【交通物流 / Transportation Logistics】

考虑多属性因素融合的城市轨道交通短时断面客流预测

何明[1]，左静[1]，余召[2]

1）兰州交通大学自动化与电气工程学院，甘肃兰州 730070；2）中车永济电机有限公司，山西运城 044500

摘　要：准确、可靠的短时断面客流预测对于优化运营组织以及提升智能化城市交通管理水平至关重要，由于天气、日期等因素的综合影响，现有的短时断面客流预测模型在捕捉复杂因素时的准确度仍不够高．为提高客流预测精度，利用重力模型构建两站之间的出行引力因子，并结合天气和不同日期影响因素建立多属性客流特征向量；通过构建门控循环单元(gated recurrent unit，GRU)网络完成多属性客流特征向量的时序特征提取，获取断面客流的时间依赖性；结合Transformer的多头自注意力机制，提取不同影响因素与客流时序特征之间的关联特征，并对关联特征权重进行优化；通过粒子群算法对模型的隐含层数、批处理量、学习率及训练轮数等参数进行优化，利用全连接网络实现特征融合及预测．以中国杭州地铁1号线2019年1月客流数据为例对所提方法进行验证，实验结果表明，在10、15和30 min粒度下的模型平均绝对百分比误差值分别为14.96%、15.86%和16.96%，均显著低于对比模型．

关键词：城市交通；断面客流预测；门控循环单元；多头自注意力；Transformer模型；关联特征

中图分类号：U293.13；TP183　　**文献标志码：**A　　**DOI：**10.3724/SP.J.1249.2025.06723

Short-term cross-sectional passenger-flow forecasting for urban rail transit with multi-attribute feature fusion

HE Ming[1], ZUO Jing[1], and YU Zhao[2]

1) School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, Gansu Province, P. R. China

2) China Railway Rolling Stock Yongji Electric Co. Ltd. , Yuncheng 044500, Shanxi Province, P. R. China

Abstract: Accurate and reliable short-term cross-sectional passenger-flow forecasting is essential for optimizing operation strategies and advancing intelligent urban-transport management. However, due to the combined effects of weather, calendar attributes, and other external factors, existing short-term cross-sectional forecasting models still struggle to fully capture complex influencing mechanisms with high accuracy. To improve forecasting accuracy, we first construct an inter-station trip-gravity indicator using the gravity model and incorporates it with weather and calendar attributes to form a multi-attribute passenger-flow feature vector. A gated recurrent unit (GRU) backbone is employed to extract temporal dependencies of cross-sectional flows. Meanwhile, a Transformer equipped with multi-head self-attention is used to capture non-linear interactions between exogenous factors and the GRU-derived temporal features with attention weights learned in an end-to-end manner. Hyper-parameters, including network depth, batch size, learning rate and training epochs, are globally optimised via particle-swarm optimisation, while a

Received: 2024-09-03; **Accepted:** 2025-01-25; **Online** (CNKI)**:** 2025-10-09

Foundation: National Natural Science Foundation of China (52262045); Key R & D Program-Industrial Project of Gansu Province (23YFGA0045)

Corresponding author: Associate professor ZUO Jing (zuojing@mail.lzjtu.cn)

Citation: HE Ming, ZUO Jing, YU Zhao. Short-term cross-sectional passenger-flow forecasting for urban rail transit with multi-attribute feature fusion [J]. Journal of Shenzhen University Science and Engineering, 2025, 42(6): 723-732. (in Chinese)

Open access: This article is licensed under the CC BY 4.0 License (https://creativecommons.org/licenses/by/4.0/).

http://journal.szu.edu.cn

fully-connected layer performs feature fusion and final prediction. Using passenger-flow data from Hangzhou Metro Line 1 in January 2019 as an example, experimental results show that the proposed method achieves mean absolute percentage errors (MAPE) of 14.96%, 15.86% and 16.96% at 10, 15 and 30 minutes intervals, respectively, outperforming benchmark models by a notable margin.

Key words: urban transportation; cross-sectional passenger flow forecast; gated recurrent unit; multi-head self-attention; Transformer model; associated characteristic

城市轨道交通网络的快速发展使得客流量显著增长，高峰时段的客流量呈现出明显波动性，这对实时客运管理和调度带来巨大挑战．2021年发布的《国家综合立体交通网规划纲要》[1]提出推动智慧城轨发展，智能调度作为其中的关键环节，对短时断面客流的实时精准预测提出更高要求[2]．

断面客流预测面临的挑战在于自动售检票(automatic fare collection system，AFC)数据中缺乏具体路径和换乘信息，需通过路径选择预测和客流分配来推算断面流量．刘洋[3]通过清分客流数据，构建基于状态空间模型的关联断面短时预测模型．过秀成等[4]采用多方式概率分配模型将竞争性方式的出行客流量分配至联合交通网络中，完成断面客流量推算．曹凯鑫[5]基于k短路径算法搜索起讫点(origin destination，OD)对之间的有效路径，并结合高斯模型进行客流分配，提取断面客流数据．李亚香等[6]利用历史断面客流数据构建最小二乘支持向量机模型，并采用粒子群算法优化参数与备选函数．张金雷[7]在OD流预测的基础上，构建基于计算图的短时断面客流预测模型，实现短时断面客流预测．

基于OD矩阵的断面预测方法在处理实时数据时存在滞后性，在捕捉跨区间客流动态交互和时空关联特征方面也存在不足．郑乐婧[8]将图卷积神经网络(graph convolutional neural network，GCN)、注意力机制及长短时记忆(long short-term memory，LSTM)网络结合进行短时客流预测，增强了时空特征的提取能力．李桃迎等[9]通过引入天气和上下游交通流等外部因素，提升模型的泛化能力．ZHOU等[10]提出基于宽注意力模块提取全局特征，并通过深度复合模块优化局部特征．ZHANG等[11]设计一种多任务深度学习框架，实现对站点进出流量和区间客流的联合预测．通过这些方法能有效提升模型性能，但对更复杂场景下的跨区间交互特性仍需进一步研究．

断面客流预测研究的局限在于对历史客流数据的分析不足和较少考虑外部环境因素(如天气和日期等)的影响．本研究采用重力模型刻画站点间的出行引力，通过进出站客流构建出行引力因子，以推算实时断面客流量．考虑到断面客流受多种因素影响，提出基于自注意力机制和多特征提取能力的门控循环单元(gate recurrent unit，GRU)-Transformer模型，有效提取客流数据中的非线性特征，并捕捉其与外部因素之间的复杂关联．采用粒子群算法优化模型超参数，在提升预测精度的同时加快运算效率，满足短时断面客流预测的需求．

1 多影响因素下的数据集获取

1.1 基于重力模型的断面客流获取

重力模型用以分析轨道交通客流出行引力并计算两站点之间的断面客流量，可以明确日常进出站客流对未来时段断面客流分布的影响．图1为抽象轨道网络图与出行OD对应区间关系，其中，0、1、4及10为轨道交通换乘站点，其余为非换乘站点．

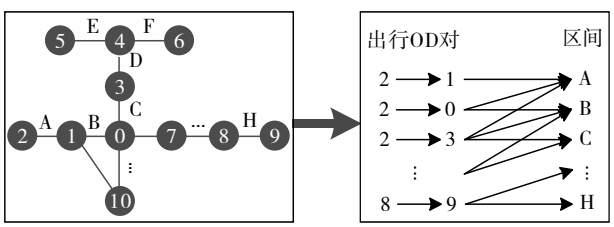


图1 抽象轨道网络图与出行OD对应区间关系

Fig. 1 Abstracted rail transit network and the relationship between travel OD and corresponding sections.

根据重力模型构造进出站客流与断面客流之间的特征关系为[12]

$$T_{ij,t}=\delta(p_{i,t})^{\alpha}(o_{j,t})^{\beta}f(c_{ij}) \tag{1}$$

其中，$T_{ij,t}$表示t时段内站点i和j之间的断面客流量；$p_{i,t}$表示t时段内站点i进站客流；$o_{j,t}$表示t时段内站点j出站客流；c_{ij}为车站i和j之间的广义出行费用；$f(c_{ij})$表示站点i和j之间的出行阻抗函数；δ、α及β为待定系数．

通过离散摩擦因子可以描述旅行时间与换乘次

http://journal.szu.edu.cn

数等因素影响下站点间出行阻力，该出行阻力用交通阻抗函数表示为

$$f(c_{ij}) = f(d_{ij}, n_{ij}) = \exp(-\eta d_{ij} - \tau n_{ij}) \tag{2}$$

其中，d_{ij}为车站i和j之间的旅行时间；n_{ij}为车站i和j之间的换乘次数；η和τ为待定参数.

对式(1)两边取对数将方程线性化，根据客流出行OD及进出站客流，采用最小二乘法标定系数，即

$$\ln T_{ij,t} = \ln\delta + \alpha \ln p_{i,t} + \beta \ln o_{j,t} + \ln f(c_{ij}) \tag{3}$$

原始AFC刷卡数据可以统计各个站点各时段的进出站客流数据，假设城市轨道交通网有m个站点，则k个时段内站点i和j的进出站客流数据为

$$P_{i,t} = (p_{i,t_0}, p_{i,t_1}, \cdots, p_{i,t_k}), i \in \{1, 2, \cdots, m\} \tag{4}$$

$$O_{j,t} = (o_{j,t_0}, o_{j,t_1}, \cdots, o_{j,t_k}), j \in \{1, 2, \cdots, m\} \tag{5}$$

根据式(1)得到每个时段的断面$T_{ij,t}$，并将其扁平化得到1组1维向量，则k个时段构成1组具有时间序列特征的断面客流数据$\boldsymbol{F}_{ij,t}$为

$$\boldsymbol{F}_{ij,t} = \left[T_{ij,t_0}, T_{ij,t_1}, \cdots, T_{ij,t_k}\right]^{\mathrm{T}} \tag{6}$$

所构造的出行引力因子为$1 \times k$维向量，为各时段模型输入的1组时序数据.

1.2　断面客流影响因素

天气、日期等因素变化，会使乘客的出行行为和模式受到影响，区间断面客流随日期变化呈现出工作日客流规律性较强、非工作日客流规律性相对不明显的特征.

1.3　数据特征识别

将式(1)计算得到每个时段的断面客流数据和影响因素以固定时间间隔进行汇总，形成以特定时间步长和特征构成的输入数据$\boldsymbol{X}$为

$$\boldsymbol{X} = \begin{bmatrix} T_{ij,t_0} & A_{1,t_0} & A_{2,t_0} \\ T_{ij,t_1} & A_{1,t_1} & A_{2,t_1} \\ \vdots & \vdots & \vdots \\ T_{ij,t_r} & A_{1,t_r} & A_{2,t_r} \end{bmatrix}_{r \times 3} \tag{7}$$

其中，$\boldsymbol{A}_{1,t} = \left[A_{1,t_0}, A_{1,t_1}, \cdots, A_{1,t_r}\right]^{\mathrm{T}}$为日期类型，工作日取1，非工作日取0；$\boldsymbol{A}_{2,t} = \left[A_{2,t_0}, A_{2,t_1}, \cdots, A_{2,t_r}\right]^{\mathrm{T}}$为天气状况，晴取0、多云取1、阴取2、小雨取3、中雨取4.

为解决多源数据量纲差异对计算结果的影响，采用欧几里得范数函数$\mathrm{norm}(\boldsymbol{X})$进行归一化处理，

$$\mathrm{norm}(\boldsymbol{X}_{ij,t}) = \sqrt{\boldsymbol{F}_{ij,t}^{\mathrm{T}}\boldsymbol{F}_{ij,t} + \boldsymbol{A}_{1,t}^{\mathrm{T}}\boldsymbol{A}_{1,t} + \boldsymbol{A}_{2,t}^{\mathrm{T}}\boldsymbol{A}_{2,t}} \tag{8}$$

$$\mathrm{norm}(\tilde{\boldsymbol{X}}_{ij,t}) = \frac{\sqrt{\boldsymbol{F}_{ij,t}^{\mathrm{T}}\boldsymbol{F}_{ij,t} + \boldsymbol{A}_{1,t}^{\mathrm{T}}\boldsymbol{A}_{1,t} + \boldsymbol{A}_{2,t}^{\mathrm{T}}\boldsymbol{A}_{2,t}}}{\mathrm{norm}(\boldsymbol{X}_{ij,t})} = 1 \tag{9}$$

其中，$\tilde{\boldsymbol{X}}_{ij,t}$为归一化后的模型输入矩阵.

2　粒子群优化的GRU-Transformer客流预测模型

本研究通过粒子群优化GRU-Transformer算法实现短时断面客流快速、准确预测，模型结构如图2，主要包括数据特征识别、GRU时序客流特征提取、Transformer客流特征权重优化及粒子群超参数优化4个部分.

2.1　GRU时序客流特征提取

采用GRU提取最近时段断面客流的时间依赖性，其结构包含重置门$\boldsymbol{r}_t$和更新门$\boldsymbol{z}_t$. 其中，$\boldsymbol{r}_t$捕捉客流时间序列里的长期依赖关系；$\boldsymbol{z}_t$用于调整前一时刻的隐状态和当前时刻的客流时序特征加权平均[14]，$\boldsymbol{r}_t$和$\boldsymbol{z}_t$可表示为

$$\boldsymbol{z}_t = \sigma\left(\boldsymbol{\omega}_z * \left[\boldsymbol{h}_{t-1}, \tilde{\boldsymbol{X}}\right] + \boldsymbol{b}_z\right) \tag{10}$$

$$\boldsymbol{r}_t = \sigma\left(\boldsymbol{\omega}_r * \left[\boldsymbol{h}_{t-1}, \tilde{\boldsymbol{X}}\right] + \boldsymbol{b}_r\right) \tag{11}$$

其中，σ为sigmoid激活函数；$\boldsymbol{\omega}_z$、$\boldsymbol{\omega}_r$及$\boldsymbol{b}_z$、$\boldsymbol{b}_r$分别为重置门、更新门的加权矩阵及偏置项；$\boldsymbol{h}_{t-1}$为前一单元的隐藏状态；$*$表示逐元素乘法.

在计算得到门控信号后，使用$\boldsymbol{r}_t$与$\boldsymbol{h}_{t-1}$逐元素乘法相乘重置隐藏状态得到$\boldsymbol{h}'_{t-1}$，即

$$\boldsymbol{h}'_{t-1} = \boldsymbol{h}_{t-1} * \boldsymbol{r}_t \tag{12}$$

将得到的结果与当前时间步的输入$\tilde{\boldsymbol{X}}$相加，再通过含激活函数tanh的全连接层计算当前记忆内容$\boldsymbol{h}'_t$为

$$\boldsymbol{h}'_t = \tanh(\boldsymbol{W} * \tilde{\boldsymbol{X}} + \boldsymbol{r}_t * \boldsymbol{U} * \boldsymbol{h}'_{t-1}) \tag{13}$$

其中，$\boldsymbol{W}$和$\boldsymbol{U}$为权重矩阵. 由式(13)可知，重置门控制了上一时间步的客流数据输入信息如何流入当前时间步. 因此，重置门可避免网络过度依赖前序客流信息，丢弃与客流预测无关的历史信息[15].

$\boldsymbol{h}'_t$主要包含当前输入的客流信息状态，将$\boldsymbol{h}'_t$更新为隐藏状态，记忆了当前时刻状态，更好捕捉客流序列中长期依赖关系. $\boldsymbol{h}'_t$与$\boldsymbol{h}'_{t-1}$通过动态控制得到向量$\boldsymbol{h}_t$，

$$\boldsymbol{h}_t = \boldsymbol{z}_t * \boldsymbol{h}'_t + (1 - \boldsymbol{z}_t) * \boldsymbol{h}'_{t-1} \tag{14}$$

$\boldsymbol{h}_t$保存了当前单元的客流信息状态并传递给网络，即为GRU对轨道交通断面客流数据特征的提取.

http://journal.szu.edu.cn

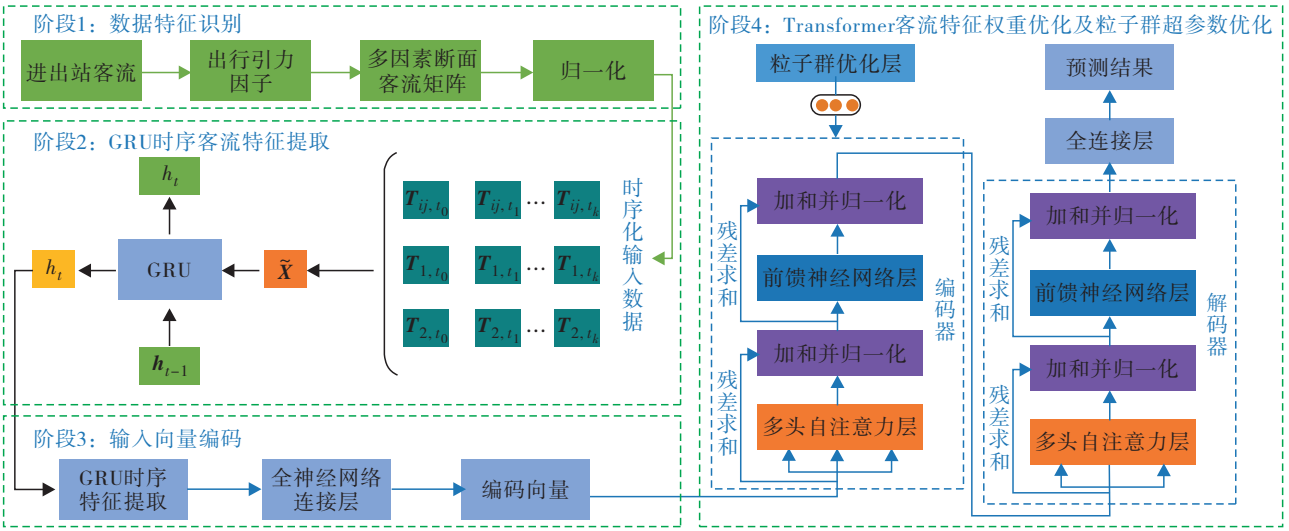


图 2 粒子群优化 GRU-Transformer 客流预测模型

Fig. 2 (Color online) Passenger flow prediction model using particle swarm optimized GRU-Transformer.

2.2 Transformer 客流特征权重优化

采用 Transformer[13] 学习断面客流数据特征与节假日特征、天气特征之间的全局交互信息，对输入向量进行位置编码能够记录其时序信息，有效降低时间序列数据顺序所造成的影响．将 $\boldsymbol{h}_t$ 作为输入，对 $\boldsymbol{h}_t$ 进行位置编码，即

$$L_t^{(l)} = \begin{cases} \sin(\omega_k t), & l = 2k \\ \cos(\omega_k t), & l = 2k+1 \end{cases} \tag{15}$$

$$\boldsymbol{h}_i = \mathrm{Embedding}(\boldsymbol{h}_t) + L_t^{(l)}(\boldsymbol{h}_t) \tag{16}$$

其中，$\omega_k = \dfrac{1}{10\,000^{2k/d_{\mathrm{model}}}}$，$i = 0, 1, 2, \cdots, \dfrac{d_{\mathrm{model}}}{2} - 1$，$d_{\mathrm{model}}$ 表示模型输入矩阵的维度；$L_t^{(l)}$ 表示当前位置向量的第 l 个元素；$\boldsymbol{h}_i$ 为编码后输入矩阵．

编码后的输入矩阵 $\boldsymbol{h}_i$ 在 Transformer 编码器部分首先通过查询 $\boldsymbol{Q}_i$、键 $\boldsymbol{K}_i$ 和值 $\boldsymbol{V}_i$ 向量传入多头注意力层，

$$\boldsymbol{Q}_i = \boldsymbol{W}_q \boldsymbol{h}_i \tag{17}$$

$$\boldsymbol{K}_i = \boldsymbol{W}_k \boldsymbol{h}_i \tag{18}$$

$$\boldsymbol{V}_i = \boldsymbol{W}_v \boldsymbol{h}_i \tag{19}$$

$$\mathrm{head}_i = \mathrm{soft\,max}\left(\boldsymbol{Q}_i \boldsymbol{K}_i^{\mathrm{T}} / \sqrt{d}\right) \boldsymbol{V}_i \tag{20}$$

$$\mathrm{Multihead}_i = \mathrm{concat}(\mathrm{head}_1, \mathrm{head}_2, \cdots, \mathrm{head}_h) \boldsymbol{W}_m \tag{21}$$

其中，$\boldsymbol{W}_q$、$\boldsymbol{W}_k$、$\boldsymbol{W}_v$ 和 $\boldsymbol{W}_m$ 为可学习的参数矩阵；softmax 函数用于计算 $\boldsymbol{Q}_i$ 和 $\boldsymbol{K}_i$ 之间的相似度，并将其转换为注意力权重；$\boldsymbol{Q}_i \boldsymbol{K}_i^{\mathrm{T}}$ 表示查询向量和键向量之间的点积矩阵；$d = m/h$ 表示键向量维度，m 为输入特征总维度，h 为注意力头的个数．$\boldsymbol{W}_q \in \mathbf{R}^{d \times h \times m} \in \mathbf{R}^{d_p \times d_k}$、$\boldsymbol{W}_k \in \mathbf{R}^{d \times h \times m}$、$\boldsymbol{W}_v \in \mathbf{R}^{d \times h \times m} \in \mathbf{R}^{d_p \times d_v}$ 及 $\boldsymbol{W}_m \in \mathbf{R}^{d \times h \times m}$ 为多头注意力层的参数向量．

多头注意力机制使模型可以自适应地关注输入序列中不同位置的信息，提高模型对输入向量中不同时段之间的关联程度．

前馈神经网络（feedforword neural network，FFN）能够降低长时间客流序列对多头注意力机制拟合程度的影响，随着层数的增多，拟合数据可能会出现过大或过小的问题，因此，加入规划层（LayerNorm）将数据规范化，提高运行速度．

$$\boldsymbol{H}_i = \mathrm{LayerNorm}(\boldsymbol{h}_i + \mathrm{Multihead}_i) \tag{22}$$

$$\boldsymbol{H}_i' = \mathrm{FFN}(\boldsymbol{H}_i) \tag{23}$$

$$\boldsymbol{H}_t = \mathrm{LayerNorm}(\boldsymbol{H}_i + \boldsymbol{H}_i') \tag{24}$$

其中，$\boldsymbol{H}_i$ 表示经过层归一化处理后的向量；$\boldsymbol{H}_i'$ 表示经过 FFN 处理后的结果；$\boldsymbol{H}_t$ 表示最终的隐藏状态向量．

解码模块按照编码模块的给定信息进行解码分析，实现对多源客流数据特征的有效提取，随后在特征层中重构输入，通过全连接层将特征进行融合并输出预测结果 $\boldsymbol{y}_t$．

$$\boldsymbol{y}_t = \mathrm{ReLU}\left[\mathrm{FCS}(\boldsymbol{h}_t;\ \boldsymbol{H}_t)\right] \tag{25}$$

其中，ReLU 是对特征融合后的向量进行非线性变换；FCS 为全连接层，用于特征融合和最终预测．

2.3 粒子群超参数优化

粒子群算法是全局搜索算法[16]，采用确定模型的训练次数、学习率、隐藏层数、批处理量及时间步长可有效提高运行效率，具体步骤如下．

步骤 1 确定粒子群参数．算法要求每个个体在进化过程中保持速度向量和位置向量，其中，速

http://journal.szu.edu.cn

度区间为[−1, 1]，位置区间为[−5, 5]，取粒子群算法惯量权重为0.9，加速系数$l_1 = l_2 = 1.5$，粒子群维度为4，种群数量为30，最高训练次数为20，最小精度误差为0.000 1．确定本模型所需优化参数的取值范围．

步骤2　设定GRU-Transformer模型隐含层数和批处理量等相关超参数优化范围，基于上述参数对模型展开训练，将均方根误差作为适应度评估指标，当达到最大迭代次数后，输出训练结果．

步骤3　以初始适应度为评价基准，计算每个粒子的全局极值和个体极值，确定最优粒子位置．迭代过程中比较粒子更新前后的适应度，若适应度提升，则更新当前时刻最佳位置和全局最佳位置．

步骤4　达到最大迭代次数后，输出相关超参数集合．

3　实验分析

3.1　实验参数设置与评价指标

本模型基于PyTorch深度学习开发框架搭建，实验操作系统为Windows11，中央处理器为Intel Core i5-8250u，图形处理器为NVIDIA GeForce MX150．采用2019年阿里天池大赛提供的杭州地铁数据集，数据集覆盖杭州市地铁全网81个车站2019-01-01至2019-01-25的客流信息和刷卡数据，每日有效时段为06:30—23:30，经数据预处理后，共得到57 800组进出站数据，31 500组OD客流数据．对式(3)中参数分为工作日和非工作日进行标定，结果见表1．

表1　重力模型系数标定

Table 1　Calibration of gravity model coefficients

时间	$\ln T_{ij,t}$	$\delta \ln p_{i,t}$	$\alpha \ln o_{j,t}$	$\ln d_{ij}$	d_{ij}	n_{ij}
工作日	−5.803	0.671	0.750	−0.787	−0.017	−0.810
非工作日	−7.074	0.654	0.736	−0.782	−0.001	−0.649

采用K-S检验以及Spearman相关分析验证所标定参数合理性，结果见表2．可见，渐进显著性均小于标准值0.05，符合检验标准．结果表明，进出站客流均与断面客流呈显著相关．

基于所标定参数，通过式(1)构建进出站客流与断面客流之间的特征关系，生成断面客流数据集．为确保模型训练的科学性，将数据集按8:1:1划分为训练集、验证集和测试集．同时将天气和日期等外部因素整合至模型的输入变量中．部分输入数据示例可通过扫描论文末页右下角二维码，查看补充材料表S1．

表2　重力模型各系数的检验结果

Table 2　Validation of gravity model coefficients

变量	K-S检验渐进显著性	Spearman相关系数
$\ln T_{ij,t}$	0.000	1.000
$\delta \ln p_{i,t}$	0.000	0.390**
$\alpha \ln o_{j,t}$	0.000	0.493**
$\ln d_{ij}$	0.000	−0.496**
d_{ij}	0.000	−0.496**
n_{ij}	0.000	−0.404**

**表示置信度(双侧)为0.01时，相关性是显著的．

粒子群算法中通过5重交叉验证来避免模型陷入局部最优，结果见表3．对时间步长进行相应调整，以确保模型在各时间尺度(10、15及30 min)下的预测精度．

表3　超参数寻优结果

Table 3　Hyperparameter optimization results

超参数名称	搜索范围	寻优结果
隐含层数(hidden layers)	[1, 10]	3
批处理量(batch size)	[2, 64]	32
学习率(learning rate)	$[1\times10^{-6}, 1]$	0.001
训练数(epoch)	[50, 300]	100
时间步长(time step)	[1, 20]	14、10、6

模型在上述参数训练下的损失函数变化如图3．可见，训练集和测试集都能很好地收敛，在迭代到100轮后，损失量趋向于平稳，达到最优值．

为了更好地分析和比较GRU-Transformer模型在测试数据上的预测性能，采用平均绝对误差(mean absolute error，MAE)、均方根误差(root mean

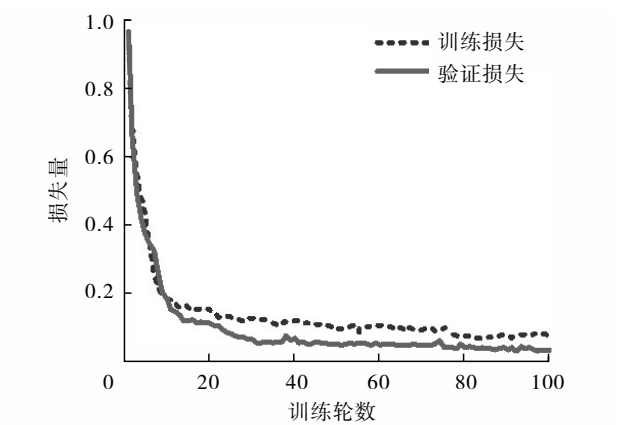


图3　模型训练过程中的损失函数

Fig. 3　Loss function during model training.

http://journal.szu.edu.cn

squared error，RMSE）和平均绝对百分比误差（mean absolute percentage error，MAPE）作为模型的评价指标，衡量预测值与真实值之间的离散程度和偏移程度．评价指标为

$$\eta_{\mathrm{MAE}} = \frac{1}{N}\sum_{i=1}^{N}\left|X_i' - \hat{X}_i\right| \tag{26}$$

$$\eta_{\mathrm{RMSE}} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(X_i' - \hat{X}_i)^2} \tag{27}$$

$$\eta_{\mathrm{MAPE}} = \frac{1}{N}\sum_{i=1}^{N}\left|\frac{X_i' - \hat{X}_i}{X_i'}\right| \times 100\% \tag{28}$$

其中，N为测试样本总数；i为测试数据编号；X_i'为真实客流值；$\hat{X}_i$为断面客流预测值．

3.2 预测性能分析

设置时间粒度为15 min，验证模型在不同线路和日期类型下的预测性能．图4为杭州地铁1、2号线两个断面在1月20日（工作日）和1月21日（非工作日）的客流预测结果，涵盖了钱江路站—江锦路站、文海南路站—文泽路站．结果表明，模型在工作日和非工作日均能够准确反映客流的实际变化趋势．

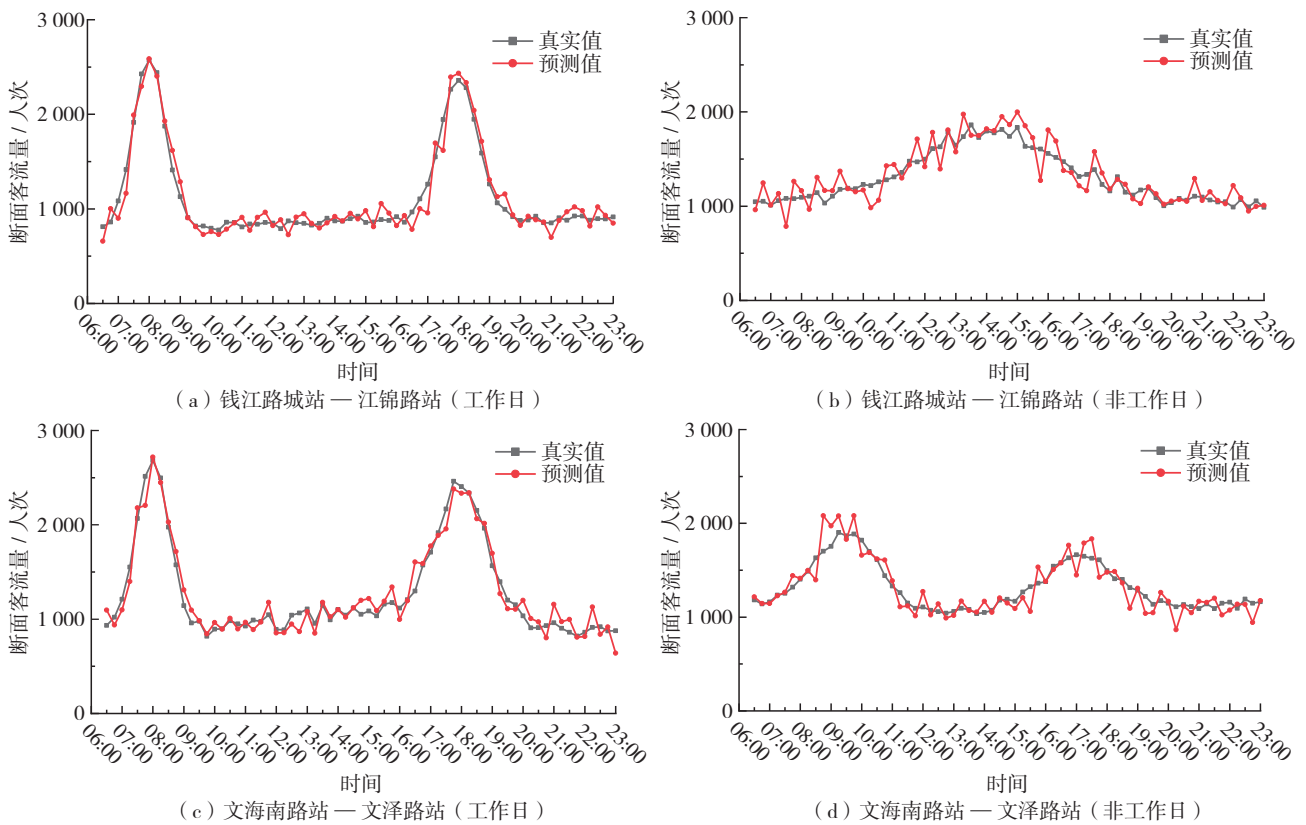


图4 模型在不同日期类型下的断面客流量预测结果

Fig. 4 (Color online) The prediction results under different date types. (a) and (b) represent the actual and predicted cross-sectional passenger flow between Qianjiang Road Station and Jiangjin Road Station on workdays and non-workdays, respectively; (c) and (d) represent the actual and predicted cross-sectional passenger flow between Wenhai South Road Station and Wenzhi Road Station on workdays. The solid line with squares and circles represent the actual value and the predicted value, respectively.

表4为不同日期类型下断面客流预测的误差指标．可见，模型在各日期类型下的MAPE值均低于20.00%，证明模型的预测精度高．通过将日期类型纳入影响因素，模型能够精准捕捉工作日与非工作日的客流规律差异．

为验证模型的泛化能力，选取6个具有不同站点客流特征的断面进行客流量预测，结果见图5．可见，本研究模型能够较精准拟合不同断面的实际

表4 不同日期类型的预测结果对比

Table 4 Comparison of prediction results for different dates

日期类型	预测步长/min	η_{MAE}	η_{RMSE}	η_{MAPE} / %
工作日	15	71.86	125.39	16.21
非工作日	15	73.69	135.87	17.15
全部日期	15	71.36	121.32	15.86

http://journal.szu.edu.cn

客流变化趋势，特别是在早晚高峰时段以及平峰时段，预测值与真实值的吻合度较高．

表 5 为不同区间下的预测结果．可见，模型的 MAPE 值均低于 20%，表明其在复杂动态客流场景下具有较高的预测精度和可靠性．尽管不同断面客流的时空分布特性和乘客出行规律差异较大，模型仍能精准捕捉断面间的动态变化及特征分布趋势．

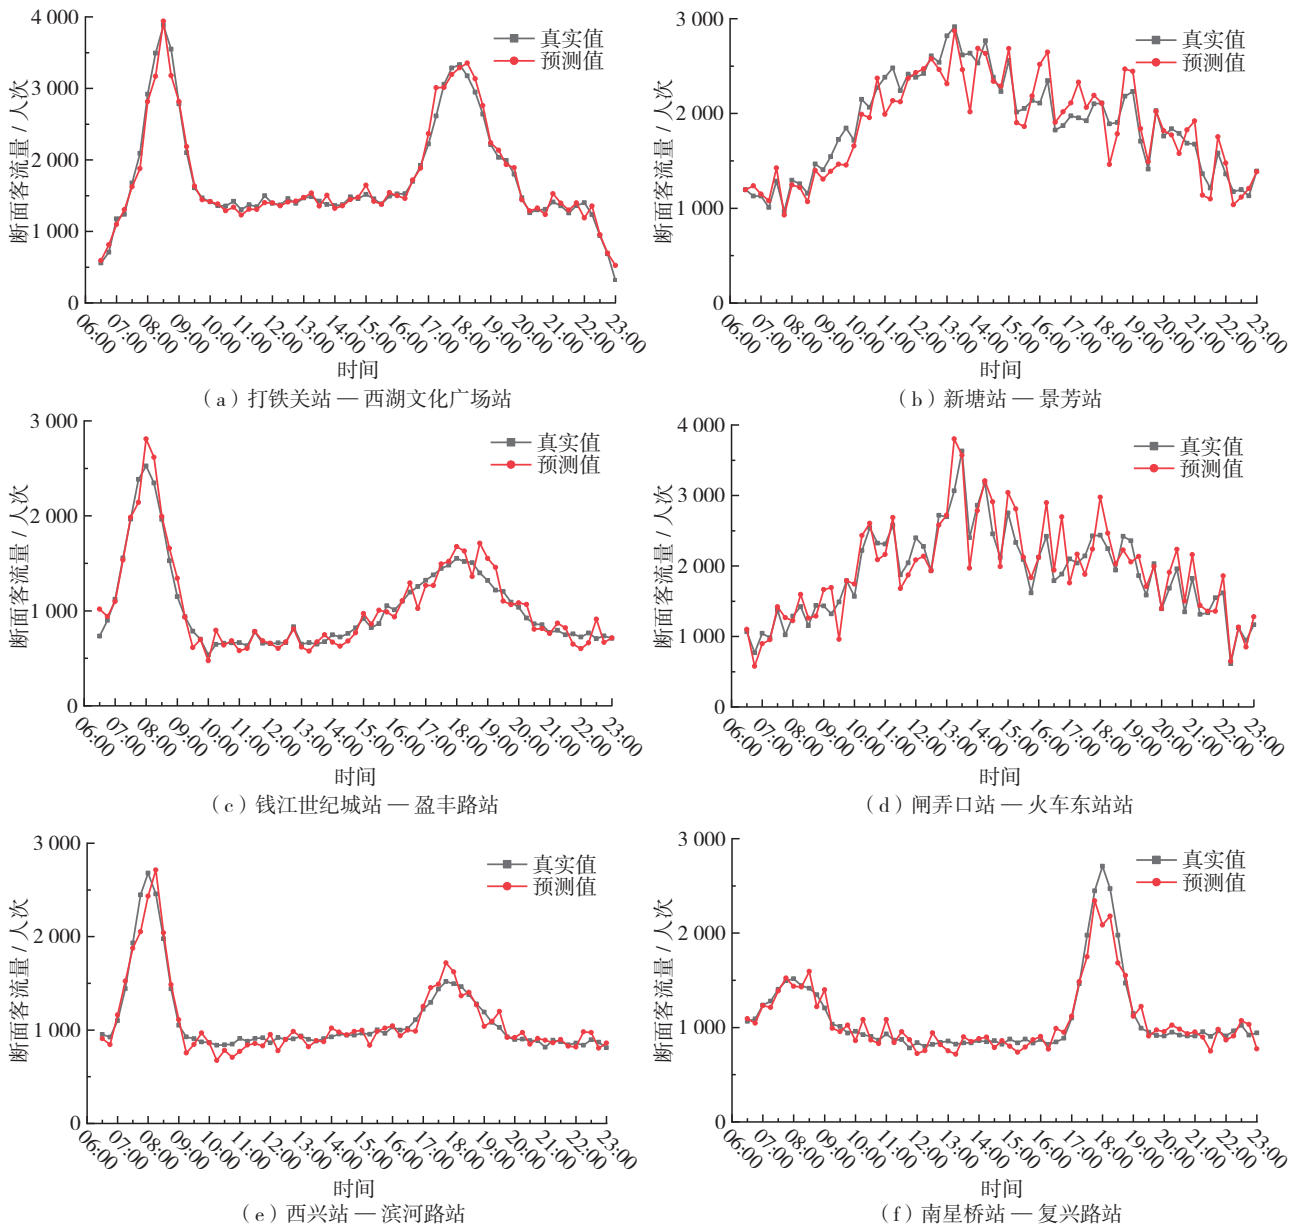


图 5　部分断面预测结果

Fig. 5　(Color online) The comparison of actual and predicted passenger flow between (a) Datieguan Station to Xihu Cultural Square Station, (b) Xintang Station to Binhai Road Station, (c) Qianjiang Century City Station to Mengfeng Road Station, (d) Deshengkou Station to Huoche East Station, (e) Xixing Station to Binhai Road Station, and (f) Luxingqiao Station to Xiaoxing Road Station. The solid line with squares and circles represent the actual value and predicted value, respectively.

3.3　预测性能对比分析

为进一步验证本模型性能，选取已有文献中的基准预测模型（随机森林（random forest，RF）[7]、LSTM[6]及 GCN-双向长短期记忆（GCN - bidirectional long short-term memory，GCN-BiLSTM）[10] 网络模型），进行对比实验．实验设置包括单一断面客流数据集，以及融合天气和日期影响因素的多源数据集．实验平台和训练参数均按照原文献设定，时间

http://journal.szu.edu.cn

表5 不同区间下的预测结果

Table 5 Prediction results under different intervals

断面区间	预测步长/min	η_{MAE}	η_{RMSE}	η_{MAPE}/%
打铁关站—西湖文化广场站	15	71.82	121.79	15.94
闸弄口站—火车东站站	15	74.32	124.10	16.86
西兴站—滨河路站	15	71.36	121.32	15.86
钱江世纪城站—盈丰路站	15	72.51	122.83	16.02
新塘站—景芳站	15	73.42	123.52	16.45
南星桥站—复兴路站	15	71.90	121.93	16.12

粒度为10、15及30 min，分别对应43 350、28 900和14 450组断面客流数据．通过计算各个模型在西兴站—滨河路站断面上的MAE、RMSE及MAPE值进行对比分析，结果见表6．

由表6可见，RF模型在不同时间粒度和输入多因素影响下的预测精度最低．相较之下，LSTM模型显著提升了对客流非线性特征的捕捉能力，计算结果有所提升．GCN-BiLSTM模型结合双向结构与图卷积网络，有效刻画空间依赖特性，在预测精度上优于传统时序模型．

表6 不同预测模型的评价指标对比

Table 6 Comparison of evaluation metrics for different prediction models

模型	输入	时间粒度/min								
		10			15			30		
		η_{MAE}	η_{RMSE}	η_{MAPE}/%	η_{MAE}	η_{RMSE}	η_{MAPE}/%	η_{MAE}	η_{RMSE}	η_{MAPE}/%
RF	矩阵分配	126.85	205.45	35.52	142.55	236.75	38.05	147.20	258.35	45.10
	计算图	125.70	203.30	34.98	141.40	235.10	37.87	145.20	256.20	44.62
	引力因子	121.72	199.45	33.94	137.93	229.12	36.61	140.78	249.97	43.51
LSTM	矩阵分配	106.15	170.20	22.75	118.35	212.80	25.85	122.35	235.60	28.50
	计算图	104.90	167.30	21.45	116.20	210.50	24.58	119.10	228.75	26.92
	引力因子	95.92	155.73	20.61	102.95	199.42	23.87	114.53	185.08	26.04
GCN-BiLSTM	矩阵分配	72.35	137.10	16.98	80.15	148.05	18.57	85.70	147.60	19.85
	计算图	71.92	135.73	16.71	78.95	146.81	18.23	84.53	145.57	19.62
	引力因子	67.36	116.68	15.17	72.42	126.91	16.66	76.48	128.26	18.53
本模型	矩阵分配	69.50	117.65	15.72	75.15	128.35	16.58	79.60	131.10	17.48
	计算图	66.75	111.98	15.12	71.62	122.97	16.08	76.15	126.85	17.02
	引力因子	65.16	110.32	14.96	71.36	121.32	15.86	75.64	123.75	16.96

注：灰底数据表示在相同时间粒度和输入方式下，本研究粒子群优化GRU-Transformer模型取得最优预测结果．

从输入方式来看，尽管矩阵分配输入方法已经纳入天气和日期等外部因素，其预测误差依然较高．相较之下，计算图输入通过图结构表示站点间的空间关联性，在捕捉空间依赖上更具优势，但其在时间依赖建模方面能力有限．在10、15和30 min粒度下的MAPE值分别为14.96%、15.86%和16.96%，均显著低于对比模型．随着时间粒度从10 min增至30 min，各模型的预测误差有所上升，然而，本模型的误差增幅相较基准模型仍然较小，MAPE的增幅仅为2.00%，尤其是在30 min粒度下依能保持较高的预测精度（MAPE值为16.96%）．

这种性能优势源于GRU与Transformer模块在长短期依赖特征提取上的协同效应，使得模型能够捕捉复杂非线性和时间依赖关系．同时，粒子群优化算法的引入显著提升了超参数优化的效率与稳定性，使模型适用于多种时间粒度需求．

3.4 消融实验

为进一步分析GRU、Transformer及改进粒子群优化（improved particle swarm optimization，IPSO）算法对本模型性能的影响，构建以下消融模型进行对比试验：① IPSO-GRU，取消本模型中的Transformer模块；② IPSO-Transformer，取消GRU算法；③ GRU-Transformer，取消粒子群优化算法．以西兴站—滨河路站为例，分别计算以上模型在10、15

http://journal.szu.edu.cn

及 30 min 时间粒度下的 MAE 值，结果见表 7.

由表 7 可见，以 10 min 的客流预测结果为例进行分析，IPSO-GRU-Transformer 模型相比 IPSO-GRU 模型，进出站客流预测结果的 MAE 值分别减少了 20.36；相比 IPSO-Transformer 模型，MAE 值分别减少了 8.53；相比 GRU-Transformer 模型 MAE 值减少了 2.05. 因此认为：① 增加 Transformer 模块预测误差降低幅度最大，表明本研究所融合具有多头注意力机制的 Transformer 是合理的；② 增加 IPSO 优化算法使预测误差降低，表明使用粒子群优化模型超参数有助于提高模型预测精度；③ 相比单一预测模块，GRU 预测精度低于 Transformer，说明 Transformer 在时序特征提取方面更具优势. 本研究使用 GRU、粒子群优化算法及 Transformer 均有助于提高模型预测性能，且增加 Transformer 模块优化时序特征权重对模型性能的提升效果更为明显.

表 7　消融实验结果

Table 7　Ablation experiment results

模型	η_{MAE}		
	10 min	15 min	30 min
IPSO-GRU	85.52	86.32	89.43
IPSO-Transformer	73.69	78.81	81.56
GRU-Transformer	67.21	72.57	77.45
IPSO-GRU-Transformer	65.16	71.36	75.64

结　语

针对城市轨道交通断面客流分配具有滞后性及多因素影响下的预测精度低问题，提出基于粒子群优化的 GRU-Transformer 短时客流预测模型. 通过引入重力模型量化客流出行引力，计算站点间断面客流量，同时结合天气和日期等扰动因素，构建具备强时序特征捕捉能力的 GRU-Transformer 网络，显著提升了预测的时效性和精度.

本模型在不同时间粒度和多因素环境下展现出卓越的预测性能，特别是在结合引力因子、天气和日期等外部因素下，显著优于 RF、LSTM 和 GCN-BiLSTM 等传统模型，能够精准捕捉复杂客流的动态变化，表现出对非线性特征的强适应性和多因素干扰下的鲁棒性. 模型对短时客流波动反应灵敏，在长时间步长下仍保持高精度，有效缓解噪声带来的特征冗余. 消融实验表明，Transformer 增强了时序特征的权重分配，粒子群优化提高了超参数设置的效率和稳定性.

本模型在面对突发事件和大型活动等引发的异常客流变化时，仍存在一定局限性. 未来工作将重点关注如何将突发事件因子纳入预测模型，以增强模型对异常客流的响应能力，进一步提升预测的准确性和适用范围，为轨道交通客流管理与应急响应决策提供更全面的技术支撑.

基金项目：国家自然科学基金资助项目(52262045)；甘肃省重点研发计划-工业类基金资助项目(23YFGA0045)

作者简介：何明(17339820312@163.com)，兰州交通大学硕士研究生. 研究方向：城市轨道交通短时客流预测.

引　　文：何明，左静，余召. 考虑多属性因素融合的城市轨道交通短时断面客流预测[J]. 深圳大学学报理工版，2025，42(6)：723-732.

参考文献 / References：

[1] 中华人民共和国务院. 国家综合立体交通网规划纲要[EB/OL].(2021-02-24)[2024-08-10]. https://www.gov.cn/gongbao/content/2021/content_5593440.htm.
The State Council of the People's Republic of China. Outline of the national comprehensive transport network plan [EB/OL]. (2021-02-24) [2024-08-10]. https://www.gov.cn/gongbao/content/2021/content_5593440.htm. (in Chinese)

[2] 户佐安，邓锦程，杨江浩，等. 轨道交通站点聚类及其对客流预测的影响分析[J]. 交通运输系统工程与信息，2023，23(6)：227-238.
HU Zuoan, DENG Jincheng, YANG Jianghao, et al. Rail transit station clustering and its impact on passenger flow forecasting [J]. Journal of Transportation Systems Engineering and Information Technology, 2023, 23(6): 227-238. (in Chinese)

[3] 刘洋. 基于状态空间模型的城市轨道交通断面短时客流预测方法研究[D]. 北京：北京交通大学，2016.
LIU Yang. Study on short-term sectional passenger flow forecasting method of urban rail transit based on state space model [D]. Beijing: Beijing Jiaotong University, 2016. (in Chinese)

[4] 过秀成，王炜. 基于居民出行决策的轻轨客流预测方法研究[J]. 东南大学学报，1998，28(4)：109-114.
GUO Xiucheng, WANG Wei. Method of light rail volume forecast based on trip decision process of citizen [J]. Journal of Southeast University, 1998, 28(4): 109-114. (in Chinese)

[5] 曹凯鑫. 基于深度学习的轨道交通断面客流短时预测[D]. 南京：东南大学，2019.

http://journal.szu.edu.cn

CAO Kaixin. Short-term prediction of section passenger flow of urban rail transit based on deep learning [D]. Nanjing: Southeast University, 2019. (in Chinese)

[6] 李亚香，王元庆. 基于PSO-LSSVM算法的城市轨道交通断面客流量预测[J]. 长安大学学报自然科学版，2021，41(6)：91-102.
LI Yaxiang, WANG Yuanqing. Cross-section passenger flow forecasting of urban rail transit based on PSO-LSSVM algorithm [J]. Journal of Chang'an University Natural Science Edition, 2021, 41(6): 91-102. (in Chinese)

[7] 张金雷. 城市轨道交通线网短时客流预测方法研究[D]. 北京：北京交通大学，2021.
ZHANG Jinlei. Study of the short-term passenger flow predictionin urban rail transit networks [D]. Beijing: Beijing Jiaotong University, 2021. (in Chinese)

[8] 郑乐婧. 基于时空特征和注意力机制的地铁区间断面客流短时预测[D]. 北京：北京交通大学，2020.
ZHENG Lejing. Short-term prediction of subway section passenger flow based on spatio-temporal characteristics and attentional mechanism [D]. Beijing: Beijing Jiaotong University, 2020. (in Chinese)

[9] 李桃迎，王婷，张羽琪. 考虑多特征的高速公路交通流预测模型[J]. 交通运输系统工程与信息，2021，21(3)：101-111.
LI Taoying, WANG Ting, ZHANG Yuqi. Highway traffic flow prediction model with multi-features [J]. Journal of Transportation Systems Engineering and Information Technology, 2021, 21(3): 101-111. (in Chinese)

[10] ZHOU Junhao, DAI Hongning, WANG Hao, et al. Wide-attention and deep-composite model for traffic flow prediction in transportation cyber-physical systems [J]. IEEE Transactions on Industrial Informatics, 2021, 17(5): 3431-3440.

[11] ZHANG Junbo, ZHENG Yu, SUN Junkai, et al. Flow prediction in spatio-temporal networks based on multitask deep learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 32(3): 468-478.

[12] 成艳，叶霞飞，王治，等. 城市轨道交通高峰时段站间起讫点矩阵预测模型[J]. 同济大学学报自然科学版，2018，46(3)：346-353.
CHENG Yan, YE Xiafei, WANG Zhi, et al. Forecasting model of peak-period station-to-station origin-destination matrix in urban rail transit systems [J]. Journal of Tongji University Natural Science, 2018, 46(3): 346-353. (in Chinese)

[13] 胡明伟，施小龙，吴雯琳，等. 城市轨道交通车站短时客流机器学习预测方法[J]. 深圳大学学报理工版，2022，39(5)：593-599.
HU Mingwei, SHI Xiaolong, WU Wenlin, et al. Machine learning based method for forecasting short-term passenger flow in urban rail stations [J]. Journal of Shenzhen University Science and Engineering, 2022, 39(5): 593-599. (in Chinese)

[14] 魏伟，赵小强，吴进. 基于VMD-ICSO-GRU的高铁列控车载设备故障率时间序列预测[J]. 铁道学报，2023，45(6)：58-68.
WEI Wei, ZHAO Xiaoqiang, WU Jin. Time series prediction of fault rate of high-speed railway on-board equipment based on VMD-ICSO-GRU [J]. Journal of the China Railway Society, 2023, 45(6): 58-68. (in Chinese)

[15] 刘雨生，汤新民，任宣铭. 基于注意力机制的GRU-IKF场面滑行轨迹预测模型[J]. 北京航空航天大学学报，2025，51(3)：1028-1036.
LIU Yusheng, TANG Xinmin, REN Xuanming. Prediction of aircraft surface trajectory based on the GRU-IKF model with attention mechanism [J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(3): 1028-1036. (in Chinese)

[16] 赵明伟，张文胜. 基于IPSO-LSTM组合模型的城市轨道交通短时客流预测[J]. 铁道运输与经济，2022，44(2)：123-130.
ZHAO Mingwei, ZHANG Wensheng. Short-term passenger flow prediction of urban rail transit based on IPSO-LSTM combined model [J]. Railway Transport and Economy, 2022, 44(2): 123-130. (in Chinese)

【中文责编：方圆；英文责编：淡紫】

补充材料

http://journal.szu.edu.cn