

文章编号:1672-3961(2024)02-0060-09 DOI:10.6040/j.issn.1672-3961.0.2023.040

基于时频分解与深度学习的轨道客流预测

徐金华, 罗义凯, 李昱燃, 李岩*

(长安大学运输工程学院, 陕西 西安 710064)

摘要:为提高城市轨道交通线网站点短时客流预测精度,在对轨道站点分类的基础上分别对各类型站点进行客流预测。以动态时间弯曲作为度量,采用K-means算法对站点进行分类,分析各类型站点客流时序特征;为弱化原始客流数据中噪声的影响,利用经验模态分解(empirical mode decomposition, EMD)方法对各类型站点原始客流进行时频分解;提出一种融合图卷积网络(graph convolution network, GCN)和门控循环单元(gated recurrent unit, GRU)的深度学习模型,并以分解得到的分量作为模型输入。以西安地铁为例进行研究,结果表明,根据连续一周站点客流时序特征可将站点分为办公就业型、密集居住型、休闲娱乐型、偏远居住型和职住均衡型5类。采用平均绝对百分比误差及均方根误差作为评价指标,结果表明本研究所提方法对各类站点客流预测的精度优于基准模型。

关键词:客流预测;图卷积;门控循环单元;站点分类;经验模态分解

中图分类号:U491.1+4 **文献标志码:**A

引用格式:徐金华,罗义凯,李昱燃,等.基于时频分解与深度学习的轨道客流预测[J].山东大学学报(工学版),2024,54(2):60-68.

XU Jinhua, LUO Yikai, LI Yuran, et al. Prediction of rail passenger flow based on time-frequency decomposition and deep learning[J].

Journal of Shandong University (Engineering Science), 2024, 54(2):60-68.

Prediction of rail passenger flow based on time-frequency decomposition and deep learning

XU Jinhua, LUO Yikai, LI Yuran, LI Yan*

(College of Transportation Engineering, Chang'an University, Xi'an 710064, Shaanxi, China)

Abstract: To improve the accuracy of short-term passenger flow forecasting at urban rail stations, the passenger flow of each type of station on the basis of the classification of rail stations was predicted. Dynamic time warping was used as a measure, and the K-means algorithm was used to classify the stations. The time-series characteristics of passenger flow at various stations were analyzed. To weaken the influence of noise in the original passenger flow data, the empirical mode decomposition (EMD) method was used to perform time-frequency decomposition on the original passenger flow of various stations. A deep learning model that combined graph convolution network (GCN) and gated recurrent unit (GRU) was proposed, and the components decomposed by EMD were used as model input. Taking Xi'an Metro as an example, the results showed that the stations could be divided into five types: office employment type, dense residential type, leisure and entertainment type, remote residential type, and occupation-residential balance type according to the time series characteristics of passenger flow in a continuous week. The average absolute percentage error and the root mean square error were used as evaluation indicators. The results showed that the method proposed in this study outperformed the baseline model in terms of accuracy for predicting passenger flow at various stations.

Keywords: passenger flow prediction; graph convolution; gated recurrent unit; station classification; empirical mode decomposition

收稿日期:2023-03-01

基金项目:国家自然科学基金资助项目(51408049);陕西省自然科学基金基础研究计划项目(2020JM-237)

第一作者简介:徐金华(1996—),男,江苏南通人,博士研究生,研究方向为交通规划等。E-mail:xujinhua@chd.edu.cn

*通信作者简介:李岩(1983—),男,河北衡水人,教授,博士生导师,博士,研究方向为交通规划等。E-mail:lyan@chd.edu.cn

0 引言

城市轨道交通具有运量大、速度快、准点率高等特点,能分担道路交通压力。完善的城市轨道交通网络可以缓解城市拥堵^[1]。轨道客流的短时预测是优化城市轨道线网运力、提高轨道线网服务水平的重要环节^[2]。短时轨道客流的准确预测对于制定合理的运营方案、提高线网的运营能力具有重要意义。由于各站点自身特性及其周边土地利用性质的不同,站点客流的时序特征也有所差异。因此,有必要对轨道站点进行合理分类,并针对具有不同时序特征类型的站点分别进行预测。

目前,轨道站点分类的依据主要有站点与其他站点或枢纽间的关联性^[3]、站点周边土地利用性质^[4]和站点进出站客流时序特征^[5-6]。 K -means 是时间序列聚类中的常用方法^[7],时序数据聚类需要以相似性度量为基础,时序数据相似性度量中最广泛、最有效的方法之一是动态时间弯曲(dynamic time warping, DTW)^[8]。

轨道站点客流短时预测的方法主要有基于统计的模型、基于非线性理论的模型、基于深度学习模型和混合模型。基于统计的模型需要对客流数据的数学分布做出假设,代表模型有自回归移动平均(auto regressive moving average, ARMA)^[9]、自回归差分平均模型(auto regressive integrated moving average model, ARIMA)^[10]、灰色模型(grey model, GM)^[11]和卡尔曼滤波^[12]等。基于统计的模型需依赖先验知识,而且大多以线性理论为基础,对具有非平稳性、周期性的短时轨道客流数据的预测性能有限。基于非线性理论的模型用到的方法主要有支持向量回归(support vector regression, SVR)^[13]和随机森林(random forest, RF)^[14]等。这类非线性预测方法主要是从大量历史数据获取客流的潜在联系,能够有效捕捉客流序列中的非线性规律。此外,随着深度学习技术的快速发展,部分学者开始探索将其应用于客流预测问题,例如:文献[15]构建图卷积网络(graph convolutional network, GCN)和循环神经网络(recurrent neural network, RNN)组合模型以捕捉客流的空间相关性和时间特征;文献[16]应用遗传算法优化的长短期记忆(long short-term memory, LSTM)神经网络获得较高精度。得益于深度神经网络的拟合能力,基于深度学习模型的预测精度通常优于基于统计和非线性理论的模型^[17]。混合

模型是指由前述多种方法组合而成的模型,混合模型主要是通过弥补单一模型缺陷提高预测精度,例如文献[18]通过构建门控制循环单元(gated recurrent unit, GRU)和 RF 组合模型来提高预测精度。然而,上述模型大多直接将客流时序作为模型输入,忽略了样本噪声对模型预测性能的干扰。有部分学者引入小波变换(wavelet transform, WT)^[9]和经验模态分解(empirical mode decomposition, EMD)^[2,19]等时频分解方法对客流时序数据预处理,结果表明这些方法可以提高模型预测精度。

本研究重点是轨道站点的短时客流预测,更关注站点间客流时序的差异,因此以各站点进出站客流的时序特征对站点进行分类,利用 EMD 法将原始客流数据分解为若干分量以降低原始数据中噪声对预测结果的影响,构建图卷积神经网络模型,通过捕捉线网客流数据的空间相关性和时间依赖性实现对各类型站点短时客流的预测。

1 方法

1.1 动态时间弯曲

DTW 是评价时间序列特征相似性的一种方法。考虑两个时间序列 $R = \{r_1, r_2, \dots, r_N\}$ 和 $T = \{t_1, t_2, \dots, t_N\}$, 其中 N 表示序列长度。将这两个时间序列构建成一个 $N \times N$ 的距离矩阵 $D_{N \times N}$, 该矩阵内各元素间的距离

$$D(i, j) = \|r_i, t_j\|_2, \quad (1)$$

式中 $\|\cdot\|_2$ 表示欧氏距离。

在满足边界性、连续性和单调性约束的情况下,基于动态规划算法在 $D_{N \times N}$ 中搜索一条使经过距离矩阵元素累计距离最小的路径,其中累积距离

$$\gamma(i, j) = D(i, j) + \min[\gamma(i-1, j-1), \gamma(i-1, j), \gamma(i, j-1)], \quad i, j = 2, 3, \dots, N, \quad (2)$$

式中 $\min[\gamma(i-1, j-1), \gamma(i-1, j), \gamma(i, j-1)]$ 表示达到该点的最小邻近元素的累计距离之和。

最终求出符合约束条件最优弯曲路径的最小值,即为 DTW 距离

$$D_{\text{TW}}(X, Y) = \min\left(\sum_{k=1}^L D(w_k)\right), \quad (3)$$

式中: w_k 为最优弯曲路径中矩阵元素 k 的坐标, $w_k = (r_i, t_j)$; $D(w_k)$ 为距离矩阵元素 k 的数值; L 为最优弯曲路径的长度,满足 $N < L < 2N - 1$ 。

1.2 经验模态分解

轨道站点客流具有非线性和非平稳性特点^[2],

若将其直接作为预测模型的输入,会因数据中掺杂的噪声而降低模型预测准确性,因此需要弱化原始数据中的噪声。EMD 是一种针对非线性、非平稳信号的自适应分解方法,可以将复杂信号分解为一系列本征模函数(intrinsic mode function, IMF)分量和残差。每个 IMF 分量都是具有特定尺度的时间序列,其定义为:在完整数据集中,信号局部极值点和过零点的数目仅有相等或差值为 1 的情况;对于任意点,由极大值包络和极小值包络确定的局部平均值为 0。

原始信号 $x(t)$ 的 EMD 分解过程如下。

步骤 1: 确定原始信号 $x(t)$ 的所有极值点,并用三次样条函数连接所有局部极值点,得到极大值包络 $e_{\max}(t)$ 和极小值包络 $e_{\min}(t)$,定义均值

$$m(t) = \frac{e_{\max}(t) + e_{\min}(t)}{2}. \quad (4)$$

步骤 2: 计算 $x(t)$ 与 $m(t)$ 的差值 $h(t) = x(t) - m(t)$,判断 $h(t)$ 是否满足 IMF 定义。若满足,则得到第 i 个本征模态函数 $c_i(t)$, $c_i(t) = h(t)$,并进入步骤 3;若不满足,则将 $h(t)$ 作为原始信号返回步骤 1。

步骤 3: 更新信号 $x(t)$, $x(t) = x(t) - c_i(t)$,若 $x(t)$ 为单调函数,则得到残余分量 $r(t)$, $r(t) = x(t)$,并停止迭代;否则,将更新后的信号 $x(t)$ 作为输入信号返回步骤 1。

一般情况下,步骤 2 中的 IMF 条件不是严格按照 Huang 的定义设定,可根据 Cauchy 准则判断,该准则要求 2 个相邻差值标准差 S_d 很小, S_d 一般取值范围为 0.2~0.3。 S_d 定义为:

$$S_d = \sum_{i=0}^T \frac{\|d_{i-1}(t) - d_i(t)\|^2}{d_{i-1}^2(t)}, \quad (5)$$

式中, $d_i(t)$ 表示重复步骤 1~3 过程中第 i 次提取出的信号, T 表示重复步骤 1~3 过程中提取到的信号数。

最终,原始信号

$$x(t) = \sum_{i=1}^n c_i(t) + r(t). \quad (6)$$

1.3 图卷积网络

GCN 能提取图中边和节点特征,与卷积神经网络(convolutional neural networks, CNN)不同,GCN 可以直接处理非欧几里得结构数据。城市轨道交通网络本身就是具有非欧几里得结构的拓扑网络,且网络中各站点客流互相影响。因此,本研究采用 GCN 捕捉城市轨道交通线网中站点客流的空问特征。

1.3.1 图生成

在以往采用 GCN 模型预测轨道客流的研究中大

多是以轨道线网的拓扑结构构建图,这容易弱化远距离站点间客流的影响。本研究构建的图 $G = \{V, E\}$ 中,任意两节点 v_i 与 v_j 间均有边 e_{ij} 直接相连。此外,构建两种邻接矩阵:最短距离邻接矩阵 A^d 和起讫点(origin-destination, OD)邻接矩阵 A^{OD} 。

地理学第一定律指出:事务之间的相关性与距离有关,距离越近,事物间相关性越大^[20]。城市轨道交通线网中各站点间是相互连通的,根据线网内站点间的最短距离的倒数构造邻接矩阵,距离较近的站点间将具有更高的权重。 A^d 中的元素

$$A_{i,j}^d = \frac{1}{d_{i,j}^{\min}}, \quad (7)$$

式中 $d_{i,j}^{\min}$ 为网络中点 v_i 与 v_j 间的最短路径距离。

轨道线网中 OD 客流量越大,意味着站点间客流相关性越高^[21]。 A^{OD} 中的元素

$$A_{i,j}^{OD} = \frac{1}{2} \left(\frac{O_{ij}^D}{\sum_k O_{ik}^D} + \frac{O_{ji}^D}{\sum_k O_{jk}^D} \right), \quad (8)$$

式中 O_{ij}^D 为网络中点 v_i 与 v_j 间的 OD 客流量。

1.3.2 图卷积

为充分考虑站点间最短距离和 OD 客流量对预测结果的影响,本研究将参照文献[22]的方法融合矩阵 A^d 和 A^{OD} 。为消除不同邻接矩阵差异较大的影响,将每个邻接矩阵作归一化处理:

$$\bar{A} = D^{-1}A + I, \quad (9)$$

式中, \bar{A} 为归一化后的矩阵, I 为单位矩阵, D 为度矩阵, D 中的元素

$$D_{ik} = \begin{cases} \sum_{j=0}^{N-1} A_{ij}, & i = k \\ 0, & i \neq k \end{cases}. \quad (10)$$

2 个邻接矩阵融合后的矩阵

$$F = \bar{W}^d \circ \bar{A}^d + \bar{W}^{OD} \circ \bar{A}^{OD}, \quad (11)$$

式中: \bar{W}^d 和 \bar{W}^{OD} 为归一化后的权重矩阵, $\bar{W}^d = \text{softmax}(W^d)$, $\bar{W}^{OD} = \text{softmax}(W^{OD})$, 其中 W^d 和 W^{OD} 为权重矩阵, softmax 表示激活函数; \circ 表示元素乘积。

在得到融合矩阵 F 后,图卷积结果

$$h_g^t = \text{ReLU}(F x_g^t W), \quad (12)$$

式中, x_g^t 表示 t 时刻的输入数据, W 表示卷积权重矩阵, ReLU 表示激活函数。

1.4 门控制循环单元

GRU 是 RNN 的一种,是 LSTM 的变体,主要用于处理序列数据^[23]。GRU 在保留 LSTM 单元解决梯度消失和梯度爆炸问题能力的基础上,对单元内部结构进行了精简,相较于 LSTM,GRU 的收敛速

度更快,性能相当,且不易过度拟合。GRU神经网络通过门结构有选择性地传递信息,可以有效解决RNN的长期依赖问题,并实现控制信息的目的。

GRU的计算过程为:

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

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z), \quad (14)$$

$$\tilde{h}_t = \tanh(W_h[r_t \odot h_{t-1}, x_t] + b_h), \quad (15)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t, \quad (16)$$

式中: z_t 和 r_t 分别表示更新门和重置门; σ 为Sigmoid激活函数,作为门控信号将中间状态转换到0~1范围内; W_r 为重置门的权重矩阵; x_t 为当前时序输入信息; b_r 为复位门的偏移向量; W_z 为更新门的权重矩阵; b_z 为更新门的偏移向量; W_h 为候选状态 \tilde{h}_t 的权重矩阵; \odot 为哈达玛积; b_h 为偏移向量; h_t 和 h_{t-1} 分别为当前时序状态和前一时序状态的信息。

1.5 EMD-GCNGRU模型

EMD-GCNGRU模型的结构如图1所示,其运算流程如下。

步骤1:通过EMD法对全网站点原始客流时序数据进行分解,得到分量特征 $X_C = \{X_{C_1}, X_{C_2}, \dots, X_{C_m}\}$,其中 m 为分量个数, $X_{C_m} \in \mathbf{R}^{S \times T}$ 为站点原始客流时序数据的第 m 个分量, S 为全网站点个数, T 为时间序列长度。

步骤2:对于每一个分量 X_{C_m} ,将 $\{X_{C_{m,t-m'}}, \dots, X_{C_{m,t-1}}, X_{C_{m,t}}\}$ 输入图卷积层后,根据式(15)计算图卷积的输出结果 $\{h_{g,C_m}^{t-m'}, \dots, h_{g,C_m}^{t-1}, h_{g,C_m}^t\}$,其中 m' 为第 m 个分量的历史时间步长, $X_{C_{m,t}} \in \mathbf{R}^{S \times 1}$ 为第 m 个分量在时间步 t 对应的值。

步骤3:将图卷积的输出 $\{h_{g,C_m}^{t-m'}, \dots, h_{g,C_m}^{t-1}, h_{g,C_m}^t\}$ 作为GRU层的输入,计算得到隐藏状态 $h_{C_{m,t}}$ 。将各分量隐藏状态通过add函数连接得到隐藏状态

$$h_C = a_{\text{add}}\{h_{C_{1,t}}, h_{C_{2,t}}, \dots, h_{C_{m,t}}\}, \quad (17)$$

式中 a_{add} 表示add函数。

步骤4:将隐藏状态 h_C 输入全连接层得到各类别站点的客流预测值 Y' 。

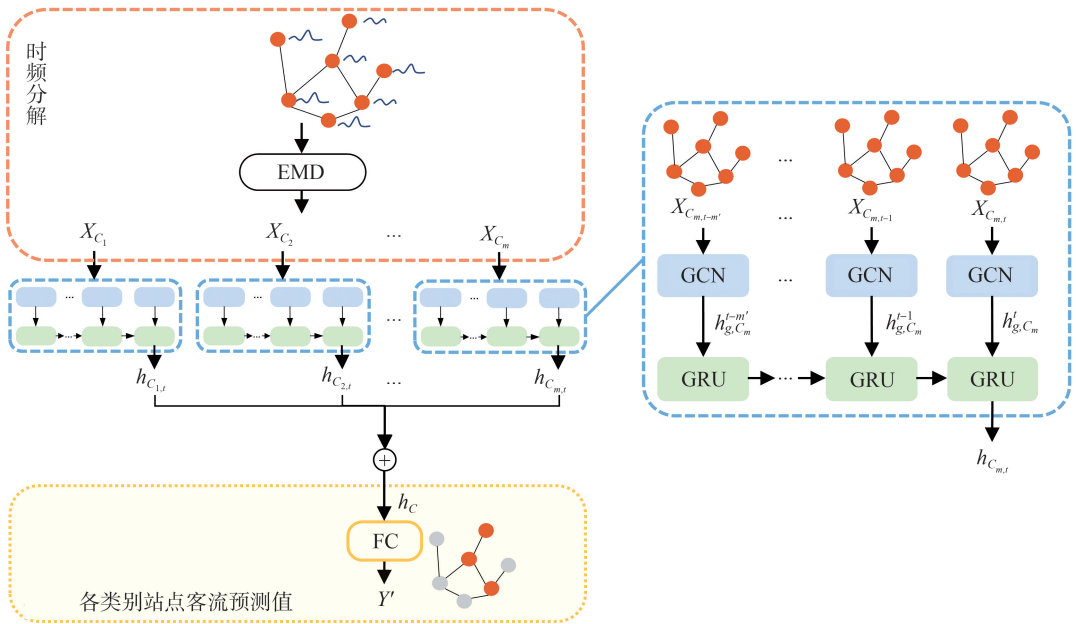


图1 EMD-GCNGRU模型结构图

Fig.1 Structure diagram of the EMD-GCNGRU model

2 站点客流时序特性

2.1 数据来源

本研究以西安市地铁站自动检票系统采集的进出站刷卡数据为例展开研究。数据来源于2018年4月1日—28日西安地铁线网内所有站点的进出站客流数据。线网共有1号线、2号线和3号线3条线路开通运行,运营时间基本为6:00—24:00。

2.2 客流时序特性分析

将连续一周以30 min为间隔统计的进出站客流时间序列作为依据对站点进行分类。为降低某一天数据的偶发性,取2018年4月1日—28日连续4个周各站点各周天对应时段的均值。采用DTW度量客流时序相似度,通过K-means算法得到站点聚类结果。

采用轮廓系数法确定聚类数 $K^{[24]}$,结果如图2所示。




图2 不同聚类数K对应的轮廓系数

Fig.2 Silhouette scores corresponding to different cluster numbers K

轮廓系数越大,表示聚类效果越好。可以看出当 $K=2$ 时,轮廓系数最大,但若仅将全线网站点分为2类,容易忽略客流时序间细节差异。在 $[3,9]$ 范围内,当 $K=5$ 时轮廓系数最大,同时参考相关研究^[25]确定聚类数目 $K=5$ 。

站点聚类结果如表1所示。将各类别内所有站点客流对应时段的均值作为该类别的特征时序,其可视化结果如图3所示。

表1 站点聚类结果

Table 1 Results of station classification

类别	站点
1	玉祥门、通化门、行政中心、永宁门、南稍门、体育场、会展中心、鱼化寨、延平门、科技路、太白南路、吉祥村、浞灞中心、国际港务区
2	三桥、皂河、枣园、长乐坡、浞河、半坡、大明宫西、龙首原、安远门、三爻、凤栖原、航天城、韦曲南、丈八北路、北池头、石家街、辛家庙、广泰门、桃花潭
3	康复路、北客站、北大街、钟楼、小寨、大雁塔、香湖湾、务庄、朝阳门、五路口
4	新筑、保税区、后卫寨、汉城路、纺织城、运动公园、双寨
5	开远门、劳动路、北苑、凤城五路、纬一街、青龙寺、延兴门、洒金桥、万寿路、市图书馆、咸宁路、长乐公园、胡家庙

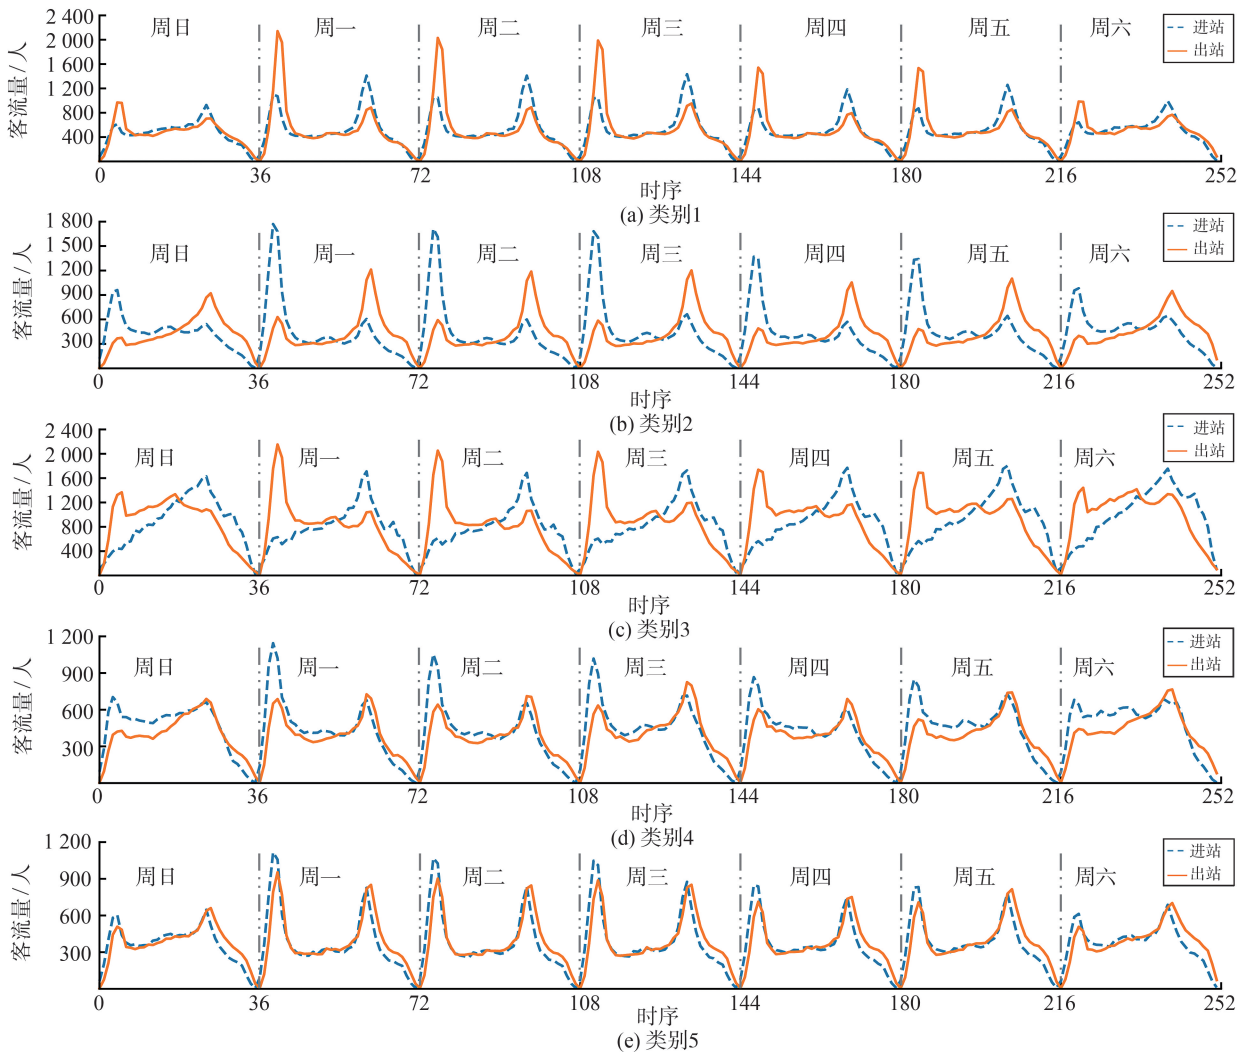


图3 各类别站点客流特征时序

Fig.3 The characteristic time series of the passenger flow of each type of station

由图3可以观察到,类别1站点工作日与休息日客流均具有双峰形态,早高峰出站客流高于进站客流,而晚高峰出站客流低于进站客流,这表明该类型站点周边有小规模居住用地,而就业性质用地占比较大,此类站点为办公就业型站点。

类别2站点工作日与休息日客流也具有双峰形态,但与类别1不同之处在于类别2站点早高峰出站客流低于进站客流,而晚高峰出站客流高于进站客流,这表明该类型站点周边用地类型较为单一,且多为居住用地,就业性质用地较少,此类站点为密集居住型站点。

类别3站点工作日与休息日进站客流呈现单峰形态,且峰值出现于晚高峰。工作日出站客流呈现双峰形态,早高峰高于晚高峰。这表明类别3站点周边居住用地较少,多为商业办公用地。类别3站点休息日出站客流呈现较为明显的三峰形态,这可能是因为这类站点周边分布较大规模商业娱乐用地,在休息日中午时段会吸引游客前来休闲餐饮。此类站点属于休闲娱乐型。


类别4站点工作日与休息日客流也具有双峰形态,而且呈现出与类别2相似的特征,但区别在于类别4站点晚高峰出站客流和进站客流相近。此外,该类站点客流量远低于类别2站点,这是由于该类站点大多远离市区,周边用地多处于开发中,且该

类站点周边居住用地规模略高于就业用地,属于偏远居住型站点。

类别5站点工作日与休息日客流均具有双峰形态,但早高峰与晚高峰的进站与出站客流量间差异都很小,这说明该类型站点周边居住类型用地和就业类型用地规模相当,为职住均衡型站点。

3 客流预测

从2.2节可以看出,不同类型站点间客流时序特征差异明显,因此有必要对各类型站点分别训练模型,对各类站点客流进行预测。将2018年4月1日—24日客流数据作为训练集,2018年4月25日—28日数据作为测试集。通过分析各类站点原始客流时序的IMF偏自相关性确定各分量的输入步长^[2],以类型1站点为例,图4展示了按30 min时间间隔统计客流数据经由EMD分解之后的分量图,各分量偏自相关系数结果如图5所示。根据各分量滞后阶数确定类别1站点客流分量1~7以及残差的历史输入步长分别为5、3、5、5、5、6、6和5。将均方误差作为模型训练的损失函数,使用Adam优化器,采用网格搜索法确定模型堆叠3层GRU,确定隐含层神经元数为64,学习率为0.001,迭代次数为1 000。






图4 类型1站点原始客流及分量时序图

Fig.4 The original passenger flow and component timing diagram of the category 1 stations

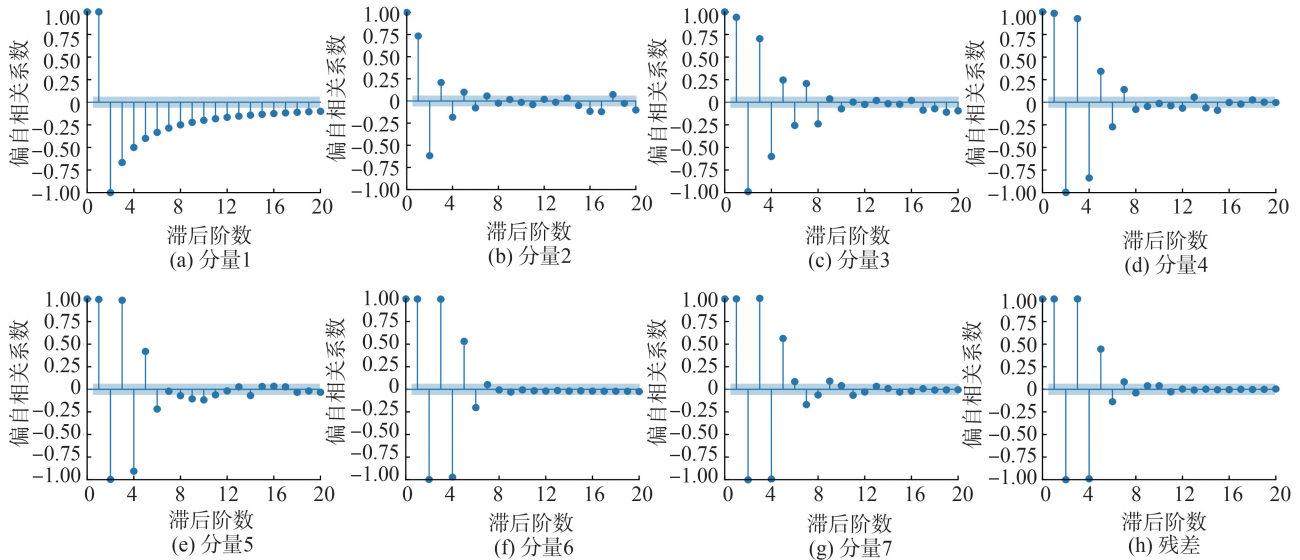


图5 类别1站点分量的偏自相关系数

Fig.5 Partial autocorrelation coefficients for IMFs of category 1 stations

采用平均绝对百分比误差 M_{APE} 和均方根误差 R_{MSE} 评估模型的准确率及稳定性。 M_{APE} 和 R_{MSE} 的计算式为:

$$M_{APE} = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - Y'_i|}{Y_i} \times 100\%, \quad (18)$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2}, \quad (19)$$

式中, Y_i 为客流真实值, Y'_i 为客流预测值。 M_{APE} 和 R_{MSE} 表示真实值与预测值之间的偏差, 其值越小, 表示预测效果越好。

为了验证本研究所提模型的有效性, 将 ARIMA、SVR、LSTM 和以原始客流时序为输入的 GCNGRU 作为基准。其中, ARIMA 的参数 p 、 d 、 q 根据贝叶斯信息准则确定; SVR 与 LSTM 的参数均通过网格搜索法确定。

各类型站点测试集预测结果如图 6 所示, 可以看出各模型预测值与真实客流趋势大体相同, 而所

提模型预测值与真实值更加吻合。

各模型客流预测误差如表 2 所示。由表 2 可以看出: ARIMA 模型误差最高, 因为 ARIMA 需要将非平稳时间序列转化为平稳时间序列, 对非线性客流序列的预测精度较低; SVR 与 LSTM 预测效果好于 ARIMA, 表明 LSTM 和 SVR 可以学习到非线性客流数据中的时间依赖性; GCNGRU 模型的预测效果优于 SVR 与 LSTM, 由于图卷积模块可以捕捉线网站点间客流空间相关性, 因此可以获得更好的预测效果; 与 GCNGRU 模型相比, 所提模型预测结果的误差更低, 类别 1~5 站点客流的 M_{APE} 预测误差分别降低 4.76%、16.06%、5.09%、14.65% 和 11.42%, R_{MSE} 误差分别降低 12.87%、9.9%、6.12%、4.71% 和 6.18%, 这是由于本研究所提模型采用 EMD 弱化了原始客流中的噪声, 此外模型中的图卷积部分可以充分挖掘线网中站点客流的潜在空间相关性, 提高预测精度。




图6 客流预测结果

Fig.6 Results of passenger flow forecast

表2 各模型客流预测误差

Table 2 Errors of different models in predicting station passenger flow

模型	类别 1		类别 2		类别 3		类别 4		类别 5	
	M_{APE}	R_{MSE}	M_{APE}	R_{MSE}	M_{APE}	R_{MSE}	M_{APE}	R_{MSE}	M_{APE}	R_{MSE}
ARIMA	16.24	70.65	26.17	53.02	17.06	118.58	27.66	68.32	17.15	55.14
SVR	15.58	48.30	13.93	36.31	12.32	83.11	19.77	54.44	13.27	40.95
LSTM	12.07	49.07	15.07	36.49	10.24	80.63	17.03	49.72	13.18	45.40
GCNGRU	10.39	48.51	12.44	35.32	9.56	75.97	15.83	47.64	13.02	39.74
EMD-GCNGRU	9.90	42.27	10.44	31.82	9.07	71.32	13.51	45.40	11.53	37.28

4 结论

为精准预测轨道站点客流,本研究提出一种基于时频分解与深度学习的站点客流预测方法。受站点区位影响,站点间客流时序有所差异,本研究以连续一周站点客流时序为依据,采用 DTW 作为度量并通过 K-means 算法将站点分为 5 类:办公就业型、密集居住型、休闲娱乐型、偏远居住型和职住均衡型。在分析各类站点客流时序特征的基础上,分别预测各类站点客流量。

为弱化原始数据中的噪声影响,采用 EMD 法对原始站点客流序列进行时频分解,将分解后的分量输入所构建的图卷积门控单元模型以实现客流的预测,其中图卷积和门控单元分别用来捕捉站点客流间的空间相关性与时间依赖性。试验结果表明,所提方法具有较高的预测精度,优于 ARIMA、SVR、LSTM 和 GCNGRU 模型。后续可以进一步探究气温和降雨等外部因素对站点客流预测的影响。

参考文献:

[1] 徐成永,叶轩,宣晶. 轨道交通运行效果评估、客流特征分析和对策研究[J]. 都市轨道交通, 2019, 32(6): 44-50.
 XU Chengyong, YE Xuan, XUAN Jing, et al. Operational evaluation, characteristic analysis and development strategy of urban rail transit in Beijing[J]. Urban Rapid Rail Transit, 2019, 32(6): 44-50.

[2] 赵阳阳,夏亮,江欣国. 基于经验模态分解与长短时记忆神经网络的短时地铁客流预测模型[J]. 交通运输工程学报, 2020, 20(4): 194-204.
 ZHAO Yangyang, XIA Liang, JIANG Xinguo. Short-term metro passenger flow prediction based on EMD-LSTM[J]. Journal of Traffic and Transportation Engineering, 2020, 20(4): 194-204.

[3] 邵滢宇,丁柏群. 基于聚类分析的地铁站点分类:以哈尔滨地铁 1 号线为例[J]. 森林工程, 2015, 31(3): 106-111.
 SHAO Yingyu, DING Boqun. Metro stations classification based on clustering analysis; a case study of Harbin metro line 1[J]. Forest Engineering, 2015, 31(3): 106-111.

- [4] 傅搏峰, 吴娇蓉, 陈小鸿. 郊区轨道站点分类方法研究[J]. 铁道学报, 2008, 30(6): 19-23.
FU Bofeng, WU Jiaorong, CHEN Xiaohong. Method of classification of suburban rail transit station sites[J]. Journal of the China Railway Society, 2008, 30(6): 19-23.
- [5] KIM M K, KIM S P, HEO J, et al. Ridership patterns at subway stations of Seoul capital area and characteristics of station influence area[J]. KSCE Journal of Civil Engineering, 2017, 21(3): 964-975.
- [6] 尹芹, 孟斌, 张丽英. 基于客流特征的北京地铁站点类型识别[J]. 地理科学进展, 2016, 35(1): 126-134.
YIN Qin, MENG Bin, ZHANG Liying. Classification of subway stations in Beijing based on passenger flow characteristics[J]. Progress in Geography, 2016, 35(1): 126-134.
- [7] 李海林, 张丽萍. 时间序列数据挖掘中的聚类研究综述[J]. 电子科技大学学报, 2022, 51(3): 416-424.
LI Hailin, ZHANG Liping. Summary of clustering research in time series data mining[J]. Journal of University of Electronic Science and Technology of China, 2022, 51(3): 416-424.
- [8] 王会青, 孙宏伟, 张建辉. 基于 Map/Reduce 的时间序列相似性搜索算法[J]. 山东大学学报(工学版), 2016, 46(1): 15-21.
WANG Huiqing, SUN Hongwei, ZHANG Jianhui. Time series similarity searching algorithm based on Map/Reduce[J]. Journal of Shandong University (Engineering Science), 2016, 46(1): 15-21.
- [9] 朱才华, 孙晓黎, 李培坤, 等. 融合车站分类和数据降噪的城市轨道交通短时客流预测[J]. 铁道科学与工程学报, 2022, 19(8): 2182-2192.
ZHU Caihua, SUN Xiaoli, LI Peikun, et al. Short-term urban rail transit passenger flow prediction based on incorporating station classification and data noise reduction[J]. Journal of Railway Science and Engineering, 2022, 19(8): 2182-2192.
- [10] NI M, HE Q, GAO J. Forecasting the subway passenger flow under event occurrences with social media[J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 18(6): 1623-1632.
- [11] 杨军, 侯忠生. 一种基于灰色马尔科夫的大客流实时预测模型[J]. 北京交通大学学报, 2013, 37(2): 119-123.
YANG Jun, HOU Zhongsheng. A grey Markov based on large passenger flow real-time prediction model[J]. Journal of Beijing Jiaotong University, 2013, 37(2): 119-123.
- [12] 刘美琪, 焦朋朋, 孙拓. 城市轨道交通进站客流量短时预测模型研究[J]. 城市轨道交通研究, 2015, 18(11): 13-17.
LIU Meiqi, JIAO Pengpeng, SUN Tuo. On short-term forecasting model of passenger flow in urban rail transit[J]. Urban Mass Transit, 2015, 18(11): 13-17.
- [13] 冯树民, 刘浩, 李来成. 雨雪天气下轨道交通客流预测模型[J]. 哈尔滨工业大学学报, 2022, 54(9): 1-6.
FENG Shumin, LIU Hao, LI Laicheng. Prediction model of rail transit passenger flow in rain and snow weather[J]. Journal of Harbin Institute of Technology, 2022, 54(9): 1-6.
- [14] 丁聪, 倪少权, 吕红霞. 基于梯度提升的城市轨道交通客流量预测分析[J]. 城市轨道交通研究, 2018, 21(9): 60-63.
DING Cong, NI Shaoquan, LÜ Hongxia. Forecast and analysis of urban rail transit passenger flow based on gradient boosting[J]. Urban Mass Transit, 2018, 21(9): 60-63.
- [15] 刘晓磊, 段征宇, 余庆, 等. 基于图卷积循环神经网络的城市轨道交通客流预测[J]. 华南理工大学学报(自然科学版), 2022, 50(3): 21-27.
LIU Xiaolei, DUAN Zhengyu, YU Qing, et al. Passenger flow forecast of urban rail transit based on graph convolution and recurrent neural network[J]. Journal of South China University of Technology (Natural Science Edition), 2022, 50(3): 21-27.
- [16] 温惠英, 张东冉, 陆思园. GA-LSTM 模型在高速公路交通流预测中的应用[J]. 哈尔滨工业大学学报, 2019, 51(9): 81-87.
WEN Huiying, ZHANG Dongran, LU Siyuan. Application of GA-LSTM model in highway traffic flow prediction[J]. Journal of Harbin Institute of Technology, 2019, 51(9): 81-87.
- [17] YUAN X, HUANG B, WANG Y, et al. Deep learning-based feature representation and its application for soft sensor modeling with variable-wise weighted SAE[J]. IEEE Transactions on Industrial Informatics, 2018, 14(7): 3235-3243.
- [18] 王金水, 欧雪雯, 陈俊岩, 等. 基于组合模型的城市轨道交通站点短时客流分类预测[J/OL]. 铁道科学与工程学报. (2022-09-22) [2022-10-30]. <https://kns.cnki.net/kcms/detail/43.1423.U.20220919.1928.015.html>.
- [19] 田秀娟, 于德新, 邢雪, 等. 交叉口短时流量 CEEMDAN-PE-OSELM 预测模型[J]. 哈尔滨工业大学学报, 2018, 50(3): 83-89.
TIAN Xiujian, YU Dexin, XING Xue, et al. Prediction model of CEEMDAN-PE-OSELM for intersections short-term traffic flow[J]. Journal of Harbin Institute of Technology, 2018, 50(3): 83-89.