

中文引用格式: 万佳慧, 杨晓霞, 康元磊, 等. 融合物理信息与雪雁优化的地铁断面客流深度学习预测[J]. 中国安全科学学报, 2026, 36(4): 244–251.

英文引用格式: Wan Jiahui, Yang Xiaoxia, Kang Yuanlei, et al. Deep learning prediction for subway section passenger flow integrating physical information and snow geese optimization[J]. China Safety Science Journal, 2026, 36(4): 244–251.

融合物理信息与雪雁优化的地铁断面客流 深度学习预测*

万佳慧¹, 杨晓霞^{**1}教授, 康元磊²高级工程师, 邵闯³

(1 青岛理工大学 信息与控制工程学院, 山东 青岛 266520; 2 中车青岛四方机车车辆股份有限公司, 山东 青岛 266111; 3 青岛理工大学 土木工程学院, 山东 青岛 266520)

中图分类号: X951

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2026.04.0517

基金项目: 国家自然科学基金资助(62373209); 山东省泰山学者青年专家项目(tsqn202507218); 山东省高等学校青年创新团队项目(2023KJ119)。

【摘要】 为提升城市轨道交通客运量的动态调度与安全管控水平, 融合物理信息约束机制、数据驱动与雪雁优化算法(SGA), 提出一种新型深度学习框架。首先, 设计一种物理残差项, 并作为调节信号嵌入记忆细胞, 强制模型在保留时序特征的同时学习客流物理特征; 然后, 提出一种基于物理损失与数据损失的双目标适应度函数, 在建立约束机制的同时实现对模型性能的再度优化; 最后, 采用SGA平衡模型中超参数的差异化作用与协同影响。结果表明: 所构建的模型在训练集与验证集上均表现出良好的预测性能, 改进后的新适应度函数能够使模型预测结果的误差范围更小。在两阶段消融试验中, 所提出的深度学习框架较长短期记忆模型的均方误差范围缩小71.03%, 验证了物理约束机制与智能优化算法的同步引入对模型预测能力的协同增强作用。

【关键词】 物理信息; 雪雁优化算法(SGA); 地铁; 断面客流; 深度学习

Deep learning prediction for subway section passenger flow integrating physical information and snow geese optimization

Wan Jiahui¹, Yang Xiaoxia¹, Kang Yuanlei², Shao Chuang³

(1 School of Information and Control Engineering, Qingdao University of Technology, Qingdao Shandong 266520, China; 2 CRRC Qingdao Sifang Co., Ltd., Qingdao Shandong 266111, China; 3 School of Civil Engineering, Qingdao University of Technology, Qingdao Shandong 266520, China)

Abstract: The rapid growth of passenger volume of urban rail transit and the urgent need for intelligent operation have made accurate section passenger flow prediction a key technical challenge to improve the level of dynamic scheduling and safety control. To this end, this paper innovatively integrated the physical information constraint mechanism, data-driven method and SGA, and proposed a new deep learning framework. Firstly, a physical residual term was designed and embedded into memory cells as a regulation

* 文章编号: 1003-3033(2026)04-0244-08; 收稿日期: 2025-10-14; 修稿日期: 2025-12-20

** 通信作者: 杨晓霞(1988—), 女, 山东招远人, 博士, 教授, 主要从事轨道交通客流智能感知、客流安全控制、人群疏散管理等方面的研究。
E-mail: yangxiaoxia@qut.edu.cn。

signal, forcing the model to learn the physical laws of passenger flow while retaining the temporal characteristics of passenger flow. Secondly, a dual-objective fitness function based on physical loss and data loss was innovatively proposed to achieve further optimization of model performance while establishing a constraint mechanism. Finally, SGA was used to balance the differentiated and synergistic effects of hyperparameters in the model. Experimental results show that the constructed model exhibits good predictive performance on both the training set and the validation set. The improved fitness function can narrow the error range of the model prediction results. In the two-stage ablation experiment, the mean square error range of the proposed deep learning framework is reduced by 71.03% compared with the long short-term memory model, which verifies the synergistic enhancement of the model prediction ability by the simultaneous introduction of physical constraint mechanism and intelligent optimization algorithm.

Keywords: physical information; snow geese algorithm (SGA); subway; section passenger flow; deep learning

0 引言

地铁断面客流量是指在特定时间段内通过地铁线路区间某一固定横截面的总客流量,可有效反映区间运载压力与服务负荷。随着城市轨道交通智慧化运营要求的不断提高,短时客流预测技术已成为保障运输安全与提升运营效率的关键技术支撑。该技术通过深度挖掘车站历史客流数据,建立客流时空特征与动态变化之间的映射关系,实现对未来时段客流量的高精度预测。短时客流预测模型的发展经历了经典统计模型、机器学习模型和深度学习模型^[1] 3个阶段。以自回归差分移动平均(Autoregressive Integrated Moving Averag, ARIMA)和指数平滑^[2]为代表的经典统计模型的结构简洁清晰,但对客流随机性变化不够敏感^[3]。以支持向量机(Support Vector Machine, SVM)、随机森林(Random Forest, RF)^[4]为代表的机器学习模型虽然可捕捉客流动态非线性关系且动态更新能力强,但特征提取多依赖人工经验。随着理论技术的发展进步,深度学习^[5]凭借其多层次非线性特征提取能力,在复杂客流动态预测中展现出显著优势。

以长短期记忆(Long Short-Term Memory, LSTM)^[6]为代表的时序预测深度学习模型通过其独特的结构设计,能够自适应地捕捉客流数据中的长期依赖关系,克服传统机器学习模型在长周期预测中的性能衰减问题^[7]。Ouyang Qi等^[8]提出集成XGboost特征提取与LSTM编码的新型客流预测模型,证明了该模型在客流预测方面具有高于其他模型的准确性。Hou Zhongwei等^[1]提出一种融合门控循环单元-长短期记忆(Gate Recurrent Unit-Long Short-Term Memory, GRU-LSTM)的轨道交通短期客

流预测模型,客流预测的准确性和稳定性较基础LSTM的预测结果得到大幅提升。可见:LSTM及其改进模型在客流预测领域已展现出显著的技术优势和应用潜力。

鉴于此,笔者拟提出一种融合物理约束LSTM(Physics-informed LSTM, PiLSTM)与雪雁优化算法(Snow Geese Algorithm, SGA)的地铁断面客流量深度学习预测方法,首先,设计一种物理残差项,并作为调节信号嵌入记忆细胞,强制模型在保留时序特征的同时学习客流物理规律特征;然后,提出一种基于物理损失与数据损失的双目标适应度函数,在建立约束机制的同时实现对模型性能的再度优化;最后,采用SGA平衡模型中超参数的差异化作用与协同影响,以期提升城市轨道交通客运量的动态调度与安全管控水平。

1 基于深度学习的地铁断面客流预测SGA-PiLSTM模型构建

融合客流数据物理信息约束,本文构建的一种基于深度学习的地铁断面客流预测SGA-PiLSTM模型如图1所示,其中,虚线代表前一时刻的细胞状态^[9]。

1.1 数据预处理模块

首先,利用最小-最大归一化法预处理时序客流量数据集^[10];然后,将归一化后的时序数据划分为训练集和验证集;最后,基于滑动窗口法^[11]将连续时间步的数据重构为子序列 $X^{(i)}$ 。

1.2 PiLSTM模块

预处理后的地铁客流量数据被传递至PiLSTM模块,开始正向传播。基础LSTM模型通过遗忘门、输入门、记忆细胞和输出门学习数据序列特征,筛选




图1 SGA-PiLSTM 结构
Fig. 1 SGA-PiLSTM structure

信息选择遗忘或保留,传播过程定义如下^[9]:

首先,遗忘门根据当前输入和上一时刻的隐藏状态,决定细胞状态中信息的保留与遗忘;其次,输入门把当前信息和记忆信息存入记忆细胞,并结合遗忘门信息、输入门信息及物理信息进行细胞状态更新;然后,输出门控制细胞状态,并将当前时刻的隐藏状态转化为预测输出 h_t ,完成模型数据的正向传播;最后,数据流开始反向传播,并基于 LSTM 当前时刻的输出计算由物理信息约束得到的物理残差项,重新进入 LSTM 的隐藏状态更新阶段。如下式,将 L_t 作为调节信号嵌入细胞状态^[12],得到融入物理损失项的当前细胞状态 $\tilde{C}_t$ 。

$$\tilde{C}_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t + \lambda \cdot L_t \quad (1)$$

式中: f_t 为遗忘门的输出; i_t 为输入门的输入; C_{t-1} 为上一时刻的细胞状态; $\tilde{C}_t$ 为候选细胞状态; λ 为残差权重系数; L_t 为综合物理信息约束残差项。

输出门基于融入物理损失项的当前细胞状态重新计算当前时刻的隐藏状态^[12],如下式。当达到最终时间步后,当前时刻的隐藏状态转化为预测输出,得到下一时间步的断面客流量预测值。

$$h_t = o_t \odot \tanh(\tilde{C}_t) \quad (2)$$

式中 o_t 为输出门的输出。

在这个过程中, LSTM 引入 L_t 修正权重矩阵和偏置项,强制模型在保留时序特征的同时,使记忆细胞学习物理规律约束,构建数据驱动与物理约束融合的断面客流预测模型 PiLSTM。以数据平滑性约束和周期性约束为基础的综合物理信息约束残差项定义为下式:

$$L_t = \alpha \cdot L_s + (1 - \alpha) \cdot L_z \quad (3)$$

式中: α 为正则化权重系数; L_s 为数据平滑性约束; L_z 为周期性约束。

在 L_s 中,基于相邻时间步的地铁客流量变化不会在短时间内剧烈波动的物理规律, L_s 需使模型输出在时间维度上保持平滑,避免相邻时间步的预测值出现不合理突变,如下式:

$$L_s = \frac{1}{T-1} \sum_{t=1}^{T-1} |y_{t+1} - y_t| \quad (4)$$

式中: T 为时间序列长度; y_t 为时间步 t 的输出值; y_{t-1} 为时间步 $t-1$ 的输出值。

在 L_z 中,客流量变化有一定周期性规律, L_z 需学习周期模式,使预测值与历史同期数据变化趋势一致,如下式:

$$L_z = \frac{1}{T-u} \sum_{t=1}^{T-u} |y_{t+u} - y_t| \quad (5)$$

式中: u 为周期长度; $T-u$ 可以确保索引在范围内; y_{t+u} 为时间步 $t+u$ 的输出值。

1.3 SGA 超参数寻优模块

为求解模型中的最优超参数,提出基于 SGA^[13] 分层协作机制更新个体位置,平衡全局搜索与局部优化能力,算法见表 1,从而实现对单元数、学习率和批大小 3 项超参数的寻优。

1) 创新适应度函数。将物理残差项嵌入 SGA 超参数寻优的适应度函数中,提出基于最小化数据损失和物理损失的适应度函数,均方误差 (Mean Square Error, MSE) 代表数据损失,如下式,以提升模型的预测能力和物理解释水平,并衡量模型预测值与实际数据间的差距。

表 1 算法 1 基于 SGA 的预测模型超参数求解

Table 1 Algorithm 1 hyperparameter solution of prediction model based on SGA

1: 开始
2: 初始化种群及相关参数设置
3: 生成初始种群位置矩阵 P 和速度矩阵 V
4: 定义式(6)为新适应度函数 F
5: 依据式(3)一式(5)定义物理损失
6: 依据式(7)定义数据损失
7: 计算初始适应度值 F
8: 当 $m < M$ 时
9: 计算雪雁的飞行角度 θ
10: 若 $\theta < \pi$
11: 进入人字形飞行阶段
12: 进行种群速度的更新
13: 进行个体的适应度值排序
14: 更新适应度排序前 20% 的个体位置
15: 更新适应度排序后 20% 的个体位置
16: 更新其他个体位置
17: 若 $\theta \geq \pi$
18: 进入直线飞行阶段
19: 更新种群位置
20: 重新计算适应度值 F
21: 更新全局最优解
22: 当 $m = M$ 时
23: 结束
24: 返回最优超参数组合

$$F = \underbrace{\beta \cdot \text{MSE}}_{\text{数据损失}} + \underbrace{(1 - \beta) \cdot L_p}_{\text{物理损失}} \quad (6)$$

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (7)$$

式中: β 为损失权重; N 为样本数量; y_i 为真实值; $\hat{y}_i$ 为预测值。

2) PiLSTM 中超参数的迭代优化。初始化种群,随机生成一组代表雪雁位置的解 $P = [p_{ij}]_{n \times d}$ 和代表雪雁速度的解 $V = [v_{ij}]_{n \times d} (i = 1, 2, \cdots, n, j = 1, 2, \cdots, n)$, 并评估个体初始适应度值,标记初始最优解。 P 和 V 表示的候选解代表 PiLSTM 中单元数、学习率和批大小的不同超参数组合。接着,利用下式生成雪雁的飞行角度 θ ,依据 θ 的取值将雪雁的位置更新策略分为人字形飞行策略和直线飞行策略 2 个阶段。

$$\theta = \frac{2\pi \cdot m}{M} \quad (8)$$

式中: m 为迭代次数; M 为最大迭代次数。

当 $\theta < \pi$ 时,进入人字形飞行阶段,进行种群速度和种群位置的更新,根据个体的适应度值排序进行 PiLSTM 模型中超参数组合的更新。当 $\theta \geq \pi$ 时,

种群开始采用直线飞行方式。进而,进行种群速度和种群位置的更新,以避免陷入局部最优解并继续更新当前最优超参数组合。

3) 终止条件。根据种群更新后的位置,重新计算个体适应度,并记录每次迭代的最优解。循环上述过程直至最大迭代次数,得到适应度值最优的个体位置,进而获取 PiLSTM 中单元数、学习率和批大小的最优组合。

2 SGA-PiLSTM 模型的案例分析

2.1 地铁断面客流预测模型参数设置及预测结果

基于 SGA-PiLSTM 模型分析地铁断面客流时序数据建模时,以过去 24 h 为滑动窗口,并预测未来 1 h 的地铁断面客流量数据。数据集的划分遵循时序连续性原则,将前 22 天的客流量数据作为训练集,将后 9 天的客流量数据作为验证集,完整覆盖该月客流波动周期。在训练集基础上,通过 SGA 进行 PiLSTM 中超参数的自适应调优,最终得到具体的参数配置,见表 2。

表 2 SGA-PiLSTM 模型中参数的设置

Table 2 Parameter setting in SGA-PiLSTM model

参数	数值
n	20
M	60
d	3
单元数	[16, 128]
批大小	[16, 128]
学习率	[0.000 1, 0.01]
t	1 h
u	24 h
D	24 h
α	0.4
β	0.6

表 3 为 SGA-PiLSTM 模型在训练集和验证集上的预测效果,可以发现,模型在训练集上的决定系数 R^2 可达 0.98,表明其能够解释 98% 的客流波动特征,展现出卓越的预测能力;且均方根误差 (Root Mean Square Error, RMSE) 和平均绝对误差 (Mean Absolute Error, MAE) 表征的误差范围较小,表明模型拥有对客流特征的精准捕捉能力。在验证集中,模型的误差指标较训练集虽稍有上升,但仍显示出良好的预测性能。图 2 进一步揭示了模型的预测行为特征;训练集下预测曲线与真实值高度重合,尤其在客流高峰时段展现出平滑的跟踪能力;验证集下预测结果虽存在局部偏差,但整体趋势吻合度仍维

持在 90% 以上。

表 3 训练集和验证集下模型预测性能的评价指标值

Table 3 Evaluation index values of model predictive performance under training set and validation set

模型	SGA-PiLSTM			
	MSE	MAE	RMSE	R^2
训练集	43 365. 3	129. 56	208. 24	0. 980 1
验证集	125 594. 7	202. 83	354. 39	0. 920 3





图 2 在训练集和验证集上的真实值与预测值对比

Fig. 2 Comparison of actual and predicted values on training set and validation set

合现象; 以 GRU、卷积神经网络 (Convolutional Neural Network, CNN) 为代表的深度学习模型表现中等, 模型间存在性能差异。模型误差指标对比效果如图 3 所示, SGA-PiLSTM 在验证集上展现出显

著优势, 其误差指标均优于对比模型, 且训练与验证阶段的性能差异较小, 展现出更强的泛化能力和预测稳定性。

表 4 训练集和验证集下不同模型预测性能的评价指标值

Table 4 Evaluation index values of different models' predictive performance under training set and validation set

模型	训练集				验证集			
	MSE	MAE	RMSE	R^2	MSE	MAE	RMSE	R^2
ARIMA	800 746. 3	510. 52	894. 84	0. 638 1	714 997. 5	504. 12	845. 58	0. 546 5
SARIMA	147 800. 61	202. 32	384. 45	0. 933 6	607 958. 35	447. 81	779. 72	0. 564 7
GRU	582 456. 8	598. 32	763. 18	0. 632 5	605 881. 2	611. 96	778. 38	0. 615 7
CNN	15 2897. 5	245. 68	391. 02	0. 847 6	184 205. 3	268. 45	429. 20	0. 802 3
SVM	177 668. 1	610. 61	421. 51	0. 919 7	540 592. 6	610. 61	735. 25	0. 657 1
RF	11 551. 5	51. 61	107. 48	0. 994 8	157 951. 9	218. 13	397. 43	0. 899 8

2.2 适应度函数中损失权重敏感性分析

为深入探究物理损失和数据损失对式(6)所示的适应度函数协同作用的机制, 基于 SGA-PiLSTM 框架, 通过动态调整适应度函数中损失权重 β , 得到 β 在 $[0, 1]$ 区间内连续变化时模型最优适应度取值与 RMSE 的响应特性, 如图 4 所示。由图 4 可知: 当 $\beta = 0$ 或 $\beta = 1$ 时, 模型呈现出较高的误差范围与较大的最优适应度取值, 表明模型因过度依赖物理损

失或数据损失而导致预测机制失衡; 随着 β 增至 $[0.4, 0.7]$ 区间范围内, RMSE 下降至 $[400, 600]$ 范围内, 且适应度函数在 $\beta = 0.6$ 时获得最小值, 实现了误差范围显著缩小与适应度取值的优化; 当 β 逐步增至 1 时, RMSE 与最优适应度取值均表现出上升趋势, 误差范围再度扩大。结合试验数据可知: 损失权重 β 存在临界阈值效应, 极端权值分配会破坏物理约束与数据特征的动态平衡, 而适度融合可




图 3 模型预测性能对比

Fig. 3 Comparison of model predictive performance

充分发挥二者的协同优势。




图 4 适应度函数中损失权重动态调整对模型预测性能的影响分析

Fig. 4 Analysis of impact of dynamic adjustment of loss weights in fitness function on model predictive performance

2.3 2 阶段消融试验

为系统评估 SGA-PiLSTM 较基础模型在断面客流预测中的性能,选取该月后 9 天的客流量数据,开展消融试验,变体模型的预测性能指标结果见表 5,不同模型中采用的参数见表 6。通过对比 PiLSTM

与 LSTM 可以得到,引入物理约束使得模型 的 MSE 降低了 62.95%, R^2 提高 23.41%;对比 SGA-PiLSTM 和 PiLSTM 可以得出,SGA 优化算法的融入将 MSE 降低了 21.82%,同时将 R^2 提高 2.45%,且 SGA-LSTM 相较 LSTM 的 RMSE 降低 17.96%。试验表明:物理信息约束机制与智能优化的有机融合使得 SGA-PiLSTM 兼具真物理与高精度特征,能有力增强 SGA-PiLSTM 对断面客流预测的稳定性和可解释性。

表 5 消融试验中预测性能指标的对比

Table 5 Comparison of predictive performance indicators in ablation experiments

模型	误差指标			
	MSE	MAE	RMSE	R^2
SGA-PiLSTM	123 821.007 7	248.954 9	351.882 1	0.921 5
SGA-LSTM	287 741.696	361.061 8	536.415 6	0.817 5
PiLSTM	158 380.600 2	241.011 9	397.970 6	0.899 5
LSTM	427 483.377 5	331.872 1	653.822 1	0.728 9

通过调整物理约束的数量,开展第二维度的消融试验,4 种模型的试验结果见表 7,模型释义见表 8。通过对比模型 3 和模型 4,可以发现,模型 3 的各项误差指标范围较模型 4 分别下降 56.97%、31.05%、34.41%,且 R^2 上升 12.72%,这意味着失

表 6 模型参数的设置
Table 6 Setting of model parameters

模型	PiLSTM 单元数	批大小	学习率	目标 函数
SGA-PiLSTM	90	16	0.001 2	F
SGA-LSTM	116	16	0.008 5	MSE
PiLSTM	66	24	0.005	F
LSTM	32	24	0.005	MSE

去所有物理约束后模型的预测精度显著下滑且误差范围大幅扩张;同时,模型 3 较模型 2、模型 3 较模型 1,其 MSE 分别下降 54.05%和 29.49%,这意味着无论是失去平滑性约束亦或是失去周期性约束对模型均有不同程度的精度损失。试验表明:融合平滑性约束与周期性约束的综合物理信息约束能够有效提升 SGA-PiLSTM 模型的预测精度,证实基于客流量规律的物理信息约束在模型预测过程中的关键调控作用,增强了模型对复杂客流模式的解释能力。

表 7 基于物理约束的消融实验中预测性能指标的对比

Table 7 Comparison of predictive performance metrics in ablation experiments based on physical constraints

SGA-PiLSTM	误差指标			
	MSE	MAE	RMSE	R^2
模型 1	175 620.120 6	271.265 4	419.070 5	0.888 6
模型 2	269 482.893 7	288.981 7	519.117 4	0.829 1
模型 3	123 821.007 7	248.954 9	351.882 1	0.921 5
模型 4	287 741.696	361.061 8	536.415 6	0.817 5

表 8 模型释义

Table 8 Model interpretation

模型	约束条件
模型 1	$L_r = L_s$
模型 2	$L_r = L_z$
模型 3	$L_r = \alpha \cdot L_s + (1 - \alpha)L_z$
模型 4	无约束

3 结 论

1) 提出一种融合物理信息约束的地铁断面客流深度学习预测 SGA-PiLSTM 模型。通过采用约束机制参与 LSTM 细胞更新过程,能够有效控制模型对学习特征的遗忘与保留;同时,引入 SGA 动态平衡各参数的差异化作用与协同影响,获得适应度最优的配置;通过构建双目标耦合适应度函数,将短时客流的平滑性约束与周期性约束编码为物理损失项,并与数据驱动的 MSE 损失相结合。

2) 试验结果表明:SGA-PiLSTM 在训练集和验证集下的 R^2 可达 98%、92%,表明模型具备良好的预测能力。基于物理损失和数据损失的适应度函数较以 MSE 为适应度函数的模型预测能力更强, RMSE 降低 51.75%。在两阶段消融试验中,SGA-PiLSTM 优势凸显。与基础的 LSTM 相较, MSE、MAE、RMSE 分别减小 71.03%、24.98%、46.18%,且 R^2 提升 26.42%,验证了物理约束机制与智能优化的融合对预测模型性能提升的协同作用。

参 考 文 献

[1] Hou Zhongwei, Du Zixue, Yang Guang, et al. Short-term passenger flow prediction of urban rail transit based on a combined deep learning model[J]. Applied Sciences, 2022, 12(15): DOI: 10.3390/app12157597.

[2] Wang Xueqin, Xu Xinyue, Wu Yuankai, et al. An effective spatiotemporal deep learning framework model for short-term passenger flow prediction[J]. Soft Computing, 2022, 26(12): 5 523-5 538.

[3] Huang Juichan, Ko Kuomin, Shu Minghung, et al. Application and comparison of several machine learning algorithms and their integration models in regression problems [J]. Neural Computing and Applications, 2020, 32 (10): 5 461-5 469.

[4] 周新民, 金江涛, 鲍娜娜, 等. 基于注意力卷积长短期记忆模型的城市出租车流量预测[J]. 中国安全科学学报, 2024, 34(7): 153-160.

Zhou Xinmin, Jin Jiangtao, Bao Nana, et al. Urban taxi traffic flow prediction based on attentive ConvLSTM-ResNet model[J]. China Safety Science Journal, 2024, 34(7): 153-160.

[5] 金坤. 基于互联网搜索指数的地铁客流预测研究[D]. 兰州:兰州交通大学, 2022.

Jin Kun. Forecasting research of subway passenger flow based on internet search index[D]. Lanzhou: Lanzhou Jiaotong University, 2022.

[6] 吴安坤, 吴仕军, 丁旻, 等. 基于 LSTM 循环神经网络的雷电潜势预测[J]. 中国安全科学学报, 2023, 33(8): 117-124.

Wu Ankun, Wu Shijun, Ding Min, et al. Prediction of lightning potential based on LSTM recurrent neural network[J]. China Safety Science Journal, 2023, 33(8): 117-124.

[7] 张念, 周彩凤, 万飞, 等. 基于 BERT-BiLSTM-CRF 的隧道施工安全领域命名实体识别[J]. 中国安全科学学报, 2024, 34(12): 56-63.

Zhang Nian, Zhou Caifeng, Wan Fei, et al. Tunnel construction safety domain named entity recognition based on BERT-BiLSTM-CRF[J]. China Safety Science Journal, 2024, 34(12): 56-63.

[8] Ouyang Qi, Lyu Yongbo, Ma Jihui, et al. An LSTM-based method considering history and real-time data for passenger flow prediction[J]. Applied Sciences, 2020, 10(11): DOI: 10.3390/app10113788.

[9] Zhao Zheng, Chen Weihai, Wu Xingming, et al. LSTM network: a deep learning approach for short-term traffic forecast[J]. IET Intelligent Transport Systems, 2017, 11(2): 68-75.

[10] 卢佳乐, 张念, 牛萌萌, 等. 基于 Stacking 集成学习的隧道突水危险预测模型[J]. 中国安全科学学报, 2025, 35(4): 137-144.

Lu Jiale, Zhang Nian, Niu Mengmeng, et al. Hazard prediction model of tunnel water intrush based on stacking ensemble learning[J]. China Safety Science Journal, 2025, 35(4): 137-144.

[11] 高媛, 鲁曼曼, 林勇, 等. 基于双模块卷积神经网络的 TCR-多肽结合位点预测[J]. 软件工程, 2024, 27(5): 51-55.

Gao Yuan, Lu Manman, Lin Yong, et al. Prediction of TCR-peptide binding sites based on dual-module convolutional neural network[J]. Software Engineering, 2024, 27(5): 51-55.

[12] Lu Yingkang, Li Yanfei, Fu Gaocai, et al. The physical information LSTM surrogate model for establishing a digital twin model of reciprocating air compressors[J]. Applied Soft Computing, 2024, 167: DOI: 10.1016/j.asoc.2024.112309.

[13] Tian Aiqing, Liu Feifei, Lyu Hongxia. Snow geese algorithm: a novel migration-inspired meta-heuristic algorithm for constrained engineering optimization problems[J]. Applied Mathematical Modelling, 2024, 126: 327-347.



作者简介： 万佳慧 （2001—）,女,山东青岛人,硕士研究生,研究方向为智能交通与协同控制。E-mail: wanjiahmm@163.com。