

DOI:10.11918/202407003

灾害性天气条件下城市轨道交通客流 DRN-BiLSTM 预测模型

程国柱¹, 吕岩峰¹, 冯天军²

(1. 东北林业大学 土木与交通学院, 哈尔滨 150040; 2. 吉林建筑大学 交通科学与工程学院, 长春 130118)

摘要: 为有效应对灾害性天气对城市轨道交通客流组织的影响, 探索灾害性天气条件下城市轨道交通线网客流变化规律, 基于深度残差网络 (DRN) 和双向长短时卷积神经网络 (BiLSTM), 充分考虑灾害性天气特征对客流变化的影响, 开展了轨道交通线网客流预测研究。构建了融入灾害性天气特征的轨道交通线网客流 DRN-BiLSTM 预测模型, 并选取均方误差 (MSE)、均方根误差 (RMSE)、平均绝对误差 (MAE)、决定系数 (R^2) 作为模型性能评价指标, 并进行模型的客流量预测效果验证分析。分析结果表明: 与传统 LSTM、BiLSTM 相比较, DRN-BiLSTM 在灾害性天气特征输入情况下, MSE 分别降低 22.10%、21.96%; RMSE 分别降低 10.54%、10.46%; MAE 分别降低 3.20%、3.95%; R^2 分别提升 5.01%、2.12%。使用网格搜索法对模型参数进行调优, 优化后, 模型训练损失降低 36%。通过实例验证了所构建的轨道线网交通客流预测 DRN-BiLSTM 组合模型能够有效捕捉数据的深层特征, 极大提升了客流预测精度。

关键词: 城市交通; 客流预测模型; 深度残差网络; 双向长短时神经网络; 灾害性天气

中图分类号: U491

文献标志码: A

文章编号: 0367-6234(2025)07-0153-09

Urban rail transit passenger flow DRN-BiLSTM combined forecasting model under catastrophic weather conditions

CHENG Guozhu¹, LÜ Yanfeng¹, FENG Tianjun²

(1. School of Civil Engineering & Transportation, Northeast Forestry University, Harbin 150040, China;

2. School of Transportation Science & Engineering, Jilin University of Architecture, Changchun 130118, China)

Abstract: To effectively address the impact of catastrophic weather on urban rail transit passenger flow organization and to explore the rules of passenger flow changes under such weather conditions, this paper conducts a prediction study on urban rail transit network passenger flow. Based on a deep residual network (DRN) and bidirectional long short-term memory (BiLSTM), a DRN-BiLSTM prediction model incorporating catastrophic weather features is constructed. The model's performance is evaluated using metrics such as mean squared error (MSE), root mean square error (RMSE), mean absolute error (MAE), and coefficient of determination (R^2), and its passenger flow prediction effectiveness is verified and analyzed. The results show that compared to traditional LSTM and BiLSTM, when inputting catastrophic weather features, the DRN-BiLSTM model reduces MSE by 22.10% and 21.96%, RMSE by 10.54% and 10.46%, MAE by 3.20% and 3.95%, and increases R^2 by 5.01% and 2.12%, respectively. By optimizing model parameters with the grid search method, the model training loss is reduced by 36%. Practical verification demonstrates that the DRN-BiLSTM combined model constructed in this paper can effectively capture deep data features and significantly improve the accuracy of passenger flow prediction.

Keywords: urban traffic; passenger flow prediction model; deep residual networks; bidirectional long short-term convolutional neural networks; catastrophic weather conditions

灾害性天气指对人民生命财产有严重威胁, 对生态环境造成严重破坏, 对工农业和交通运输会造成重大损失的天气。如大风、暴雨、暴雪、冰雹、冻雨、大雾等。这类天气具有突发性强、破坏力大的特点。在全球气候变化与城市化进程叠加作用下, 灾

害性天气对城市轨道交通系统的冲击已从偶发扰动演变为常态化挑战。据统计, 2020—2024 年全球轨道交通因暴雨、暴雪、台风等灾害性天气导致的运营中断事件逐年增长。中国的城市轨道交通系统受灾害性天气影响的直接经济损失达数十亿。提升城市

收稿日期: 2024-07-01; 录用日期: 2024-08-01; 修订日期: 2025-05-26; 网络首发日期: 2025-05-30

网络首发地址: <https://link.cnki.net/urlid/23.1235.t.20250529.1618.002>

基金项目: 中央高校基本科研业务费专项资金 (2572023CT21); 吉林省科技发展计划项目 (20220402030GH)

作者简介: 程国柱 (1977—), 男, 教授, 博士生导师

通信作者: 冯天军, fengtianjun@jlju.edu.cn

轨道交通系统应对灾害性天气能力,尤其是提升客运领域应对能力,对保障乘客生命财产安全意义重大。

有效预测灾害天气条件下的客流变化,是运营调整决策的基础。准确的客流预测可以帮助城市交通管理者合理安排车辆运行计划,优化资源分配,提高运输效率,同时也能够为乘客提供更加便捷、舒适的出行体验^[1-2]。然而,由于城市轨道交通客流受多种因素影响,使得客流量具有明显的时间变化特性和不确定性,这给客流量预测带来了挑战^[3],既有客流预测模型在应对多尺度、强耦合的气象灾害时,仍面临三大瓶颈:其一,气象物理场(如台风涡度、暴雨雨强空间梯度)与设施损伤(接触网覆冰、站厅积水)的跨尺度关联建模不足;其二,乘客避险行为在极端天气下的时空异质性(如郑州暴雨中的瞬时聚集与北京暴雪中的长时滞留)缺乏动态表征;其三,传统数据驱动方法受限于灾害样本稀缺性,在超阈值天气场景中预测效能断崖式下降。

多年来,国内外学者对城市轨道交通客流预测方法开展了大量研究,传统方法如自回归移动平均(ARMA)和季节性分解的趋势、季节性和残差(STL)等模型曾被广泛应用。这些模型依赖于严格的统计假设,且在处理非线性和非平稳时间序列数据时表现不佳^[4]。随着机器学习技术的发展,支持向量机(SVM)、决策树和随机森林等算法开始被应用于客流量预测,这些方法在一定程度上改善了预测的准确性,但仍然难以捕捉时间序列数据中的复杂依赖关系^[5]。

随着人工智能技术的快速发展,深度学习方法已被广泛应用于交通流量预测领域。特别是深度神经网络(DNN)、卷积神经网络(CNN)和长短时记忆网络(LSTM)等模型,由于其强大的特征提取和时间序列分析能力,已被证明在客流量预测方面具有显著的效果^[6-7]。深度学习技术的兴起为解决客流预测问题提供了新的思路。基于深度学习的预测模型,尤其是基于神经网络的模型,因其出色的特征提取能力和对非线性数据的处理能力,已成为研究的热点。例如,卷积神经网络(CNN)由于其在图像处理领域的成功,被引入到时间序列预测中,用于提取时间序列数据的空间特征^[8-9]。长短时记忆网络(LSTM)则因其在处理长期依赖问题方面的优势而被广泛应用于时间序列预测,尤其是在交通流量和客流量预测领域^[10-14]。

然而,尽管 LSTM 在时间序列预测方面取得了一定的成功,但其在处理非常长的序列和处理大规模数据时仍然存在不足^[15]。此外,单向 LSTM 无法

充分利用未来时间步的信息。为了解决这些问题,相关研究提出了双向长短时记忆网络(BiLSTM)方法,它通过结合正向和反向两个 LSTM,同时处理过去和未来的信息,从而达到提高预测的准确性的目的^[16]。虽然 BiLSTM 模型在时间序列数据的处理上取得了显著进展,但在城市轨道交通客流量预测的实际应用中,还需考虑到各种外部因素,如天气状况、节假日、突发事件等对客流量的影响^[17-18]。这些因素使得客流量预测问题变得更具复杂性和多变性。也因此,一些研究开始探索将外部影响因素融入到深度学习模型中,以提高预测的准确性和鲁棒性。

此外,从近些年的研究情况可以看出,将各种方法进行集成,如随机森林和梯度提升机,可以有效地结合多个模型在预测方面的优势,从而进一步提高预测性能和准确度^[19]。这些方法通过将不同模型的优点集成在一起,在一定程度上缓解了单一模型在预测过程中存在的过拟合或欠拟合等问题。也有研究将时间和空间信息与深度学习模型结合,如站点间的距离、连接性、时间段和工作日、非工作日的区别,来提高预测的准确性^[20-21]。这些研究表明,考虑时空特性,对于提高城市轨道交通客流量预测的准确性至关重要。

上述相关研究,均不同程度地关注多源特征对客流变化的影响,但更侧重于客流变化和客流预测方法本身对客流预测模型精度的影响。综合考虑灾害性天气的时间、空间特征对客流变化的影响还较少,如降雪不仅在当天吸引大量客流,其后期也可能对客流产生影响,如冰雹等短时灾害性天气会引起客流的瞬时增加。为了充分考虑上述灾害性天气对客流预测的影响,本文提出了一种考虑应对灾害性天气的深度残差网络(DRN)和双向长短时卷积神经网络(BiLSTM)的城市轨道交通客流组合预测模型。深度残差网络(DRN)的核心原理是通过引入残差连接,有效解决了深层神经网络训练中的梯度消失和表示瓶颈问题,即通过多层残差块的堆叠,从复杂的输入数据中提取出有用的深层特征,包括客流量的趋势、周期性和异常模式。BiLSTM 的核心原理是通过结合前向和后向两个 LSTM 层,同时处理时间序列的正向和反向信息,从而提高对时间序列数据的建模能力和预测准确性。二者的组合预测模型通过融合多源数据特征,综合利用深度残差网络和双向长短时记忆网络的优点,以达到提高灾害性天气条件下城市轨道交通客流量预测的鲁棒性和泛化能力的目的。

1 DRN-BiLSTM 客流组合预测模型

深度残差网络(DRN)是一种深度学习模型,它通过引入残差连接来解决深度神经网络训练中的梯度消失和表示瓶颈问题。在DRN中,输入不仅通过加权连接传递到下一层,还通过跳过一层或多层的直接连接传递。这意味着每一层都学习输入和输出之间的残差,而不是直接学习映射。深度残差网络的核心是残差学习单元^[22-23],即 $F(x, \{W_i\}) = x + F(x, \{W_i\})$,其中, x 是输入特征,即客流数据中的时间、天气状况、客流量等各项特征。 $F(x, \{W_i\})$ 是权重为 $\{W_i\}$ 的残差映射,代表了连续层之间的非线性变换。这种设计允许信号直接从较低层传递到较高层,从而提高了网络的训练效率和多源数据中影响轨道交通客流的特征提取能力。在客流预测的过程中,DRN 可以有效地从复杂的客流数据中提取出趋势、周期性和异常模式等深层次的特征。这些特征包括但不限于客流量变化、灾害性天气对客流量的影响,以及客流量的不同时空分布^[24]。

双向长短时记忆网络(BiLSTM)是一种特殊类型的循环神经网络(RNN),它通过结合两个独立的LSTM层来处理序列数据,一个处理正向时间步骤,另一个处理反向时间步骤。这种结构使得网络能够同时获取过去和未来的上下文信息,从而在时序数据处理中表现出色。

BiLSTM 模型的输入门为 $i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} +$

$b_i)$,遗忘门为 $f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f)$,输出门为 $o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o)$,最终输出为 $u_t = o_t \odot \tanh(c_t)$ 。其中, $x_t = F_{dnn}(x_t)$ 是在时间步 t 的 DRN 处理后的输入特征,即通过 DRN 提取后的灾害天气条件下影响轨道交通客流预测的气温、天气、降水量等特征值。在客流预测中,BiLSTM 能够通过这种双向结构捕获时间序列数据中的长期依赖关系,从而提高预测的准确性。

BiLSTM 层的输出可以用于进行最终的客流预测。BiLSTM 层处理完所有时间序列数据后,其最终的隐藏状态 h_t 包含了整个时间序列的上下文信息。这些信息是预测未来客流量的关键。BiLSTM 层的输出 u_t 会被送入一个全连接层,该层将高维的隐藏状态映射到一个低维的输出空间。在客流预测中,这个低维输出通常是一个单一的预测客流量值。全连接层包含权重矩阵 W_i 和偏置向量 b_i 。权重 W_i 负责将 BiLSTM 层的输出转换为预测客流量,而偏置 b_i 则对预测结果进行平移调整。最终的预测客流量是通过全连接层的权重和偏置对 BiLSTM 层的输出 u_t 进行线性变换得到的,即

$$y_t = W_y u_t + b_y \tag{1}$$

式中: y_t 为在时间步 t 的轨道交通预测客流量,即 DRN-BiLSTM 模型的最最终预测结果; W_y, b_y 分别为全连接层的权重和偏置。模型的结构如图 1 所示, DRN-BiLSTM 组合模型的具体实施步骤如图 2 所示。

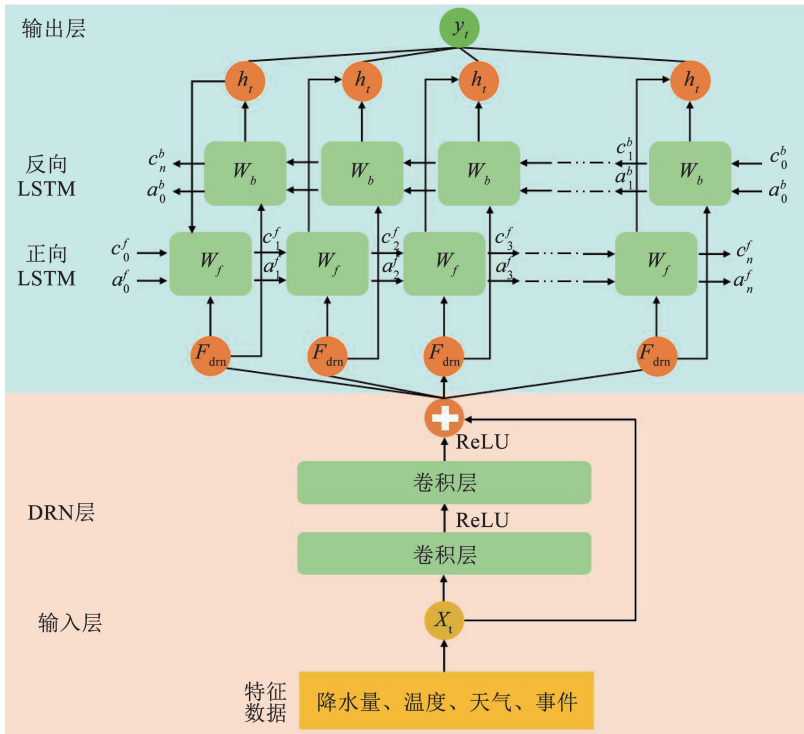


图 1 DRN-BiLSTM 模型结构示意图

Fig. 1 Schematic diagram of DRN-BiLSTM model structure

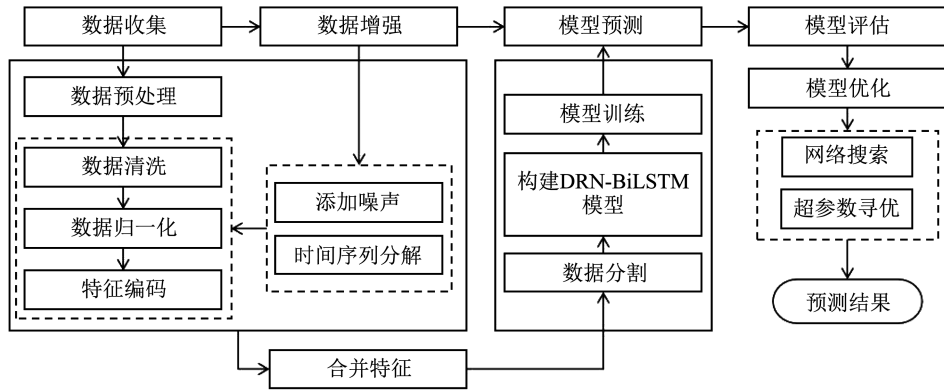


图 2 DRN-BiLSTM 模型客流预测流程

Fig. 2 DRN-BiLSTM model passenger flow prediction flowchart

2 案例分析

2.1 数据集构建

本文选取北京、深圳、郑州、哈尔滨市地铁线网

2021、2022、2023 年线网逐日客流量数据作为预测基础数据,获取逐日平均气温、降水量、灾害性天气等数据,作为客流量预测特征数据,与客流数据共同构建数据集。数据集见表 1。

表 1 案例分析数据集
Tab. 1 Case analysis dataset

日期	星期	降水量/mm	平均气温/℃	天气情况	灾害性天气预警
2021-07-19	星期一	0.068 540 261	24.069 603 71	多云 ~ 雷阵雨	—
2021-07-20	星期二	10.323 354 277	19.656 735 65	中雨 ~ 雷阵雨	暴雨红色预警
2021-07-21	星期三	30.406 403 420	18.907 437 35	雷阵雨	暴雨红色预警
2021-07-22	星期四	11.269 605 269	20.795 967 91	多云 ~ 晴	暴雨红色预警
2021-07-23	星期五	0.005 150 807	23.514 992 31	多云	—
2021-07-24	星期六	2.820 543 895	25.487 060 45	多云	—
2021-06-25	星期日	0.273 875 809	26.860 967 48	多云 ~ 晴	—

2.2 数据增强处理

数据增强^[25]是提高数据集多样性和鲁棒性的重要步骤,尤其是在处理有限数据时。本研究中采用了添加噪声和时间序列分解两种主要数据增强技术,以生成更多的训练样本,从而提高模型的性能。

1) 添加噪声:通过添加高斯噪声在原始数据中引入小的随机变化来生成新的数据样本,这些样本具有与原始数据类似的特征,但由于引入了噪声,因此增加了数据的多样性。

为了防止模型过度拟合噪声,采用了以下策略:首先,限制噪声的添加量,确保噪声的方差远小于原始数据的方差;其次,在训练过程中使用了早停法,监控验证集上的性能,以避免对噪声的过度学习;最后,通过交叉验证来评估模型的泛化能力。数据增强公式为

$$\tilde{X}(t) = X(t) + \epsilon \tag{2}$$

其中: $\tilde{X}(t)$ 为增强后的客流量数据, $X(t)$ 为原始客流量数据, ϵ 为服从正态分布 $N(0, \sigma^2)$ 的噪声。

2) 时间序列分解:将数据分解为趋势、季节性和残差 3 个主要部分,该方法有助于理解数据的基本模式,并以此生成新的数据样本。其计算公式为

$$X(t) = T(t) + S(t) + R(t) \tag{3}$$

其中: $X(t)$ 为原始时间序列数据, $T(t)$ 为趋势部分, $S(t)$ 为季节性部分, $R(t)$ 为残差部分。

3) 数据合并:通过添加噪声和时间序列分解,分别生成了两组独立的数据集。这些增强数据集可以分别捕捉数据的不同方面的变化和模式,从而增加数据的多样性。增强数据样本量对比如图 3 所示。




图3 增强数据样本量对比

Fig. 3 Comparison of sample sizes in enhanced data

2.3 评价指标

应用均方误差 (MSE)、均方根误差 (RMSE)、平均绝对误差 (MAE)、决定系数 (R^2) 4 个评价指标对模型性能进行评估。这些指标不仅能够反映模型的预测性能, 还能识别和理解模型的优缺点。

均方误差 (MSE), 用于衡量预测值与实际值之间差异的平方和的平均值。MSE 值越小, 说明模型的预测性能越好。其计算公式为

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

其中: y_i 为实际值, \hat{y}_i 为预测值, n 为样本数量。

均方根误差 (RMSE), 用于衡量预测值与实际值之间差异的平方根的平均值。RMSE 值越小, 说明模型的预测性能越好。其计算公式为

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

平均绝对误差 (MAE), 预测值与实际值之间差异的绝对值的平均值。MAE 值越小, 说明模型的预

测精度越高。其计算公式为

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

决定系数 (R^2), 用于衡量模型对数据变异的解释程度, 值域在 0 ~ 1 之间。 R^2 越接近 1, 说明模型对数据的解释能力越强。其计算公式为

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

2.4 预测模型优化

在深度学习方法中, 超参数的设置对模型性能有着至关重要的影响。合适的超参数可以显著提高模型的泛化能力和预测精度^[26]。本研究采用网格搜索 (Grid Search) 方法对 DRN-BiLSTM 模型的超参数进行系统调优。

2.4.1 网格搜索方法

网格搜索是一种常用的超参数优化方法, 其基

本原理是尝试所有可能的超参数组合,以找到最佳的模型性能。对于每个超参数,定义一个值的集合,网格搜索将遍历这些集合的所有组合。本研究中,选定了以下超参数进行调优:学习率(lr)、隐藏层维度(hidden_dim)、DRN 层数(drn_layers)、BiLSTM 层数(lstm_layers)。其数学表达式为

$$H = \prod_{i=1}^n h_i \tag{8}$$

设 H 为超参数集合, h_i 为第 i 个超参数的可能值集合, n 为超参数的数量, prod 为笛卡尔积。对于每种超参数组合 $h \in H$, 训练模型 $f(h)$ 并计算其在验证集上的性能 $L(f(h))$ 。目标是找到使得性能指标最优的超参数组合, 表达式为

$$h^* = \arg \min_{h \in H} L(f(h)) \tag{9}$$

基于前文所构建的模型,参考了类似模型在城

市轨道交通客流预测任务中的设置,考虑了模型的架构和可用的计算资源,将 lr 的搜索范围设置为 $[0.001, 0.0005, 0.0001]$, 这个范围通常在深度学习中表现良好。对于隐藏层维度,考虑覆盖从较小到较大的网络容量,将 hidden_dim 的搜索范围设置为 $[32, 64, 128]$ 。DRN 层数和 BiLSTM 层数的搜索范围考虑到增加层数可能会提高模型的学习能力,但也会增加训练难度,将搜索范围确定为 $[1, 2]$ 。

2.4.2 网格搜索结果分析

使用 Python 的 GridSearchCV 工具来实现网格搜索。通过交叉验证的方式,评估每一组超参数组合的性能,并选择表现最佳的超参数组合。网格搜索完成后,得到了最佳的超参数组合为最优参数,模型超参数组合见表 2。

表 2 模型超参数组合

Tab. 2 Model hyperparameter combinations

学习率(lr)	隐藏层维度 (hidden_dim)	DRN 层数 (drn_layers)	BiLSTM 层数 (lstm_layers)	验证损失 (val_loss)	备注
0.002	64	2	1	0.041 961 973	初始参数
0.001	32	1	1	0.090 507 448	参数寻优
⋮	⋮	⋮	⋮	⋮	
0.001	64	2	1	0.044 725 471	参数寻优
0.001	64	2	2	0.061 324 308	参数寻优
⋮	⋮	⋮	⋮	⋮	
0.001	128	1	1	0.039 919 943	参数寻优
0.001	128	1	2	0.042 487 808	参数寻优
0.001	128	2	1	0.037 620 213	参数寻优
⋮	⋮	⋮	⋮	⋮	
0.002	32	1	1	0.061 189 906	参数寻优
0.002	32	2	1	0.034 959 082	参数寻优
⋮	⋮	⋮	⋮	⋮	
0.005	128	2	2	0.025 491 442	最优参数

使用这组参数重新训练模型。结果显示,经过超参数调优后的模型在测试集上的表现有显著提升,使用最优参数后,模型的验证损失降低了约 39.25%,如图 4 所示。

超参数优化后, MSE 从 0.013 89 降低到 0.012 89, RMSE 从 0.011 785 降低到 0.011 358, 表明模型的预测精度有所提高。MAE 的降低表明优化后的模型在预测误差上有所改进。优化后的 R^2 值(0.774 97)比优化前的 R^2 值(0.708 96)高,这表明优化后的模型对数据的解释能力更强。优化后模型评估指标对比详见表 3。




图 4 优化后模型损失对比

Fig. 4 Optimized model training loss comparison

表3 DRN-BiLSTM 模型优化前后预测性能对比

Tab.3 Comparison of prediction performance before and after optimization of the DRN-BiLSTM model

模型	MSE	RMSE	MAE	R^2
超参数优化前	0.013 89	0.117 85	0.094 50	0.708 96
超参数优化后	0.012 89	0.113 58	0.088 47	0.774 97

超参数优化后,所有指标均显示出模型性能的提升。MSE 和 R^2 的提升尤为显著,表明优化后的模型不仅在预测精度上有所提高,而且在解释数据变异性方面也更加有效。

2.5 预测结果分析

按上述实验设计,经过对 DRN-BiLSTM 模型的训练,最终生成哈尔滨市地铁线网的客流预测值。通过对实际客流量与预测客流量的比较,如图5所示,可以观察到,考虑灾害性天气的情况下,该模型能够准确捕捉到客流量趋势的关键变化点,尽管在某些高峰或低谷期间存在一些偏差,但在大多数情况下,模型能够准确跟踪客流量的趋势变化。

模型在测试集上的 MSE 为 0.013 89。这个值表明模型的预测值与实际值之间的平均平方差较小,指示出模型有较好的预测精度。测试集上的 RMSE 为 0.117 85。由于 RMSE 与预测目标在同一量纲,这个值进一步证实了模型预测的准确性,显示出预测结果与真实值的平均偏差是可接受的。模型

的 MAE 值为 0.094 50。与 MSE 和 RMSE 相比,MAE 提供了预测误差的另一种度量,这个较小的 MAE 值表明模型预测的偏差较低。模型在测试集上的 R^2 为 0.708 96。这表示模型能够解释约 70.89% 的目标变量的方差,反映了模型在客流量预测方面的可靠性和有效性。

为了进一步证明模型的有效性,将 DRN-BiLSTM 模型的预测性能与标准 LSTM 和 BiLSTM 进行了比较。从表4对比数据可知,考虑灾害性天气相较于单一特征输入,可以显著提高模型的预测性能。这表明,在实际应用中,集成多种数据源可能会对预测精度有显著影响。模型预测结果对比如图6所示。

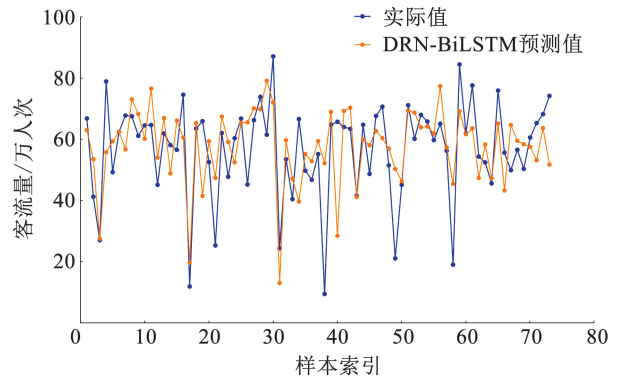


图5 DRN-BiLSTM 模型预测结果与真实值对比

Fig.5 Comparison chart of DRN-BiLSTM model prediction results and true values

表4 模型对比结果

Tab.4 Comparison results of models

模型	输入特征	MSE	RMSE	MAE	R^2
LSTM	单一特征	85.738 31	9.259 49	7.150 84	0.309 34
	考虑灾害性天气	0.016 96	0.130 27	0.097 52	0.673 47
BiLSTM	单一特征	80.773 75	8.965 14	6.899 73	0.310 28
	考虑灾害性天气	0.016 94	0.130 18	0.098 23	0.693 91
DRN-BiLSTM	单一特征	79.047 92	8.890 89	6.870 49	0.434 71
	考虑灾害性天气	0.013 89	0.117 85	0.094 50	0.708 96

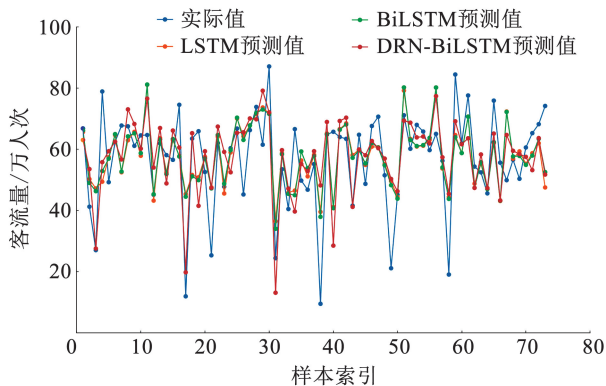


图6 灾害性天气情况下各模型预测结果对比

Fig.6 Comparison of predictive results from different models under disaster weather conditions

在单一特征情况下,BiLSTM 模型表现最佳,其次是 DRN-BiLSTM,LSTM 表现最差。在考虑灾害性天气特征输入情况下,DRN-BiLSTM 模型表现最佳,其次是 BiLSTM,LSTM 仍然表现最差。这显示了 BiLSTM 和 DRN-BiLSTM 模型在捕捉时间序列数据上的优势。

从 RMSE(均方根误差)和 MAE(平均绝对误差)两个指标可以看出,BiLSTM 和 DRN-BiLSTM 在处理单一特征时表现更好,而在多源特征上,DRN-BiLSTM 表现最优。可见 DRN 在处理多源数据特征时具有明显优势。

R^2 值在考虑灾害性天气特征模型中普遍较高,显示了多种特征共同提供的信息可以更好地解释目

标变量的方差。尤其是 DRN-BiLSTM 模型,在考虑灾害性天气情况下有很高的 R^2 值,表明其预测非常准确。

DRN-BiLSTM 相较于 BiLSTM, MSE、RMSE、MAE 分别下降 21.96%、10.46%、3.95%, R^2 提升 2.12%。DRN-BiLSTM 相较于 LSTM, MSE、RMSE、MAE 分别下降 22.10%、10.54%、3.20%, R^2 提升 5.01%。

综上所述,本文所建立的考虑灾害性天气情况下的 DRN-BiLSTM 组合模型在进行地铁线网客流量预测时,能够有效提高预测的准确性。

3 结 论

本研究构建了灾害性天气条件下的轨道交通客流 DRN-BiLSTM 组合预测模型,并对比分析了其与 LSTM、BiLSTM 的预测精度,评估了模型性能。得出主要结论如下:

1) 当仅使用单一客流数据进行预测时, BiLSTM 和 DRN-BiLSTM 模型在各项评价指标上均优于传统的 LSTM 模型,表明双向结构和深度残差网络的引入能够更有效地捕获时间序列数据的动态特性和长期依赖关系。在使用考虑灾害性天气特征数据时,所有模型的性能均得到显著提升,其中 DRN-BiLSTM 模型表现最佳,突显了在 DRN 在提取数据特征时的优势,证明了组合模型的有效性。

2) 模型对比分析结果强调了灾害性天气特征的输入在提升模型预测性能中的作用。特别是, DRN-BiLSTM 模型通过整合多种相关特征,在各评价指标上,均表现出较高的准确度和泛化能力,这表明了构建预测模型时,综合考虑与预测目标密切相关的多种特征数据,能够有效提升模型的预测能力。

3) 本文所构建的 DRN-BiLSTM 客流预测模型,经实例分析证明了其在灾害性天气特征影响下进行客流预测方面的明显优势,可以更有效精准地进行轨道交通线网客流量预测,该模型的提出可为城市轨道交通在灾害性天气发生期间城市轨道交通系统优化车辆调度、调整客流组织方式等运营决策以及提升服务质量和运营效率提供支持。

4) 本文的研究虽得了积极的结果,但研究内容和模型仍存在一些局限性,如模型在当前数据集上表现良好,但可能在不同的地理、文化或经济背景下的适用性有限。不同城市的轨道交通系统可能具有独特的客流模式,这可能需要调整模型参数或结构。未来可进一步探讨该模型在不同城市、不同线网规

模、不同数据特征下的轨道交通客流预测,以提升模型的普遍适用性。

参考文献

- [1] YANG D, CHEN K, YANG M, et al. Urban rail transit passenger flow forecast based on LSTM with enhanced long-term features[J]. IET Intelligent Transport Systems, 2019, 13(10): 1475
- [2] 华伟欣. 基于圈层的轨道交通一体化客流预测方法: 以粤港澳大湾区为视角[J]. 综合运输, 2023, 45(2): 66
HUA Weixin. A circle-based integrated passenger flow forecasting method for rail transit: a perspective of the Guangdong-Hong Kong-Macao Greater Bay Area[J]. Comprehensive Transportation, 2023, 45(2): 66
- [3] XUE Q, ZHANG W, DING M, et al. Passenger flow forecasting approaches for urban rail transit: a survey[J]. International Journal of General Systems, 2023, 52(8): 919
- [4] 李伟聪, 潘福全, 胡盼, 等. 基于季节性差分整合移动平均自回归模型的城市公交短期客流预测[J]. 济南大学学报(自然科学版), 2022, 36(3): 308
LI Weicong, PAN Fuquan, HU Pan, et al. Short-term passenger flow forecasting for urban public transportation based on seasonal difference integrated moving average autoregressive model [J]. Journal of Jinan University (Natural Science Edition), 2022, 36(3): 308
- [5] 鲁文博, 马超群, 李国栋, 等. 基于月客流量残差的地铁客流季节指数预测方法[J]. 城市轨道交通研究, 2021, 24(9): 77
LU Wenbo, MA Chaoqun, LI Guodong, et al. A forecasting method for subway passenger flow seasonal index based on monthly passenger flow residuals[J]. Urban Mass Transit, 2021, 24(9): 77
- [6] 孙承洁. 上海地铁车站客流数据预测方法研究[J]. 交通与运输, 2023, 39(5): 36
SUN Chengjie. Research on passenger flow data prediction method for Shanghai metro stations [J]. Traffic & Transportation, 2023, 39(5): 36
- [7] 唐继强, 杨璐琦, 杨武. 融合长短期记忆网络和图卷积网络的轨道交通短时客流起讫点预测[J]. 重庆大学学报, 2022, 45(11): 91
TANG Jiqiang, YAN Luqi, YANG Wu. Short-term passenger origin-destination prediction for rail transit by integrating long short-term memory network and graph convolutional network [J]. Journal of Chongqing University, 2022, 45(11): 91
- [8] 禹倩, 张亚东, 郭进, 等. 基于深度集成神经网络的城市轨道交通短时进站客流预测[J]. 铁道学报, 2023, 45(12): 37
YU Qian, ZHANG Yadong, GUO Jin, et al. Short-term inbound passenger flow prediction for urban rail transit based on deep ensemble neural network [J]. Journal of the China Railway Society, 2023, 45(12): 37
- [9] 张建旭, 宾科, 蒋雨洋. 考虑轨道出行时空分布的断面客流预测[J]. 重庆理工大学学报(自然科学), 2022, 36(6): 164
ZHANG Jianxu, BIN Ke, JIANG Yuyang. Sectional passenger flow forecasting considering the spatiotemporal distribution of rail transit travel [J]. Journal of Chongqing University of Technology (Natural

- Science), 2022, 36(6): 164
- [10] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735
- [11] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436
- [12] 管恩丞. 基于深度学习的城市轨道交通客流短时预测方法研究[D]. 扬州: 扬州大学, 2024
- GUAN Encheng. Research on short-term passenger flow prediction method for urban rail transit based on deep learning [D]. Yangzhou: Yangzhou University, 2024
- [13] 邢璐, 王玮, 刘飞, 等. 考虑峰值数据重平衡的地铁客流预测研究[J]. *铁道科学与工程学报*, 2023, 20(5): 1611
- XING Lu, WANG Wei, LIU Fei, et al. Research on subway passenger flow forecasting considering peak data rebalancing[J]. *Journal of Railway Science and Engineering*, 2023, 20(5): 1611
- [14] 史永飞. 多尺度时序特征融合的地铁短时客流预测方法[J]. *福建电脑*, 2023, 39(3): 15
- SHI Yongfei. A subway short-term passenger flow forecasting method based on multi-scale temporal feature fusion[J]. *Fujian Computer*, 2023, 39(3): 15
- [15] 姚志刚, 卢致远, 李聪聪, 等. CEEMDAN-PSO 组合优化 BiLSTM 的公交站点短时客流预测方法[J]. *北京交通大学学报*, 2023, 47(1): 74
- YAO Zhigang, LU Zhiyuan, LI Congcong, et al. A short-term passenger flow forecasting method for bus stops based on the combination optimization of CEEMDAN and PSO for BiLSTM [J]. *Journal of Beijing Jiaotong University*, 2023, 47(1): 74
- [16] 吕秋霞, 钟晓情, 任雅思. 基于 Bi-LSTM 网络的广珠城际短期客流预测方法[J]. *五邑大学学报(自然科学版)*, 2022, 36(1): 50
- LÜ Qiuxia, ZHONG Xiaqing, REN Yasi. A Short-term passenger flow forecasting method for Guangzhou-Zhuhai Intercity based on Bi-LSTM network [J]. *Journal of Wuyi University (Natural Science Edition)*, 2022, 36(1): 50
- [17] 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
- FENG Shumin, LIU Hao, LI Laicheng. A passenger flow forecasting model for rail transit under rainy and snowy weather conditions[J]. *Journal of Harbin Institute of Technology*, 2022, 54(9): 1
- [18] 施俊庆, 李睿, 程明慧, 等. 基于动态时空神经网络模型的地
铁客流预测[J]. *交通运输系统工程与信息*, 2023, 23(2): 139
- SHI Junqing, LI Rui, CHENG Minghui, et al. Subway passenger flow prediction based on dynamic spatio-temporal neural network model [J]. *Journal of Transportation Systems Engineering and Information Technology*, 2023, 23(2): 139
- [19] HU X, LIU T, HAO X, et al. Attention-based Conv-LSTM and Bi-LSTM networks for large-scale traffic speed prediction [J]. *The Journal of Supercomputing*, 2022, 78(10): 12686
- [20] GARETH J, DANIELA W, TREVOR H, et al. An introduction to statistical learning: with applications in R [M]. New York: Springer, 2013
- [21] 李淑庆, 李伟, 刘耀鸿, 等. 基于组合深度学习的轨道交通短时进站客流预测模型[J]. *重庆交通大学学报(自然科学版)*, 2024, 43(2): 92
- LI Shuqing, LI Wei, LIU Yaohong, et al. A short-term inbound passenger flow prediction model for rail transit based on combined deep learning [J]. *Journal of Chongqing Jiaotong University (Natural Science Edition)*, 2024, 43(2): 92
- [22] 刘帆, 朱强. 基于注意力机制和残差网络的地铁客流量预测方法研究[J]. *自动化与仪器仪表*, 2024(4): 11
- LIU Fan, ZHU Qiang. Research on subway passenger flow forecasting method based on attention mechanism and residual network[J]. *Automation and Instrumentation*, 2024(4): 11
- [23] 陈玺阳, 刘晨辉, 刘令, 等. 基于韧性理论的地铁线路局部中断事件应急策略[J]. *郑州大学学报(工学版)*, 2025, 46(3): 82
- CHEN Xiyang, LIU Chenhui, LIU Ling, et al. An emergency strategy for subway disruption based on resilience theory [J]. *Journal of Zhengzhou University (Engineering Science)*, 2025, 46(3): 82
- [24] 马勇. 基于时空轨迹数据的交通流量的预警方法研究[J]. *自动化技术与应用*, 2024, 43(4): 138
- MA Yong. Research on early warning method of traffic flow based on spatiotemporal trajectory data[J]. *Techniques of Automation and Applications*, 2024, 43(4): 138
- [25] 王启帆. 基于数据增强的小样本学习方法研究[D]. 北京: 北京交通大学, 2023
- WANG Qifan. Research on small sample learning methods based on data augmentation[D]. Beijing: Beijing Jiaotong University, 2023
- [26] LI Z, XU H, GAO X, et al. Fusion attention mechanism bidirectional LSTM for short-term traffic flow prediction[J]. *Journal of Intelligent Transportation Systems*, 2024, 28(4): 511