文章编号：1003-1421(2026)11-0138-11
引用格式：邹丹，唐博宇，操建中，等. 融合小波降噪和改进LSTM的铁路短期客流预测[J]. 铁道运输与经济，2026，48(11)：138-148.
ZHOU Dan，TANG Boyu，CAO Jianzhong，et al. Short-Term Railway Passenger Flow Forecast Based on Wavelet Denoising and Improved LSTM[J]. Railway Transport and Economy，2026，48(11)：138-148.

融合小波降噪和改进LSTM的铁路短期客流预测

邹　丹[1]，唐博宇[2]，操建中[2]，吴　江[1]，王建强[2,3]

(1.中国铁道科学研究院集团有限公司 电子计算技术研究所，北京　100081；2.兰州交通大学 交通运输学院，甘肃 兰州　730070；3.兰州交通大学 高原铁路运输智慧管控铁路行业重点实验室，甘肃 兰州　730070)

摘　要：为提升铁路短期客流预测的精度，研究提出一种融合时间序列季节特征聚类、小波降噪与改进LSTM网络模型的WT-改进LSTM预测模型。首先，基于客流时间序列的季节性特征，采用K-means聚类算法对月份进行季节类别划分；其次，对各类序列选取最优小波基进行多尺度分解与自适应阈值降噪；最后，构建改进LSTM网络，针对不同类别的客流分别建模。以兰州局集团公司2015—2024年旅客发送量为数据基础开展实证分析，结果显示，WT-改进LSTM预测模型在3类客流类型中的平均MAPE分别为1.62%，5.88%，4.58%，均优于其他模型；模型整体预测误差为5.08%，相比未分类建模的改进LSTM模型(15.1%)，SARIMA模型(16.2%)，SVM(14.91%)和BP神经网络(13.77%)，均实现了明显的误差降低，验证了季节聚类与小波降噪在提升客流预测性能方面的有效性。

关键词：铁路短期客流预测；小波变换；K-means聚类；改进LSTM网络模型；时间序列季节特征
中图分类号：U293.1+3　　**文献标识码**：A　　**DOI**：10.16668/j.cnki.issn.1003-1421.20250727001

Short-Term Railway Passenger Flow Forecast Based on Wavelet Denoising and Improved LSTM

ZHOU Dan[1]，TANG Boyu[2]，CAO Jianzhong[2]，WU Jiang[1]，WANG Jianqiang[2,3]

(1. Institute of Computing Technologies, China Academy of Railway Sciences Corporation Limited, Beijing 100081, China; 2. School of Traffic and Transportation, Lanzhou Jiaotong University, Lanzhou 730070, Gansu,China; 3. Key Laboratory of Railway Industry on Plateau Railway Transportation Intelligent Management and Contral, Lanzhou Jiaotong University, Lanzhou 730070, Gansu, China)

Abstract: To enhance the accuracy of short-term railway passenger flow forecast, a WT-Improved LSTM forecast model that combines seasonal characteristics clustering of time series, wavelet denoising, and an improved LSTM network was proposed. First, based on the seasonal characteristics of the passenger flow time series, the K-means clustering algorithm was used to categorize months into seasonal groups. Next, the optimal wavelet basis was chosen for different series to conduct multi-scale decomposition and adaptive threshold denoising. Finally, an improved LSTM network was built and modelled for different types of passenger flows. An empirical analysis was carried out using passenger dispatch data from China Railway Lanzhou Group Co., Ltd. from 2015 to 2024. The results

收稿日期：2025-07-27
通信作者：王建强(1980—)，男，山东临沂人，兰州交通大学交通运输学院教授。
基金项目：中国国家铁路集团有限公司科技研究开发计划课题(N2023S022)

show that the average MAPE (mean absolute percentage error) of the WT-improved LSTM forecast model for the three types of passenger flow is 1.62%, 5.88%, and 4.58%, respectively, all outperforming other models. The overall forecast error of the model is 5.08%, which achieves significant error reduction compared to the improved LSTM model without classification (15.1%), SARIMA model (16.2%), SVM (14.91%), and BP neural network (13.77%). The effectiveness of seasonal clustering and wavelet denoising in enhancing the performance of passenger flow forecast is verified.
Keywords: Short-Term Railway Passenger Flow Forecast; Wavelet Transform; K-means Clustering; Improved LSTM Network Model; Seasonal Characteristics of Time Series

0　引言

随着我国铁路运输网络的持续扩展与客运服务水平的不断提升，铁路客运量呈现出逐年攀升的趋势，客流需求表现出高频波动、节假日效应显著以及区域性差异明显等特点。这种复杂多变的客流特性对铁路运输组织、运力资源配置及运营决策提出了更高要求。为实现客运资源的优化配置、提升服务质量以及制定科学合理的运营策略，开展铁路短期客流预测研究具有重要的现实意义。

在现有研究中，铁路客流预测模型大体可以归纳为3类：参数型、非参数型与混合型方法。参数型方法常用的有时间序列分析、回归分析以及自回归积分移动平均模型(ARIMA)[1]等。为改善参数模型预测缺陷，有研究构建小波变换-自回归移动平均(WT-ARMA)组合模型，显著提升了短期客流预测效果[2]。非参数预测模型主要包含支持向量机(SVM)、随机森林(RF)、人工神经网络(ANN)等算法，拥有较强的非线性拟合能力，能够适配复杂客流序列建模场景。然而单一非参数模型易受时序噪声干扰，泛化性能存在不足，部分研究通过聚类预处理、网络结构优化等方式对长短期记忆神经网络(LSTM)进行改进，进一步优化预测性能[3]。混合预测模型依托多模型组合或多阶段处理框架，能够充分融合各类算法在数据降噪、特征提取与时序预测上的优势，进一步提升预测精度。现有混合模型多采用时序分解与深度学习相结合的架构，时序卷积神经网络-长短期记忆网络(TCN-LSTM)、集合经验模态分解-广义支持向量机(EEMD-GSVM)、变分模态分解-长短期记忆网络(VMD-LSTM)等框架相继被提出。该类方法先对原始非平稳客流序列实施分解降噪，再依托深度学习模型开展预测，能够充分挖掘客流多尺度与时变特征，具备良好的预测效果[4-6]。

铁路客流数据受多种外部因素影响，常伴随大量异常值、缺失数据及高频噪声波动。若直接基于原始数据训练LSTM模型，易导致模型学习偏差，从而影响预测的准确性与泛化能力。数据预处理阶段常采用标准差法、孤立森林算法以及小波变换等[7-8]降噪方法，用于提升模型的稳定性与预测精度。其中，小波变换具备良好的时频局部化特性，可对原始客流数据进行多尺度分解，将高频噪声与低频趋势成分有效分离，结合阈值去噪与小波重构过程，有助于抑制随机扰动与突发异常对预测模型性能的不利影响。LSTM模型在处理非线性时间序列建模中具有良好的预测性能，但其在训练阶段易受到超参数设置复杂性及序列长度对网络深度依赖等因素的制约，影响模型的收敛效率与预测效果[9]。因此，对LSTM结构进行优化已成为基于深度学习的客流预测研究的重要方向之一[10]。

综上，现有预测模型难以同时兼顾客流序列的季节性分异规律、噪声干扰抑制与时序非线性特征挖掘。针对上述局限，提出一种融合时间序列季节特征聚类、小波降噪与改进LSTM网络的WT-改进LSTM预测模型，通过差异化建模思路充分挖掘客流时序内在规律，开展铁路短期客流预测研究。

1　方法框架

本研究提出一种融合时间序列季节特征聚类、小波降噪与改进LSTM网络模型的WT-改进LSTM预测模型，通过捕捉铁路客流时序数据的季节性特征并抑制噪声，实现铁路短期客流预测。方法步骤为：①通过K-means聚类算法[11]识别客流时序数据的季节性特征，划分各月份的季节类别；②对预处理后的客流序列做小波分解，按互相关系数匹配最优小波基，经自适应阈值降噪后重构，生成保留核心特征的序列；③基于改进LSTM模型提取非线性

时序关系，完成精确预测。该方法显著提升了预测精度，适用于复杂客流场景。

1.1　时间序列的季节特征聚类

铁路客流随时间变化呈现显著的季节性特征[12]，为实现对铁路客流量的精准预测，需采用聚类算法对全年各月份进行类别划分。聚类分析通过对象固有属性和特定分类规则对样本进行分组。本研究采用K-means聚类算法[11, 13]对月份进行聚类。基于跨年度月度客流时间序列特征作为聚类因子，以增强短期客流预测的基础数据表达能力。

每个数据与聚类中心间的欧式距离计算公式为

$$d\left(x_p,\ \mu_q\right)=\sqrt{\sum_{m=1}^{n}\left(x_{p,\ m}-\mu_{q,\ m}\right)^2} \tag{1}$$

式中：x_p为第p个数据($p=1,\ 2,\ \cdots,\ N$，N为总数据量)；μ_q为第q个聚类中心($q=1,\ 2,\ \cdots,\ k$，k为聚类数)；n为数据的维度；$x_{p,\ m}$，$\mu_{q,\ m}$分别为x_p和μ_q的第m个属性值。

整个数据集的误差平方和(SSE)计算公式为

$$SSE=\sum_{q=1}^{k}\sum_{p\in C_q}\left|x_p-\mu_q\right|^2 \tag{2}$$

式中：C_q为第q个簇。

为消除数据在量纲和尺度上的差异，采用Z-score标准化方法对原始数据进行预处理，引入轮廓系数作为指标，判断不同聚类数k下的聚类质量，从而确定最优聚类数目。对于任意点x_p的轮廓系数$S\left(x_p\right)$为

$$S\left(x_p\right)=\frac{b\left(x_p\right)-a\left(x_p\right)}{\max\left\{a\left(x_p\right),\ b\left(x_p\right)\right\}} \tag{3}$$

式中：$a\left(x_p\right)$为点x_p到簇内其他点的平均距离；$b\left(x_p\right)$为点x_p到相邻近簇中所有点的平均距离。

轮廓系数介于-1到1之间，值越接近1表明聚类结果的紧密度和区分度越佳，分类性能越优。

1.2　小波变换

小波变换通过对铁路客流数据进行分解与重构，可实现降噪处理[4]。其核心原理是将复杂的非平稳时间序列数据分解为不同尺度(频率)和不同时间位置的子信号，从而提取数据中的趋势成分与细节成分。小波变换的关键在于选取合适的小波基函数，并利用该函数将原始信号映射为不同频率尺度和时间位置上的小波系数，从而实现信号的多尺度分解。小波基函数的展开表达式为

$$T_x(a,\ b)=\frac{1}{\sqrt{a}}\int_{-\infty}^{+\infty}x(t)\psi(\overline{\frac{t-b}{a}})\mathrm{d}t=\left\langle x(t),\ \psi_{a,\ b}(t)\right\rangle \tag{4}$$

式中：$a>0$为小波基尺度；$b\in R$为小波基平移量；$x(t)\in L^2(R)$为原始客流信号；$\psi(t)\in L^2(R)$为母小波函数；$\psi_{a,\ b}(t)$为小波基函数。采用能量归一化$\psi_{a,\ b}(t)=a^{-1/2}\psi\left(\frac{t-b}{a}\right)$，使$\left\|\psi_{a,\ b}\right\|_2=\left\|\psi\right\|_2=1$。

母小波函数须满足以下约束。

$$\int_{-\infty}^{+\infty}\psi(t)\mathrm{d}t=0 \tag{5}$$

$$C_\psi=\int_0^{+\infty}\frac{\left|\Psi(\omega)\right|^2}{\omega}\mathrm{d}\omega<\infty \tag{6}$$

式中：$\Psi(\omega)$为$\psi(t)$的傅里叶变换。式(5)为零均值，式(6)为可容许性，保证变换的可逆与稳定。

由于互相关系数能够有效衡量信号之间的相似度，以确保所选小波基能够有效分离信号的主要趋势与噪声。互相关系数通过计算信号间的协方差与标准差，能够更好地捕捉信号的细微变化，同时在时序数据中抑制高频噪声。相比其他相关系数，互相关系数P特别适用于时序数据的分析。因此本研究选取互相关系数P来匹配低频轮廓信号与原始信号，计算公式如下。

$$P=\frac{\mathrm{cov}(x,\ y)}{\delta_x\delta_y}=\frac{\sum_{i=1}^{n}(x_i-\bar{x})(y_i-\bar{y})}{n\cdot\delta_x\delta_y}=\frac{\sum_{i=1}^{n}(x_i-\bar{x})(y_i-\bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i-\bar{x})^2\cdot\sum_{i=1}^{n}(y_i-\bar{y})^2}} \tag{7}$$

式中：P为互相关系数；x为小波基提取的低频轮廓信号；y为原始信号；$\mathrm{cov}(x,\ y)$为两者的协方差；δ_x，δ_y为对应信号的标准差；x_i，y_i为在i处的取值，$\bar{x}$，$\bar{y}$为其均值，n为信号数据点的总数量。

在小波基的选择上，遵循相关性最优原则。通过计算不同小波基与原始信号的互相关系数，选择最大值的小波基，确保最大化信号低频趋势与小波基的匹配，从而优化降噪效果，保留信号主要特征，抑制高频噪声，为后续预测建模提供精准数据输入。

1.3　改进LSTM客流预测模型

1.3.1　LSTM神经网络概述

LSTM旨在缓解传统循环神经网络(RNN)处理长时间序列时的梯度消失与爆炸问题[14]。LSTM通过引入记忆单元和门控机制(包括遗忘门、输入门和输出门)，实现对时序信息的高效存储与动态调控。遗忘门用于判断并筛选需保留的历史信息，输入门决定当前输入对记忆状态的更新程度，而输出门则控制记忆信息向当前隐藏状态的传递过程。借助这一结构，LSTM能够捕捉数据中的长期依赖关系，在时间序列建模中展现出优越的非线性拟合能力，尤其适用于如客流预测等具有显著时序特征的任务。LSTM单元结构如图1所示。

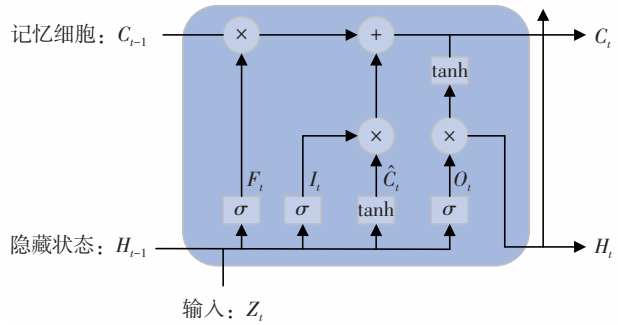


图1　LSTM单元结构

Fig.1　LSTM unit structure

图1中，t为时刻；H_{t-1}为上一序列的隐藏层状态；C_{t-1}为上一时刻的细胞状态；C_t为细胞状态；H_t为输出状态；F_t为遗忘门控单元；I_t为输入门控单元；O_t为输出门控单元；$\hat{C}_t$为候选细胞；σ和tanh为激活函数。

设输入序列Z_t为$(z_1, z_2, \cdots, z_t)$，隐藏层状态为$(h_1, h_2, \cdots, h_t)$，在t时刻有

$$F_t = \sigma(W_f \cdot [H_{t-1}, Z_t] + b_f) \tag{8}$$

$$I_t = \sigma(W_i \cdot [H_{t-1}, Z_t] + b_i) \tag{9}$$

$$O_t = \sigma(W_o \cdot [H_{t-1}, Z_t] + b_o) \tag{10}$$

$$\hat{C}_t = \tanh(W_c \cdot [H_{t-1}, Z_t] + b_c) \tag{11}$$

$$C_t = F_t \cdot C_{t-1} + I_t \cdot \hat{C}_t \tag{12}$$

$$H_t = O_t \cdot \tanh(C_t) \tag{13}$$

式中：f_i，i_t，o_i分别为遗忘门控制单元，输入门控制单元和输出门控制单元；W_f，W_i，W_o，W_c为递归连接的权重；$(h_1, h_2, \cdots, h_t)$为隐藏状态；x_i为输入信息；b_f，b_i，b_o，b_c为函数的偏置；C_t，C_{t-1}为隐藏层的输出层。

1.3.2　改进LSTM网络模型

神经网络深度受记忆单元数量影响，而记忆单元又依赖于输入划分的尺度，尺度过大会限制模型深度，影响预测性能[15]。为提升特征提取能力，在输入层后引入全连接层，以增强网络非线性表达与特征整合能力。该全连接层与LSTM层权重一致，实现更紧密的信息交互与特征融合，从而提升模型对复杂时序数据的表征效果。改进LSTM短期客流预测模型框架如图2所示。

1.3.3　模型训练

（1）划分训练集和测试集。针对不同类别的客流数据，按照时间序列进行分段分割，得到训练样本集，记为S_{train}，验证样本集，记为S_{val}。

（2）数据归一化处理。为加快模型收敛速度并避免数据量级差异对训练的干扰，采用归一化方法将训练数据映射至[−1，1]区间。具体计算公式如下。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{14}$$

式中：x'为归一化后的值；x为当前样本数据；$x_{\max}$，$x_{\min}$分别为样本最大值和最小值。

（3）初始化与迭代训练。初始化网络模型参数后，将训练集数据输入模型生成预测结果，通过损失函数计算预测值与真实值的偏差。若误差超出预设阈值，采用时域反向传播算法结合自适应矩估计(Adam)优化器动态调整网络权重，同时引入学习率衰减机制，避免训练过程中出现震荡。

（4）中间验证与参数调优。每完成50轮迭代，使用验证集对模型进行中间评估，对比预测结果与真实数据的偏差。若连续3次验证误差无明显下降，则提前终止训练以防止过拟合；否则，继续迭代直至损失函数收敛至稳定范围。误差函数计算公式如下。

$$E = \frac{1}{n}\sum_{i=1}^{n}\left|y_i - \hat{y}_i\right| \tag{15}$$

式中：s为误差值；y_i为真实值；$\hat{y}_i$为预测值。

（5）参数调优与验证。使用测试集对训练完成的模型进行性能评估，对比预测结果与真实数据的偏差。若误差满足精度要求，则确定模型参数；否则，返回训练阶段重新调整网络结构或优化算法参数，直至模型达到预期预测效果。

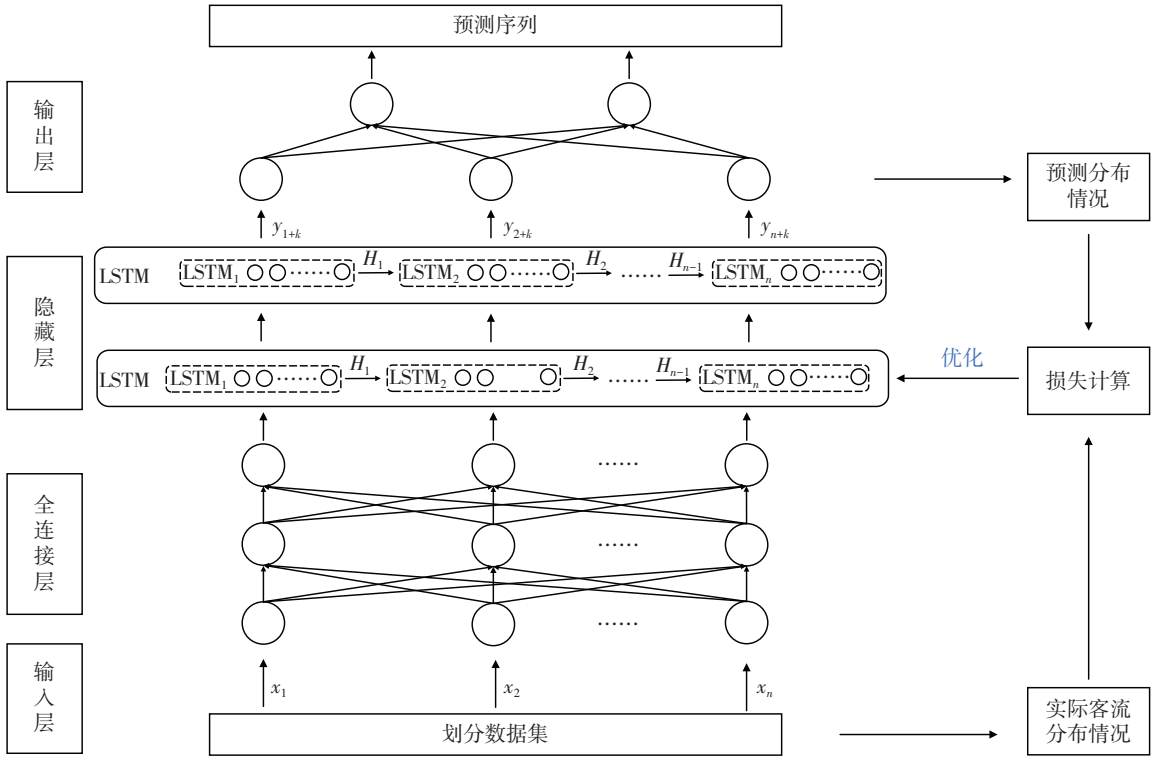


图2　改进LSTM短期客流预测模型框架

Fig.2　Improved LSTM short-term passenger flow forecast model framework

2　实例分析

2.1　数据采集与特征分析

以中国铁路兰州局集团有限公司2015年1月至2024年7月的旅客发送量月度数据序列为例进行实例分析，其原始客流数据如图3所示。由图3可见，旅客发送量的月度时间序列呈现出显著的周期性特征。各年份中相同月份的客流走势高度一致，体现出明显的年度循环规律。每年客流曲线的波峰与波谷集中在特定月份，受季节变化和节假日等因素影响，呈现规律性波动。不同月份在客流规模和波动趋势上存在明显差异，说明季节性对客流行为具有重要影响。基于此，在预测前采用聚类方法对月份进行分组，有助于提升数据结构表达力和模型对周期规律的适应性，从而提高预测精度。

为开展相关分析与预测，基于数据的周期性特点，选取2015年1月至2023年12月的月旅客发送量数据作为训练样本数据，用于模型训练等环节，以学习客流的周期性及趋势等规律；选取2024年1—7月的月旅客发送量数据作为测试数据集，用于验证模型在新数据上的预测效果，以此评估模型训练效果。

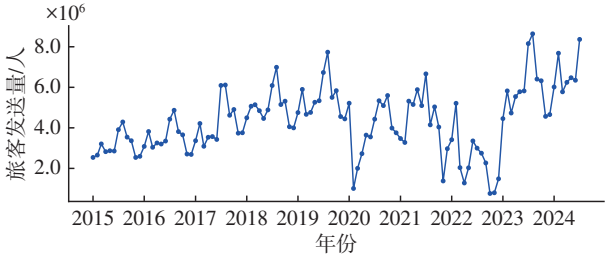


图3　原始客流数据

Fig.3　Original passenger flow data

2.2　季节类型识别结果

不同聚类数对应的轮廓系数如图4所示，聚类数为3时轮廓系数最大，因此确定聚类数目为3。不同类别客流聚类结果如表1所示，展示了各月份的聚类结果，其中“类别”表示每个月份的聚类归属，“距离”则衡量其与对应簇中心的相似程度，距离越小，说明该月份在该类别中的代表性越强。

不同类别客流聚类结果如图5所示，展示了不同类别月份的旅客发送量在年度维度下的变化趋势。

（1）第Ⅰ类。该类客流月份包括年初与年末的1月、11月和12月，月度客流量规模约为254万~602万人，月均383万人，在3类客流中处于中等水

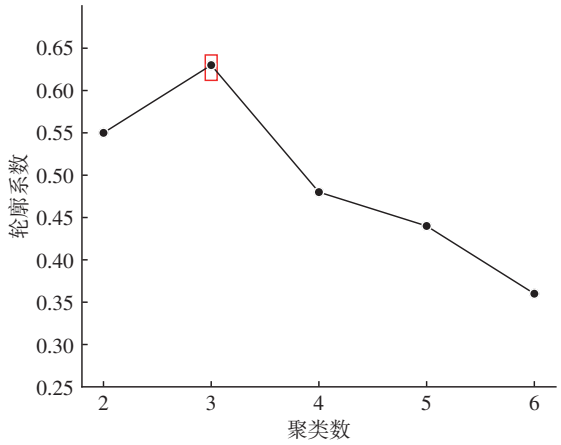


图4　不同聚类数对应的轮廓系数

Fig.4　Contour coefficients corresponding to different numbers of clusters

表1　不同类别客流聚类结果

Tab.1　Clustering results of different types of passenger flows

月份	聚类		月份	聚类		月份	聚类	
	类别	距离		类别	距离		类别	距离
1月	Ⅰ	1.119 5	5月	Ⅱ	1.187 8	9月	Ⅱ	1.908 0
2月	Ⅱ	2.374 8	6月	Ⅱ	0.672 1	10月	Ⅱ	2.265 9
3月	Ⅱ	1.877 7	7月	Ⅲ	1.344 7	11月	Ⅰ	0.960 4
4月	Ⅱ	1.049 0	8月	Ⅲ	1.344 7	12月	Ⅰ	0.628 6

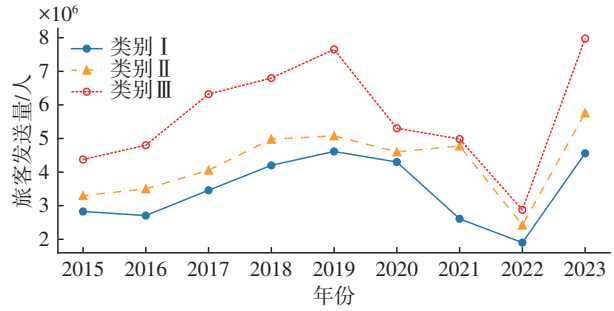


图5　不同类别客流聚类结果

Fig.5　Clustering results of different types of passenger flows

平。其年际波动幅度较小：2015年至2024年，1月由254万人增至602万人，波动幅度约348万人；11月和12月的波动幅度分别为203万人和207万人，该类月份的波动幅度低于其他类别的客流。该类月份受春运探亲流和年底出行需求影响，季节重复性强，不同年份之间走势高度一致，体现出较强的规律性。

（2）第Ⅱ类。该类客流月份包括春秋季节及其过渡时段的2—6月及9—10月，月度客流量介于266万~763万人之间，月均约430万人，在3类客流中属于中等偏高水平。该类客流的年际波动幅度最为显著，2015年至2024年，2月从266万人增至768万人，差值高达502万人；其他月份波动幅度多集中在150万~300万人。该类客流月份规律性较强，受节假日安排和外部环境扰动影响，客流水平在不同年份之间起伏明显。

（3）第Ⅲ类。该类客流月份包括7—8月对应的暑运高峰，月度客流量规模在392万~864万人，月均达到644万人，为3类客流中的最高水平。其年际波动幅度处于中等偏高水平，2015年至2024年，7月波动约444万人，8月波动约435万人，不同年份间客流量差异明显。该类月份主要受学生流和旅游流的共同影响，客流量较大，且持续时间较长。整体而言，该类客流虽然波动较大，但与暑运规律高度吻合。

2.3　季节类型识别结果

由于各月份客流特性不同，需根据小波基与原始信号的匹配程度选择合适的小波系。综合正交性、支持长度等因素，选取5种小波系作为候选。小波系与不同类别客流的互相关系数如表2所示，互相关分析表明，类别Ⅰ采用Biorthogonal小波系，类别Ⅱ和Ⅲ采用Haar小波系。类别Ⅰ小波分解图如图6所示，类别Ⅱ小波分解图如图7所示，类别Ⅲ小波分解图如图8所示。降噪时在不同层级设定阈值，第4至第1层高频系数的阈值分别为80%，60%，40%，20%，以保留波动特征。

表2　小波系与不同类别客流的互相关系数

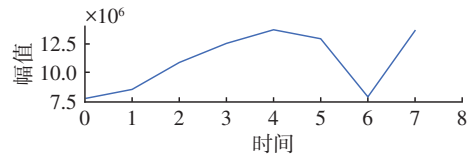
Tab.2　Cross-correlation coefficients between wavelet coefficients and different types of passenger flows

小波系	月份类别		
	Ⅰ	Ⅱ	Ⅲ
Haar	1.058 3	1.003 4	1.031 5
Daubechies	1.055 5	0.999 9	0.890 0
Biorthogonal	1.060 8	1.001 2	1.012 1
Symlets	1.055 5	0.913 3	1.025 6
ReverseBior	1.056 8	1.001 2	1.030 1

原始客流信号通过小波重构恢复原始趋势，增强对短期波动的识别，并有效去除噪声。原始信号与降噪处理后结果对比如图9所示。

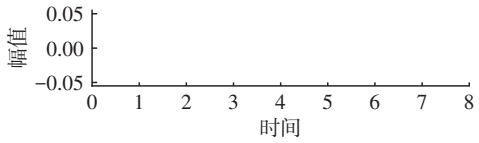
2.4　WT-改进LSTM模型预测结果分析

根据2.2节对原始客流序列的聚类结果，将客流按月份划分为3类具有不同时序特征的客流类型。针对每一类客流的特性，分别构建并训练独立



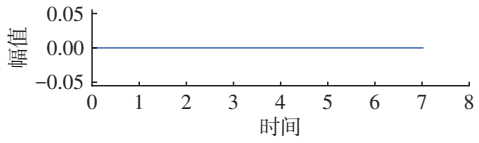
a　类别Ⅰ客流原始信号

a　Original signal of passenger flow of Category Ⅰ



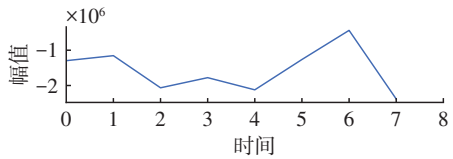
b　类别Ⅰ客流细节系数第4层

b　Passenger flow detail coefficient level 4 of Category Ⅰ



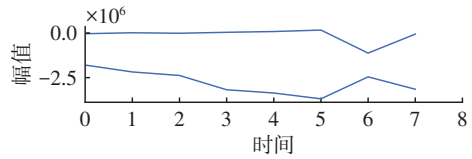
c　类别Ⅰ客流细节系数第3层

c　Passenger flow detail coefficient level 3 of Category Ⅰ



d　类别Ⅰ客流细节系数第2层

d　Passenger flow detail coefficient level 2 of Category Ⅰ

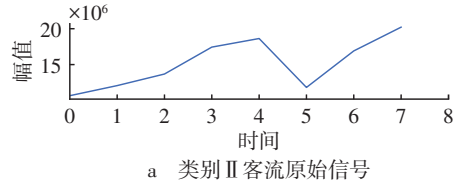


e　类别Ⅰ客流细节系数第1层

e　Passenger flow detail coefficient level 1 of Category Ⅰ

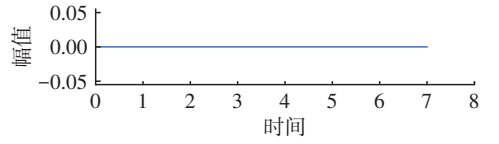
图6　类别Ⅰ小波分解图

Fig.6　Wavelet decomposition of Category Ⅰ



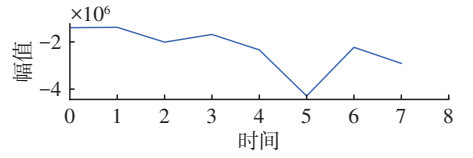
a　类别Ⅱ客流原始信号

a　Original signal of passenger flow of Category Ⅱ



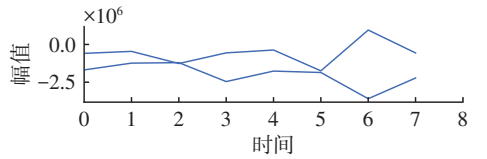
b　类别Ⅱ客流细节系数第4层

b　Passenger flow detail coefficient level 4 of Category Ⅱ



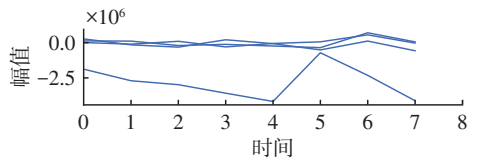
c　类别Ⅱ客流细节系数第3层

c　Passenger flow detail coefficient level 3 of Category Ⅱ



d　类别Ⅱ客流细节系数第2层

d　Passenger flow detail coefficient Level 2 of Category Ⅱ



e　类别Ⅱ客流细节系数第1层

e　Passenger flow detail coefficient level 1 of Category Ⅱ

图7　类别Ⅱ小波分解图

Fig.7　Wavelet decomposition of Category Ⅱ

的改进LSTM网络模型，以提高对不同波动模式的适应能力与预测精度。

改进后的LSTM模型在参数设置上包括网络深度、输入输出维度、神经元的数量、损失函数设定以及训练轮数等。训练过程中，设定初始学习率范围为0.01至0.001，并采用固定学习率策略，以避免因学习率过大引发的训练不稳定，从而保障参数更新过程的平稳性。同时，结合Adam优化器的自适应机制，使模型在500次迭代内实现损失函数的平滑收敛。针对不同类别的客流数据，分别调整网络结构与参数配置，以增强模型对各类时序特征的拟合能力。为评估改进后的LSTM模型的预测效果，选取平均绝对误差(MAE)、平均绝对百分误差(MAPE)和均方根误差(RMSE)作为性能评价指标，其具体计算公式如下所示。

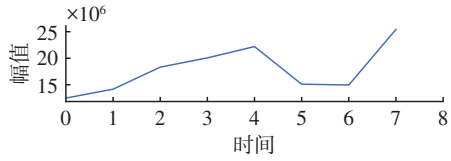
$$MAE = \frac{1}{s}\sum_{i=1}^{s}\left|\hat{y}_i - y_i\right| \tag{16}$$

$$MAPE = \frac{100\%}{s}\sum_{i=1}^{s}\left|\frac{\hat{y}_i - y_i}{y_i}\right| \tag{17}$$

$$RMSE = \sqrt{\frac{1}{s}\sum_{i=1}^{s}\left(\hat{y}_i - y_i\right)^2} \tag{18}$$

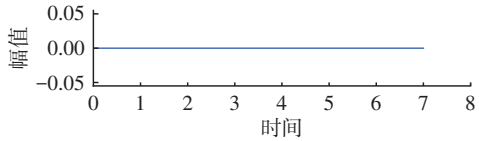
式中：s为数据集中的样本数；$\hat{y}_i$与y_i分别为第i个样本的预测值与实际值。

为便于分类建模结果与整体建模结果进行比较，本研究将聚类建模后的总体月均评价指标按每类的月份数加权汇总，计算公式如下。



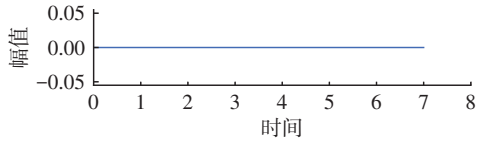
a　类别Ⅲ客流原始信号

a　Original signal of passenger flow of Category Ⅲ



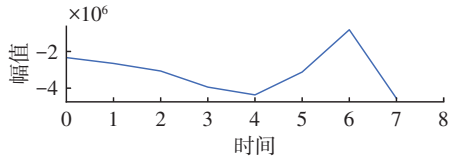
b　类别Ⅲ客流细节系数第4层

b　Passenger flow detail coefficient level 4 of Category Ⅲ



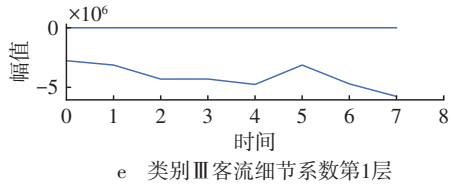
c　类别Ⅲ客流细节系数第3层

c　Passenger flow detail coefficient level 3 of Category Ⅲ



d　类别Ⅲ客流细节系数第2层

d　Passenger flow detail coefficient level 2 of Category Ⅲ



e　类别Ⅲ客流细节系数第1层

e　Passenger flow detail coefficient level 1 of Category Ⅲ

图8　类别Ⅲ小波分解图

Fig.8　Wavelet decomposition of Category Ⅲ

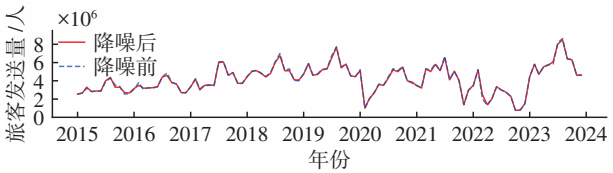


图9　原始信号与降噪处理后结果对比

Fig.9　Comparisonof original passenger flow signals and denoised results

$$MAE_{\text{overall}} = \sum_c \frac{n_c}{N} MAE_c \tag{19}$$

$$MAPE_{\text{overall}} = \sum_c \frac{n_c}{N} MAPE_c \tag{20}$$

$$RMSE_{\text{overall}} = \sqrt{\sum_c \frac{n_c}{N} RMSE_c^2} \tag{21}$$

式中：n_c表示类别c的月份数；N表示所有类别的总月份数；MAE_c，$MAPE_c$，$RMSE_c$分别为类别c的月均绝对误差、月均百分比误差、月均均方根误差。

WT-改进LSTM模型预测结果如图10所示，各模型在不同客流类别下的预测误差评价指标如表3所示，具体分析如下。

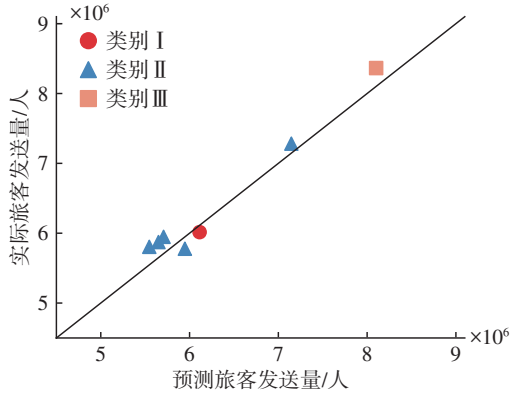


图10　WT-改进LSTM模型预测结果

Fig.10　Forecast results of WT-improved LSTM model

（1）类别Ⅰ客流预测结果分析。该类客流波动稳定、趋势一致，噪声干扰较少，预测曲线与实际基本吻合，误差约为1.6%。采用Biorthogonal小波基降噪，有效保留核心趋势。改进LSTM引入全连接层，提升了对周期信号的提取能力，预测误差波动较小，整体精度较高。

（2）类别Ⅱ客流预测结果分析。该类客流波动中等，呈多峰特征，伴有部分突发扰动。模型能较好把握整体趋势，局部峰值略有偏差，平均误差为5.88%。采用Haar小波基降噪，保留有效高频信息并抑制噪声。改进LSTM通过全连接层增强了对局部波动的响应能力，预测精度与稳定性较好。

（3）类别Ⅲ客流预测结果分析。该类客流波动剧烈、峰值频繁且强度不一，噪声与有效信号重叠明显。模型整体拟合较好，峰值存在一定误差，平均误差为4.58%。采用Haar小波多尺度降噪，提升了高频特征提取能力。改进LSTM通过深层结构增强了对多峰时序的记忆能力，提升了对复杂客流的拟合效果。

2.5　WT-改进LSTM模型预测效果对比分析

为验证WT-改进LSTM模型的性能，选取改进LSTM，SARIMA，SVM模型和BP神经网络作为对比模型，分别在是否进行月份聚类建模的条件下进行实验。图10展示了WT-改进LSTM模型预测结

表3　各模型在不同客流类别下的预测误差评价指标

Tab.3　Evaluation indicators of prediction errors for each model under different passenger flow categories

模型	类别	MAE	MAPE/%	RMSE
WT-改进LSTM	Ⅰ	97 618.3	1.62	97 618.3
	Ⅱ	349 648.6	5.88	358 786.2
	Ⅲ	382 866.0	4.58	382 866.0
	月均	318 389.6	5.08	324 916.5
改进LSTM	Ⅰ	334 771.8	5.57	334 771.8
	Ⅱ	754 059.4	12.33	779 465.2
	Ⅲ	722 571.2	8.60	722 571.2
	月均	689 662.9	10.83	707 809.9
SARIMA	Ⅰ	505 012.4	8.39	505 012.4
	Ⅱ	686 654.9	10.85	762 114.6
	Ⅲ	929 961.3	11.12	929 961.3
	月均	695 464	10.53	749 363.8
SVM	Ⅰ	154 995.1	2.49	154 995.1
	Ⅱ	609 842.3	9.56	689 294.5
	Ⅲ	569 881.4	6.03	569 881.4
	月均	539 155.4	8.05	595 907
BP神经网络	Ⅰ	119 654.1	1.99	119 654.1
	Ⅱ	865 471.3	11.05	896 764.6
	Ⅲ	689 723.4	6.86	689 723.4
	月均	733 819.1	9.16	756 171.5
WT-改进LSTM	—	729 989.8	10.87	815 137.5
改进LSTM	—	1 015 704.1	15.1	1 145 702.9
SARIMA	—	1 340 060.3	16.2	1 590 378
SVM	—	1 188 503.0	14.91	1 344 664.9
BP神经网络	—	909 932.5	13.77	1 023 831.6

果，表3列出了各类客流的误差指标。图11为不同模型预测误差对比，各模型的MAE，MAPE和RMSE指标按式(16)—(18)由预测值与真实值计算得出。结果表明，WT-改进LSTM拟合效果最佳，在所有指标上均优于其他模型，表现出显著优势。

（1）季节聚类建模效果分析。结果表明，按季节特征聚类后，各模型的预测精度均有提升。改进LSTM聚类建模后月均MAE降至68.97万，MAPE降为10.83%，优于未聚类时的101.57万和15.1%。SARIMA模型也有类似改善，聚类后MAPE降至11.60%。同时，SVM和BP神经网络的聚类效果亦得到提升：SVM模型的MAPE由14.91%降至8.05%，BP神经网络的MAPE由13.77%降至9.16%。由此可见，针对不同季节特征分别建模，能够更准确捕捉时序规律，避免单一模型对复杂数据的平均化处理，提高预测精度。

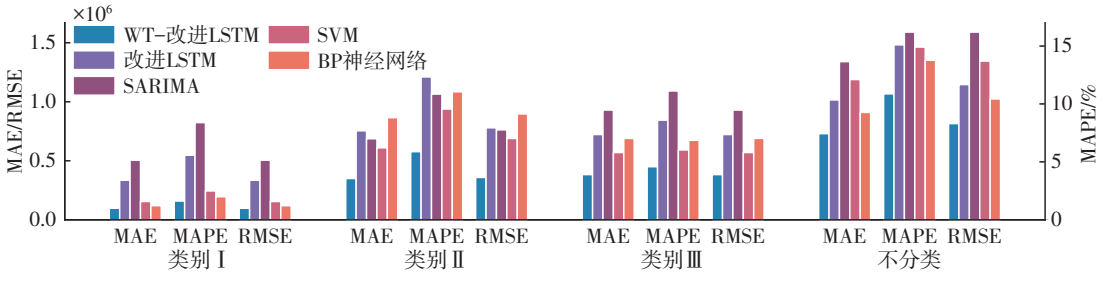


图11　不同模型预测误差对比

Fig.11　Comparison of prediction errors of different models

（2）小波降噪的效果分析。在季节聚类的基础上，WT-改进LSTM模型在3类客流预测中均表现最佳。其中，第Ⅰ类MAPE为1.62%，第Ⅱ类和第Ⅲ类分别为5.88%和4.58%，明显优于未降噪模型。模型总体MAPE为5.08%，低于不降噪时的10.83%。这表明小波降噪在提取有效信息、抑制干扰方面成效显著，增强了模型对高频波动和突发异常的适应能力。

综上所述，季节聚类与小波降噪在铁路客流预测中均具有显著效果，WT-改进LSTM模型在多类客流下实现了最优预测，验证了该方法在应对非平稳、多样性数据序列中的有效性与实用价值。

3　结论

（1）针对铁路客流显著的季节性差异性，提出以月份为单位进行聚类建模，将全年客流按月份划分为Ⅰ，Ⅱ，Ⅲ 3类客流类型。该分类策略使模型能够针对不同类别的时序结构分别建模，显著提升了对复杂周期性与多样波动模式的适应能力。

（2）针对不同类别客流的波动特性，分别选取最优小波基进行多尺度分解与自适应阈值降噪处理，从而有效降低高频扰动与异常点对模型训练的影响，提升了输入数据的平稳性与主趋势表达能力，提高了数据质量。

（3）针对客流的季节性差异，采用K-means对月份进行聚类，划分为3类客流类型。实验结果显示，分类建模显著提升了模型的适应性与精度，WT-改进LSTM在3类客流中的MAPE均低于6%，有效避免了单一模型对复杂数据的平均化处理。

（4）在分类建模的基础上引入小波降噪，使模型能够更好地应对高频干扰与异常波动。WT-改进LSTM的平均MAPE由10.83%降至5.08%，显著低于改进LSTM，SARIMA，SVM和BP神经网络等对比模型。以上结果表明，小波降噪能够有效提升输入数据质量，增强模型的稳定性与预测能力，从而在复杂非平稳客流序列下展现出更优的适应性。

参考文献：

[1] 李　洁，彭其渊，杨宇翔. 基于SARIMA模型的广珠城际铁路客流量预测[J]. 西南交通大学学报，2020，55(1)：41-51.
LI Jie，PENG Qiyuan，YANG Yuxiang. Passenger Flow Prediction for Guangzhou-Zhuhai Intercity Railway Based on SARIMA Model[J]. Journal of Southwest Jiaotong University，2020，55(1)：41-51.

[2] 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.

[3] 彭凯贝，白　伟，伍柳伊，等. 基于改进LSTM模型的铁路客运站客流预测研究[J]. 铁道运输与经济，2023，45(4)：53-60.
PENG Kaibei，BAI Wei，WU Liuyi，et al. Research on Method for Prediction of Passenger Flow of Railway Station Based on Improved LSTM Model[J]. Railway Transport and Economy，2023，45(4)：53-60.

[4] 赵利强，李瑞森，唐水雄，等. 基于多维可预知特征的TCN-LSTM城轨短期客流预测[J]. 北京化工大学学报(自然科学版)，2024，51(5)：86-96.
ZHAO Liqiang，LI Ruisen，TANG Shuixiong，et al. Short-Term Urban Rail Passenger Flow Prediction Using Temporal Convolutional Network-Long Short-Term Memory(TCN-LSTM) Based on Multidimensional Predictable Features[J]. Journal of Beijing University of Chemical Technology (Natural Science Edition)，2024，51(5)：86-96.

[5] JIANG X S，ZHANG L，CHEN X. Short-Term Forecasting of High Speed Rail Demand：A Hybrid Approach Combining Ensemble Empirical Mode Decomposition and Gray Support Vector Machine with Real-World Applications in China[J]. Transportation Research Part C：Emerging Technologies，2014，44：110-127.

[6] 苏焕银，彭舒婷，曾琼芳，等. 基于VMD-LSTM混合模型的城际高速铁路时变客流预测[J]. 铁道科学与工程学报，2023(4)：1200-1210.
SU Huanyin，PENG Shuting，ZENG Qiongfang，et al. Forecast of Time-Dependent Passenger Flow of Intercity High Speed Railway Based on VMD-LSTM Mixed Model[J]. Journal of Railway Science and Engineering，2023(4)：1200-1210.

[7] NOTARO V，IESS L，ARMSTRONG J W，et al. Reducing Doppler Noise with Multi-Station Tracking：The Cassini Test

Case[J]. Acta Astronautica，2020，173：45-52.

[8] YIN D，GU Z Z，ZHANG Y R，et al. Speckle Noise Reduction in Coherent Imaging Based on Deep Learning without Clean Data[J]. Optics and Lasers in Engineering，2020，133：106151.

[9] 翁剑成，陈旭蕊，潘晓芳，等. 基于超参数优化WOA-Bi-LSTM模型的客运枢纽抵站客流预测方法[J]. 交通信息与安全，2023，41(5)：148-157.
WENG Jiancheng，CHEN Xurui，PAN Xiaofang，et al. A Forecasting Method for Arrival Passenger Flow Based on Hyperparametric Optimization WOA-Bi-LSTM Model for Passenger Hubs[J]. Journal of Transport Information and Safety，2023，41(5)：148-157.

[10] 熊章友，李卫军，朱晓娟，等. 基于深度学习的短时交通流预测研究综述[J]. 计算机工程与应用，2025，61(11)：67-82.
XIONG Zhangyou，LI Weijun，ZHU Xiaojuan，et al. Short-Term Traffic Flow Prediction Based on Deep Learning[J]. Computer Engineering and Applications，2025，61(11)：67-82.

[11] LI D，ZHAO Y F，LI Y. Time-Series Representation and Clustering Approaches for Sharing Bike Usage Mining[J]. IEEE Access，2019，7：177856-177863.

[12] 孙晓黎，朱才华，李美妮，等. 时间序列聚类下的城市轨道交通客流预测研究[J]. 铁道运输与经济，2023，45(3)：149-157.
SUN Xiaoli，ZHU Caihua，LI Meini，et al. Research on Passenger Flow Prediction of Urban Rail Transit Based on Time Sequence Clustering[J]. Railway Transport and Economy，2023，45(3)：149-157.

[13] 陈维亚，潘　鑫，方晓平. 基于K-means聚类组合模型的公交线路客流短时预测[J]. 华南理工大学学报(自然科学版)，2019，47(4)：83-89，113.
CHEN Weiya，PAN Xin，FANG Xiaoping. Short-Term Prediction of Passenger Flow on Bus Routes Based on K-means Clustering Combination Models[J]. Journal of South China University of Technology (Natural Science Edition)，2019，47(4)：83-89，113.

[14] 白　丽. 城市轨道交通常态与非常态短期客流预测方法研究[J]. 交通运输系统工程与信息，2017，17(1)：127-135.
BAI Li. Urban Rail Transit Normal and Abnormal Short-Term Passenger Flow Forecasting Method[J]. Journal of Transportation Systems Engineering and Information Technology，2017，17(1)：127-135.

[15] JIAO P P，LI R M，SUN T，et al. Three Revised Kalman Filtering Models for Short-Term Rail Transit Passenger Flow Prediction[J]. Mathematical Problems in Engineering，2016，2016(1)：9717582.

(责任编辑　汪沁萱)

(上接第137页)

Approach Based on Time-Varying Demand for High Speed Rail under the Combined Operation of Periodic and Aperiodic Services[J]. Computers & Industrial Engineering，2023，185：109665.

[14] 贾　斌，朱　凌，李树凯，等. 城市轨道交通小交路计划与客流控制协同优化策略[J]. 交通运输系统工程与信息，2022，22(1)：124-132.
JIA Bin，ZHU Ling，LI Shukai，et al. Collaborative Optimization Strategy of Short-Turning Plan and Passenger Flow Control in Urban Rail Transit[J]. Journal of Transportation Systems Engineering and Information Technology，2022，22(1)：124-132.

[15] 杨安玉. 低碳视角下城市轨道交通列车交路运行方案优化研究[J]. 铁道运输与经济，2025，47(2)：110-118，160.
YANG Anyu. Optimization of Train Routing Operation Scheme of Urban Rail Transit from the Perspective of Low Carbon[J]. Railway Transport and Economy，2025，47(2)：110-118，160.

[16] 张斯嘉，刘　澜，毛剑楠. 考虑乘客反向换乘的城市轨道交通快慢车停站方案[J]. 铁道运输与经济，2020，42(11)：110-116.
ZHANG Sijia，LIU Lan，MAO Jiannan. Express/Local Train Stop Scheme in Urban Rail Transit Based on Passengers' Reverse Transfer[J]. Railway Transport and Economy，2020，42(11)：110-116.

(责任编辑　魏　然)