑结构的交通网络具有一定的局限性^[13].近年来,借助谱图论发展起来的图卷积网络(graph convolutional network, GCN)为上述问题提供了解决思路^[14].文献[15]应用高阶图卷积方法在一定程度上提高了模型的预测性能,但是对短时交通流时间特性的考虑不够充分,同时对目标路段影响较小的路段以及无关路段的筛选不够充分.对路段进行筛选的常见手段是 k -最近邻(k -nearest neighbor, KNN)算法,然而由于路网容易受到包括交通拥堵和交通事故等在内的多种因素影响,这些因素使得周围路段对目标预测路段的影响滞后,仅采用KNN算法无法处理这种滞后影响,导致预测效果不够理想^[16].总而言之,

目前的研究工作在短时交通流预测策略方法上不尽相同,但仍然存在对交通流时空特性挖掘不够深入的问题,同时还需要对最优路段组合筛选策略做进一步的探索.

本文首先利用自相关函数与互相关函数能够分析不同路段之间延迟的时空关系的优势^[17],提出一种由自相关函数、互相关函数与KNN算法构成的两级筛选机制来确定与目标路段相关性较强的最优路段组合;同时继承GCN全局处理路段拓扑信息的优点挖掘短时交通流的空间特性,并通过GRU对时间信息的长时记忆能力来提取其时间特性,搭建GCN-GRU组合预测模型以克服GRU无法考虑空间特性的缺点.实验结果表明,基于两级筛选机制的GCN-GRU组合预测模型对实际短时交通流数据拟合效果较好,具有较高的预测精度.

1 两级筛选机制

为了避免引入对目标路段影响较小的路段以及无关路段交通流,在进行短时交通流预测之前对路段进行有效筛选十分必要.针对KNN算法无法处理周围路段对目标预测路段的滞后影响,本文利用自相关函数与互相关函数处理不同路段之间延迟的时空关系,将满足函数条件的路段归入目标预测路段的空间邻域集,这是第1级筛选.然后,通过KNN算法对空间邻域集作进一步筛选,最终确定与目标路段相关性较强的最优路段组合.将经过筛选后的数据集整理成邻接矩阵与特征矩阵的形式并作为模型输入,用于后续的实验分析.

下面分别描述两级筛选机制中的自相关函数、互相关函数与KNN算法部分.

1.1 自相关函数

自相关函数用来度量目标预测路段的交通流序列及自身滞后序列之间的相关性,该函数中的滞后 $\varphi_a \in [0, 1, \dots, n]$ 反映了时间序列的延迟效应,其中一个滞后所代表的时间用 τ 表示.给定第 j 个路段 L_j 的交通流序列 $\{U_t^{L_j}\}$ 及其滞后序列 $\{U_{t-\varphi_a}^{L_j}\}$,对于各自序列中的交通流 u_t 和 $u_{t-\varphi_a}$,自相关函数 $\rho_{L_j}(\varphi_a)$ 定义如下:

$$\rho_{L_j}(\varphi_a) = \frac{\gamma_{u,u}}{\sigma_u^2}, \quad (1)$$

$$\gamma_{u,u} = E[(u_t - \mu_u)(u_{t-\varphi_a} - \mu_u)], \quad (2)$$

$$\sigma_u = \sqrt{\sum (u_t - \mu_u)^2}. \quad (3)$$

其中: $\gamma_{u,u}$ 表示序列 $\{U_t^{L_j}\}$ 与其滞后序列之间的协方差, μ_u 和 σ_u 分别表示交通流的均值与标准差.当自

相关函数为正时,滞后值 φ_a 定义如下:

$$\phi_{L_j} \leftarrow \{\varphi_a \mid \forall \rho_{L_j}(\varphi_a) > 0\}. \quad (4)$$

集合 ϕ_{L_j} 代表滞后值亦即时间窗口的取值范围,在该范围内目标路段交通流及其滞后交通流之间存在明显的相关性.接下来利用互相关函数和KNN算法筛选出不同时间窗口取值所对应的路段组合并作为模型输入,然后评估不同路段组合下模型的预测效果,使得预测效果最好时对应的的时间窗口即为模型的最优时间窗口.

1.2 互相关函数

在滞后 $\varphi_c \in [0, \pm 1, \dots, \pm n]$ 下,对于目标预测路段 L_j 的交通流序列 $\{U_t^{L_j}\}$ 与周围路段 L_v 的序列 $\{Z_t^{L_v} \mid v \in [1, \dots, j-1, j+1, \dots, N]\}$,各自序列中的交通流 u_t 和 $z_{t+\varphi_c}$ 在 φ_c 处的互相关函数定义如下:

$$\text{ccf}_{u,z}(\varphi_c) = \frac{\gamma_{u,z}(\varphi_c)}{\sigma_u \sigma_z}, \quad (5)$$

$$\gamma_{u,z}(\varphi_c) = E[(u_t - \mu_u)(z_{t+\varphi_c} - \mu_z)], \quad (6)$$

$$\sigma_u = \sqrt{\sum (u_t - \mu_u)^2}, \quad (7)$$

$$\sigma_z = \sqrt{\sum (z_{t+\varphi_c} - \mu_z)^2}. \quad (8)$$

其中: $\gamma_{u,z}(\varphi_c)$ 表示滞后 φ_c 下 $\{U_t^{L_j}\}$ 与 $\{Z_{t+\varphi_c}^{L_v}\}$ 的协方差, μ_u 和 μ_z 分别表示 $\{U_t^{L_j}\}$ 和 $\{Z_{t+\varphi_c}^{L_v}\}$ 的均值, σ_u 和 σ_z 为标准差.使得周围路段 L_v 与目标预测路段 L_j 的交通流互相关函数值最大化的滞后值 $\varphi_c^{L_v}$ 定义为

$$\varphi_c^{L_v} = \text{argmax}[\text{ccf}_{u,z}(\varphi_c^{L_v})]. \quad (9)$$

目标预测路段 L_j 的空间邻域集 R_{L_j} 定义为

$$R_{L_j} \leftarrow \{L_v \mid \forall 0 \leq |\varphi_c^{L_v}| \leq \varphi_a\}. \quad (10)$$

当滞后满足 $0 \leq |\varphi_c^{L_v}| \leq \varphi_a$,即使得互相关函数值最大化的滞后值不超过模型的时间窗口时,周围路

段与目标预测路段交通流之间的空间特性对于组合模型的预测结果才有意义,对应的路段将被纳入 R_{L_j} 用于进一步的筛选.

1.3 KNN算法

在空间邻域集的基础上,KNN算法通过计算不同路段交通流序列之间的距离来分析搜索相似的路段,从而优化交通流样本集.KNN算法中的一个关键步骤是合理地衡量状态空间中两个序列之间的相似性.作为一种最常用的距离度量方式,欧氏距离(euclidean distance)为各个交通流数据点赋予坐标,它们之间的差异通过直线距离得以体现.曼哈顿距离是通过计算两个序列中各个时刻交通流差值的绝对值,但是受量纲的影响很大,过大或过小的值都会对距离的计算产生影响;切比雪夫距离简单地将分别存在于两个样本序列中不同点之间的最大距离作为样本之间的距离,计算方法非常粗糙.相比之下,欧氏距离更适合用来衡量交通流序列之间的相似性.因此,本文使用欧氏距离来度量交通流数据之间的相似性.给定交通流样本序列 $x_j = (x_{j1}, x_{j2}, \dots, x_{jT})$ 和 $x_v = (x_{v1}, x_{v2}, \dots, x_{vT})$,欧氏距离定义如下:

$$\text{dist}_{ed}(x_j, x_v) = \sqrt{\sum_{t=1}^T |x_{jt} - x_{vt}|^2}. \quad (11)$$

2 短时交通流预测模型

2.1 GCN-GRU组合预测模型

本文提出的GCN-GRU组合预测模型的总体结构如图1所示.将经过两级筛选机制后的数据集整理成邻接矩阵 A 与特征矩阵 X 的形式,同时将其作为模型输入,图卷积层和门控循环单元层分别用来提取短时交通流的空间特性与时间特性,最后通过全连接层输出最终预测结果.

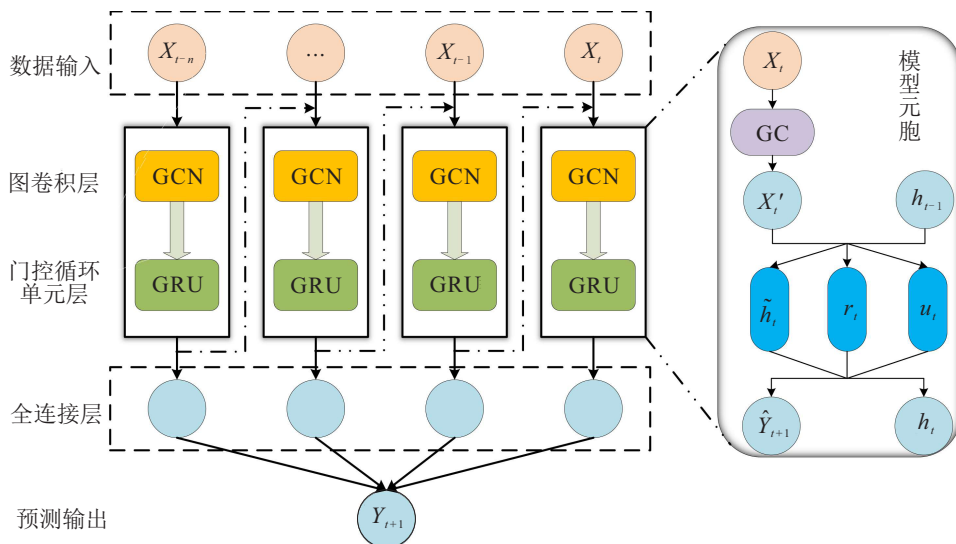


图1 GCN-GRU模型结构

模型元胞中的 h_{t-1} 表示 $t-1$ 时刻的输出, 组合模型中 GCN 的输出作为 GRU 的输入, u_t 和 r_t 分别表示在 t 时刻的更新门和重置门, \tilde{h}_t 是 h_t 的候选状态, h_t 表示 t 时刻的输出. 模型元胞计算过程如下所示:

$$u_t = \sigma\{W_u[f(X, A), h_{t-1}] + b_u\}, \quad (12)$$

$$r_t = \sigma\{W_r[f(X, A), h_{t-1}] + b_r\}, \quad (13)$$

$$\tilde{h}_t = \tanh\{W_c[f(X, A), (r_t \otimes h_{t-1})] + b_c\}, \quad (14)$$

$$h_t = u_t \otimes h_{t-1} + (1 - u_t) \otimes \tilde{h}_t. \quad (15)$$

其中: W_* 和 b_* 分别表示权重和偏差, $f(X, A)$ 表示图卷积过程, \otimes 表示两个向量之间进行逐元素相乘运算.

2.2 图卷积层

路网中各个路段通过节点的形式以拓扑结构呈现出来, 路段自身及不同路段交通流之间的交互作用形成图数据, 这意味着用于规则网络的卷积神经网络在处理这种复杂拓扑结构时存在着局限性. 而 GCN 可以从空间角度通过聚集和转换中心节点的邻域信息, 获得中心节点与其周围节点之间的拓扑关系. GCN 需要邻接矩阵 A 和特征矩阵 X 作为输入, 其

隐藏层可以表示为

$$H^l = f(H^{l-1}, A). \quad (16)$$

其中: $H^{(l)} \in R^{N \times D}$ 表示第 l 层的激活值, $H^0 = X$ 表示特征矩阵, $f(\cdot)$ 表示传播规则. 分层传播规则基本形式如下所示:

$$H^l = \sigma(AH^{l-1}W^{l-1}). \quad (17)$$

其中: $\sigma(\cdot)$ 为激活函数, W^{l-1} 为权重矩阵. 为了将节点自身特征包含其中, 在给定的邻接矩阵中加入单位矩阵 ($\tilde{A} = A + I$), 同时构造一个对角节点度矩阵 \tilde{D}_{ii} , 将邻接矩阵 \tilde{A} 的行值求和作为度矩阵的对角元素 ($\sum_j \tilde{A}_{ij}$). 然后通过计算对称归一化拉普拉斯算子 ($D^{-1/2}\tilde{A}D^{-1/2}$) 对邻接矩阵进行归一化, 以维持特征的原本分布. 传播规则的最终形式为

$$H^l = \sigma(D^{-1/2}\tilde{A}D^{-1/2}H^{l-1}W^{l-1}). \quad (18)$$

2.3 门控循环单元层

GRU 由传统循环神经网络发展而来, 通过引入门控机制进行遗忘与选择记忆^[18], 同时模型结构较为简洁、参数较少, 故使用 GRU 完成短时交通流时间特性的提取工作, 其模型结构如图 2 所示.




图 2 门控循环单元结构

h_{t-1} 为 $t-1$ 时刻的隐藏状态; x_t 为 t 时刻的交通信息; r_t 为重置门, 用于控制忽略前一时间步状态信息的程度以控制门控开启的大小; u_t 为更新门, 用于控制前一时间步状态信息进入当前状态的程度, $t-1$ 时刻的隐藏状态与 t 时刻的交通流信息都会经过线性变换, 激活函数通过更新门接收两个不同时刻信息并求和. 更新门帮助模型决定前一时间步与当前时间步有多少信息需要进一步向前传播, 从而降低梯度消失的风险; \tilde{h}_t 为 h_t 的候选状态, h_t 为 t 时刻的输出状态, 该变量保留当前单元的信息并传递到下一个单元中. 将待学习的参数分别表示为 W_* 、 U_* 和 b_* , GRU 的计算过程如下所示:

$$u_t = \sigma\{W_z x_t + U_z h_{t-1} + b_z\}, \quad (19)$$

$$r_t = \sigma\{W_r x_t + U_r h_{t-1} + b_r\}, \quad (20)$$

$$\tilde{h}_t = \tanh\{W_h x_t + U_h (r_t \otimes h_{t-1}) + b_h\}, \quad (21)$$

$$h_t = (1 - u_t) \otimes \tilde{h}_t + u_t \otimes h_{t-1}. \quad (22)$$

3 路段筛选

本文选用的数据集来自美国交通数据研究实验室 (transportation data research lab, TDRL)^[19], 包含了 TH10、TH610、I-35E、US169 等 19 条高速公路的短时交通流数据, 采样时间间隔为 15 min, 每个监测点每天有 $24 \times 4 = 96$ 条数据, 因此一个滞后所代表的时间 τ 为 15 min. 本文采用 TH77 号高速公路各个监测点从 2016-05-01 ~ 2016-09-30 总共 5 个月的数据, 经

过缺失数据修复、归一化等预处理^[20-21]后作为实验样本. 因为GCN和GRU能够分别有效地处理数据中蕴含的空间特征信息与时间特征信息,因此实验数据与GCN-GRU组合模型相匹配. 考虑到工作日与周末的短时交通流趋势存在着差异^[22],后续需要从工作日与周末这两方面展开实验,同时将实验数据集划分为训练集、交叉验证集和测试集,比例分别为70%、10%和20%^[23].

3.1 性能评价指标

本文在实验过程中涉及到的评价指标包括均方根误差(RMSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和拟合优度(R^2),计算公式如下:

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (Y_t - \hat{Y}_t)^2}, \quad (23)$$

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |Y_t - \hat{Y}_t|, \quad (24)$$

$$\text{MAPE} = \frac{1}{m} \sum_{i=1}^m \frac{|Y_t - \hat{Y}_t|}{Y_t}, \quad (25)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (Y_t - \hat{Y}_t)^2}{(Y_t - \bar{Y})^2}. \quad (26)$$

其中: Y_t 为 t 时刻样本的交通流实际值, \bar{Y} 为样本均值, \hat{Y}_t 为 t 时刻的预测值.

3.2 两级筛选流程

1) 第1级筛选.

图3展示了实验选取的TH77号高速公路总共31个监测点的分布情况,S537号监测点为本文选取的目标预测路段. 首先选择目标预测路段S537连续一周(2016-06-06~2016-06-12)的数据进行自相关性分析,其中,工作日中星期二与周末中星期六的交通流自相关性如图4所示. 可以看出,星期二的交通流使得自相关函数为正时的滞后值取值范围为[1, 7],星期六为[1, 6],星期一、星期三、星期四、星期五和星期日的滞后值取值范围分别为:[1, 7]、[1, 8]、[1, 7]、[1, 7]、[1, 6]. 因此可以确定:工作日与周末使得自相关函数值为正时的滞后值取值范围分别为[1, 7]和[1, 6].



图3 监测点分布

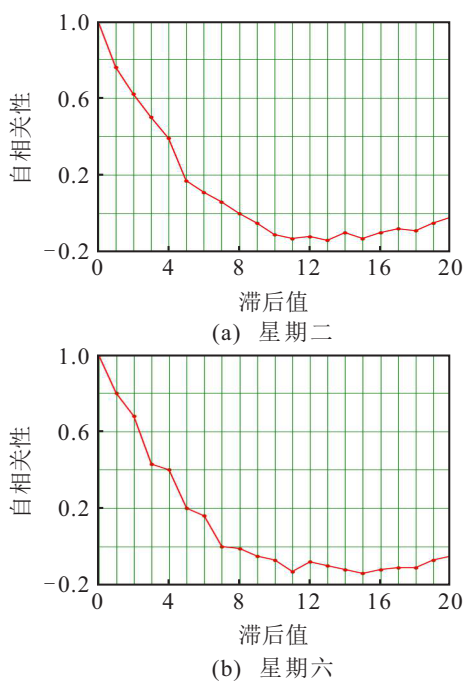


图4 自相关性

现取工作日的滞后值 $\varphi_a = 5$,接下来利用互相关函数计算路段之间的互相关性. 图5表示监测点S538与S537的互相关性. 由图5可知,当滞后值为1时互相关性最大,同时满足 $0 \leq |\varphi_c^{L_v}| \leq 5$,故将S538归入空间邻域集 R_{L_j} . 同理,最终得到目标预测路段的空间邻域集总共包含16个路段,分别为S523, S526, S527, S528, S529, S531, S534, S536, S538, S539, S540, S542, S324, S333, S334, S1818.




图5 S538与目标预测路段的互相关性

2) 第2级筛选.

利用KNN算法计算各个路段与目标路段的欧式距离,选取与目标预测路段具有较强关联性的路段作为模型的输入.图6显示了不同k值下RMSE的变化趋势.当k较小时,偏少的路段信息会使组合模型挖掘的时空特性不够全面,而当k较大时,模型的输入中会加入相关性较弱的路段信息,削弱对目标路段影响较大的路段的作用.由图6可知,当k取8时预测效果最好,对应路段组合为S334,S526,S529,S534,S536,S538,S539,S1818.

工作日与周末的各种滞后值取值下的筛选情况如表1所示,监测点S537在工作日和周末的最佳路段

组合数分别为8和7,最佳时间窗口分别为5和4,即分别利用前60min与前45min的历史交通流数据来预测下一个15min的交通流.




图6 不同k值下的RMSE变化趋势

表1 不同滞后值下的筛选结果

滞后值	工作日			周末		
	k 值	RMSE	最佳路段组合	k 值	RMSE	最佳路段组合
1	2	34.61		3	35.22	
2	3	29.91		3	31.97	
3	6	24.85		5	22.60	
4	5	18.30	S334, S526, S529, S534, S536, S538, S539, S1818	7	15.33	S526, S531, S534, S536, S538, S539, S1818
5	8	13.56		8	18.08	
6	9	16.12		8	21.81	
7	9	18.297		-	-	

3.3 输入数据结构

1) 邻接矩阵.邻接矩阵A描述了各个路段交通流两两之间的影响程度.以周末的时间窗口为4时的筛选结果为例,监测点S537与各个路段两两之间的互相关函数值按照8x8形式排列,如表2所示.

表2 邻接矩阵

	S526	S531	S534	S536	S537	S538	S539	S1818
S526	0	0.33	0.16	0.26	0.49	0.33	0.23	0.16
S531	0.33	0	0.27	0.30	0.44	0.34	0.31	0.38
S534	0.16	0.27	0	0.19	0.18	0.50	0.25	0.20
S536	0.26	0.30	0.19	0	0.35	0.12	0.29	0.25
S537	0.49	0.44	0.18	0.35	0	0.17	0.46	0.39
S538	0.33	0.34	0.50	0.12	0.17	0	0.50	0.23
S539	0.23	0.31	0.25	0.29	0.46	0.50	0	0.37
S1818	0.16	0.38	0.20	0.25	0.39	0.23	0.37	0

表3 特征矩阵

	S526	S531	S534	S536	S537	S538	S539	S1818
0:00	14	12	13	13	12	18	10	11
0:15	22	22	25	28	28	19	25	25
0:30	40	38	33	31	29	40	23	29
0:45	41	43	51	46	46	29	36	37
1:00	59	55	54	55	56	27	36	42
1:15	36	33	35	29	28	25	26	28
1:30	36	34	41	39	38	14	24	25
1:45	41	41	40	41	35	16	24	29
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

2) 特征矩阵.特征矩阵X描述了每个路段上交通流随时间的变化,包括S537在内的8个路段在周末43天的数据按照(43x96)x8形式排列,如表3所示.

4 实验仿真与结果分析

4.1 模型参数设置

GCN与GRU的网络层数、隐藏神经元数是组合模型的主要参数.表4显示了不同图卷积层数对组合模型预测性能影响的实验结果,可以得知当图卷积层数为2时预测性能最好.

表4 不同图卷积层数对模型预测性能影响

图卷积层数	性能评价指标		
	RMSE	MAE	R ²
1	20.54	17.68	0.842
2	15.23	13.25	0.863
3	16.80	16.05	0.853
4	18.74	18.77	0.850
5	22.68	20.23	0.854

进一步地,在图卷积层数设置为2时调节GRU的网络层数和隐藏神经元数进行实验,表5展示了网络层数为3时不同隐藏神经元数下的实验结果.通过试凑法对不同网络层数下的实验结果进行对比分析,得到在[1,5]范围内GRU的最佳网络层数为3,隐藏神经元个数为100.

表5 不同隐藏神经元数对模型预测性能影响

隐藏神经元数	性能评价指标		
	RMSE	MAE	R^2
8	8.15	6.96	0.826
16	8.04	6.82	0.831
32	7.98	6.79	0.833
64	7.96	6.74	0.834
100	7.90	6.72	0.841
128	7.95	6.76	0.836
200	8.45	7.01	0.830

综上,GCN-GRU组合模型的初始学习率取0.001, batch_size大小为64, epoch大小为200, 图卷积层数为2, 门控循环单元层数为3, 隐藏神经元数设置为100, 激活函数选择ReLU, 模型优化器设置为Adam.

用于对比的几种常用模型包括支持向量回归模型(SVR)、堆栈式自编码网络模型(SAEs)^[24]、门控

循环单元模型(GRU)及时间卷积网络模型(TCN)^[25]等. 其中,SVR模型是一种用于短时交通流预测的经典机器学习模型,按照文献[7]使用径向基函数(RBF)作为核函数,惩罚参数设置为0.001; SAEs模型通过堆叠自动编码器创建深度网络来有效学习短时交通流特征,其隐藏层设置为4层,每层隐藏单元数设置为150; GRU模型参考文献[9]设置3层网络,每层隐藏单元数设置为64; TCN模型借助因果卷积与扩张卷积实现对短时交通流序列时间信息的深入挖掘,按照文献[25]的思路,模型的扩张系数设置为{1, 2, 4, 8}, 卷积层数为3层,残差模块堆栈数为1,卷积核大小和数目分别为 3×3 和16.

4.2 两级筛选机制对实验结果影响的分析论证

在监测点S537处,分别对经过两级筛选、只采用第1级筛选、只采用第2级筛选及未经过筛选的数据集的预测结果进行比较. 预测结果对比如表6所示.

表6 不同隐藏神经元数对模型预测性能影响

不同筛选策略	工作日				周末			
	RMSE	MAE	MAPE	R^2	RMSE	MAE	MAPE	R^2
未经筛选	25.20	16.47	23.51%	0.762	28.56	17.60	27.24%	0.734
只采用第一级筛选	21.59	15.01	19.87%	0.833	26.68	16.08	22.37%	0.810
只采用第二级筛选	21.38	14.60	18.83%	0.835	25.59	14.82	19.64%	0.821
经过两级筛选	13.56	9.58	12.26%	0.908	15.33	10.25	14.02%	0.895

由表6可知:

1) 在工作日内,与未经过筛选的模型预测结果相比,只采用第1级筛选之后的预测效果的RMSE、MAE、MAPE分别降低了14.3%、8.9%、15.5%, R^2 提高了9.3%;只采用第2级筛选之后的预测效果的RMSE、MAE、MAPE分别降低了15.2%、11.4%、19.9%, R^2 提高了9.6%. 周末的实验结果展现出了与周内同样的规律,表明了筛选处理数据集对提高模型预测效果的重要性.

2) 经过两级筛选之后的模型与只经过第1级筛选的预测结果相比,在周末的RMSE、MAE、MAPE分别降低了42.5%、36.3%、37.3%, R^2 提高了7.7%;与只经过第2级筛选的模型预测结果相比, RMSE、MAE、MAPE分别降低了40.1%、30.8%、28.6%, R^2 提高了10%. 这是由于只采用两级筛选机制中的任何一级都会导致对目标预测路段影响较小的路段以及无关路段被引入,从而对组合模型的预测效果产生影响. 说明采用两级筛选机制能够提高组合模型的预测效果.

4.3 不同预测模型的实验结果对比

将GCN-GRU组合模型与SVR模型、SAEs模型、GRU模型及TCN模型等进行预测结果的比较,并将其分为工作日与周末进行讨论,以验证组合模型的预测性能. 各模型性能评价指标如表7的TDRL数据集所在列所示.

由表7可知:

1) SVR模型的预测效果最差,说明浅层机器学习模型对数据的特征挖掘能力不足. 相比之下,GRU模型、TCN模型在工作日的RMSE分别降低了18.0%、35.7%, R^2 分别提高了11.0%、16.0%;周末的RMSE分别降低了16.5%、26.8%, R^2 分别提高了10.7%、16.1%. 这是因为两个模型能够记忆交通流的时间信息以提取时间特征.

2) 利用时空特性的GCN-GRU组合模型与GRU模型相比,工作日的RMSE、MAE、MAPE分别降低了47.2%、42.2%、48.6%, R^2 提高了14.8%;与TCN模型相比,组合模型在周末的RMSE、MAE、MAPE分别降低了37.8%、35.2%、35.9%, R^2 提高了11.6%. 原因

表7 各模型的性能评价指标

预测模型	TDRL数据集								PeMs数据集							
	工作日				周末				工作日				周末			
	RMSE	MAE	MAPE	R^2	RMSE	MAE	MAPE	R^2	RMSE	MAE	MAPE	R^2	RMSE	MAE	MAPE	R^2
SVR	31.32	22.09	33.59%	0.713	33.68	23.31	35.92%	0.691	30.09	21.01	32.78%	0.720	32.28	22.11	34.83%	0.698
SAEs	24.59	15.42	21.04%	0.802	26.02	17.07	26.13%	0.783	25.83	15.07	20.62%	0.792	25.94	18.49	26.97%	0.791
GRU	25.68	16.57	23.86%	0.791	28.13	19.97	27.69%	0.765	25.30	15.48	23.11%	0.795	26.04	18.54	26.84%	0.780
TCN	20.15	13.44	17.12%	0.827	24.64	15.83	21.87%	0.802	15.68	10.03	15.40%	0.887	18.53	11.85	19.45%	0.874
GCN-GRU	13.56	9.58	12.26%	0.908	15.33	10.25	14.02%	0.895	11.51	8.21	11.27%	0.921	13.32	10.07	12.33%	0.903

在于该组合模型借助GCN实现了对交通流空间特性的挖掘,预测效果得到了进一步提升,说明该组合模型在考虑多路段时空特性的短时交通流预测中有着优秀的表现.同时,模型在工作日和周末的训练时间分别为125 s和119 s,训练完成后用于预测所需时间分别为12 s和15 s,均在时间间隔15 min范围内,说明该组合模型具有时效性.

将该组合模型与用于对比的各个模型应用到美国加利福尼亚州性能测量系统(performance measurement system, PeMS)^[26]数据集中,该实测数据集的时间间隔仍为15 min,各模型性能评价指标如表7的PeMs数据集所在列所示.由表7可知,它在工作日和周末的预测效果均好于其余模型,说明该组合模型具有一定的泛化能力.而模型在工作日和周末的训练时间分别为131 s和122 s,训练完成后用于预测所需时间分别为13 s和12 s,仍在时间间隔15 min范围内,同样说明该组合模型具有较好的时效性.

5 结论

为了有效分析并挖掘多路段时空特性,本文提出了一种两级筛选机制来确定与目标预测路段相关性较强的最佳路段组合,借助GCN全局处理路段拓扑信息的优势以及GRU对时间信息的长时记忆能力,搭建了GCN-GRU组合预测模型以提取短时交通流的时空特性.仿真结果表明,利用两级筛选机制对路段进行筛选能优化数据集,模型预测性能得到明显改善,预测效果优于SVR、SAEs、GRU及TCN等常用预测模型.本文中采用的图卷积网络是从基于图结构的邻接矩阵与特征矩阵中提取局部特征,因此输入空间所在的局部区域会造成卷积运算结果的局限性.在后续对空间特征的提取需要扩大目标区域,其次,中国高速公路的交通特性与美国存在着差异,所提出方法在中国的适用性也值得进一步研究.

参考文献(References)

[1] Hassan T, El-Mowafy A, Wang K. A review of system integration and current integrity monitoring methods

for positioning in intelligent transport systems[J]. IET Intelligent Transport Systems, 2021, 15(1): 43-60.

[2] Pavlyuk D. Feature selection and extraction in spatiotemporal traffic forecasting: A systematic literature review[J]. European Transport Research Review, 2019, 11: 6.

[3] Zhang S Q, Lin K P. Short-term traffic flow forecasting based on data-driven model[J]. Mathematics, 2020, 8(2): 152-169.

[4] 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.

[5] Zhou T, Jiang D Z, Lin Z Z, et al. Hybrid dual Kalman filtering model for short-term traffic flow forecasting[J]. IET Intelligent Transport Systems, 2019, 13(6): 1023-1032.

[6] 陈丹, 胡明华, 张洪海, 等. 基于贝叶斯估计的短时空域扇区交通流量预测[J]. 西南交通大学学报, 2016, 51(4): 807-814.

(Chen D, Hu M H, Zhang H H, et al. Short-term traffic flow prediction of airspace sectors based on Bayesian estimation theory[J]. Journal of Southwest Jiaotong University, 2016, 51(4): 807-814.)

[7] 姚智胜, 邵春福, 高永亮. 基于支持向量回归机的交通状态短时预测方法研究[J]. 北京交通大学学报, 2006, 30(3): 19-22.

(Yao Z S, Shao C F, Gao Y L. Research on methods of short-term traffic forecasting based on support vector regression[J]. Journal of Beijing Jiaotong University, 2006, 30(3): 19-22.)

[8] Zhang L Z, Alharbe N R, Luo G C, et al. A hybrid forecasting framework based on support vector regression with a modified genetic algorithm and a random forest for traffic flow prediction[J]. Tsinghua Science and Technology, 2018, 23(4): 479-492.

[9] Zhang D, Kabuka M R. Combining weather condition data to predict traffic flow: A GRU-based deep learning approach[J]. IET Intelligent Transport Systems, 2018,

- 12(7): 578-585.
- [10] Dai G W, Ma C X, Xu X C. Short-term traffic flow prediction method for urban road sections based on space-time analysis and GRU[J]. *IEEE Access*, 2019, 7(9): 143025-143035.
- [11] Cao X F, Zhong Y H, Zhou Y, et al. Interactive temporal recurrent convolution network for traffic prediction in data centers[J]. *IEEE Access*, 2018, 6: 5276-5289.
- [12] Du S D, Li T R, Gong X, et al. A hybrid method for traffic flow forecasting using multimodal deep learning[J]. *International Journal of Computational Intelligence Systems*, 2020, 13(1): 85-97.
- [13] Shuman D I, Narang S K, Frossard P, et al. The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains[J]. *IEEE Signal Processing Magazine*, 2013, 30(3): 83-98.
- [14] Bronstein M M, Bruna J, LeCun Y, et al. Geometric deep learning: Going beyond euclidean data[J]. *IEEE Signal Processing Magazine*, 2017, 34(4): 18-42.
- [15] Cui Z Y, Henrickson K, Ke R M, et al. Traffic graph convolutional recurrent neural network: A deep learning framework for network-scale traffic learning and forecasting[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(11): 4883-4894.
- [16] Cai P L, Wang Y P, Lu G Q, et al. A spatiotemporal correlative k-nearest neighbor model for short-term traffic multistep forecasting[J]. *Transportation Research Part C: Emerging Technologies*, 2016, 62(1): 21-34.
- [17] Cheng S F, Lu F, Peng P, et al. Short-term traffic forecasting: An adaptive ST-KNN model that considers spatial heterogeneity[J]. *Computers, Environment and Urban Systems*, 2018, 71(9): 186-198.
- [18] 韩冲, 王俊丽, 吴雨茜, 等. 基于神经进化的深度学习模型研究综述[J]. *电子学报*, 2021, 49(2): 372-379.
(Han C, Wang J L, Wu Y X, et al. A review of deep learning models based on neuroevolution[J]. *Acta Electronica Sinica*, 2021, 49(2): 372-379.)
- [19] Taek M K. Transportation data research laboratory [DB/OL]. [2021-05-25]. <https://www.d.umn.edu/tdrl/>.
- [20] 于泉, 姚宗含. 交通流预测的马尔科夫粒子滤波方法研究[J]. *交通运输系统工程与信息*, 2019, 19(2): 209-215.
(Yu Q, Yao Z H. Markov particle filter traffic flow prediction model[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2019, 19(2): 209-215.)
- [21] 袁华, 陈泽濠. 基于时间卷积神经网络的短时交通流预测算法[J]. *华南理工大学学报: 自然科学版*, 2020, 48(11): 107-113.
(Yuan H, Chen Z H. Short-term traffic flow prediction based on temporal convolutional networks[J]. *Journal of South China University of Technology: Natural Science Edition*, 2020, 48(11): 107-113.)
- [22] Hou Z S, Li X Y. Repeatability and similarity of freeway traffic flow and long-term prediction under big data[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(6): 1786-1796.
- [23] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 97-115.
(Zhou Z H. *Machine learning*[M]. Beijing: Tsinghua University Press, 2016: 97-115.)
- [24] Lv 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] Zhao W T, Gao Y Y, Ji T X, et al. Deep temporal convolutional networks for short-term traffic flow forecasting[J]. *IEEE Access*, 2019, 7(5): 114496-114507.
- [26] Tavares T, Toks O. The freeway performance measurement system[DB/OL]. [2021-05-25]. <http://pems.dot.ca.gov/>.

作者简介

徐先峰(1982—), 男, 副教授, 博士, 从事深度学习理论及应用、智慧能源与智能电网等研究, E-mail: xxf_chd@163.com;

杨凡(1998—), 男, 硕士生, 从事短时交通流预测的研究, E-mail: 1323139414@qq.com;

刘状壮(1988—), 男, 副教授, 博士, 从事交通与能源融合、路域环境感知与智能铺面等研究, E-mail: zzliu@chd.edu.cn;

李陇杰(1987—), 男, 讲师, 博士, 从事智能交通系统的研究, E-mail: lilongjie@chd.edu.cn;

夏振(1996—), 男, 硕士生, 从事短时交通流预测的研究, E-mail: 1499006481@qq.com.

(责任编辑: 孙艺红)