

中文引用格式:吴振坤,彭敏,朱国庆,等.侧向多开口地铁列车和隧道温度特征参数预测[J].中国安全科学学报,2026,36(1):130-137.

英文引用格式:WU Zhenkun, PENG Min, ZHU Guoqing, et al. Study on prediction of temperature characteristic parameters for subway train with multiple lateral openings and tunnels [J]. China Safety Science Journal, 2026, 36(1): 130-137.

侧向多开口地铁列车和隧道温度特征参数预测^{*}

吴振坤^{1,2}讲师,彭敏^{**2}副教授,朱国庆²教授,刘璐²,秦东子³

(1 无锡学院 应急管理学院,江苏 无锡 214105;2 中国矿业大学 安全工程学院,江苏 徐州 221116;

3 中国科学技术大学 火灾科学国家重点实验室,安徽 合肥 230026)

中图分类号:X951

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2026.01.1196

基金项目:国家重点研发计划项目(2023YFC3009900);国家自然科学基金资助(52574289,52204254);江苏省自然科学基金资助(BK20221124);公共火灾防治技术四川省高等学校重点实验室开放基金资助(SC_KLPFPCT2024Z02)。

【摘要】为解决现有地铁列车和隧道火灾预测方法大多依赖于物理模型和经验公式而导致预测精度不足的问题,从人工智能角度出发,基于遗传算法(GA)优化反向传播神经网络(BPNN),构建GA-BPNN网络模型;利用GA对BPNN的权重和阈值进行全局寻优;训练与预测车厢与隧道顶棚温度分布,智能反演火灾温度场。结果表明:GA-BPNN模型对车厢温度预测的平均绝对误差(MAE)为8.17,均方根误差(RMSE)为9.76,决定系数 R^2 为0.99;隧道温度预测的MAE为3.95, RMSE为5.63, R^2 为0.98。通过对比发现,GA-BPNN模型在准确性和泛化能力上都优于传统BPNN模型。

【关键词】侧向多开口;地铁列车;温度预测;特征参数;反向传播神经网络(BPNN);遗传算法(GA)

Study on prediction of temperature characteristic parameters for subway train with multiple lateral openings and tunnels

WU Zhenkun^{1,2}, PENG Min², ZHU Guoqing², LIU Lu², QIN Dongzi³

(1 School of Emergency Management, Wuxi University, Wuxi Jiangsu 214105, China;

2 School of Safety Engineering, China University of Mining and Technology, Xuzhou

Jiangsu 221116, China; 3 State Key Laboratory of Fire Science, University of Science and Technology of China, Hefei Anhui 230026, China)

Abstract: Existing methods for predicting temperature from subway carriage and tunnel fires mainly rely on physical models and empirical methods that are valid only under narrowly-defined environmental conditions. To solve this issue, this study adopts an artificial-intelligence-based approach. A GA-BPNN network model is constructed by optimizing BPNN using a GA. The GA is employed to global optimize BPNN's weights and thresholds, after which the model is trained to predict the temperature distribution of both the subway carriage and the tunnel, thereby achieving intelligent inversion of the fire temperature field. The results show that, for subway carriage temperature prediction, GA-BPNN model yields a mean

* 文章编号:1003-3033(2026)01-0130-08; 收稿日期:2025-09-05; 修稿日期:2025-11-22

** 通信作者:彭敏(1995—),女,安徽宿州人,博士,副教授,主要从事城市轨道火灾安全研究。E-mail:pengmin@cumt.edu.cn。

absolute error (MAE) of 8.17, a root mean square error (RMSE) of 9.76, and a coefficient of determination (R^2) of 0.99. For tunnel temperature prediction, MAE is 3.95, RMSE is 5.63, and R^2 reaches 0.98. By comparing the results with those of the traditional BPNN, it is found that the GA-BPNN model outperforms the conventional BPNN in both prediction accuracy and generalization capability.

Keywords: multiple lateral openings; subway train; temperature prediction; characteristic parameters; back-propagation neural network (BPNN); genetic algorithm (GA)

0 引 言

城市轨道交通系统直接关乎千万级人口的生命安危与城市运行秩序^[1]。然而,在地下封闭空间与高密度客流耦合作用下,各类致灾风险正以指数级增长的复杂程度威胁着系统韧性。其中,火灾以其链式灾害效应之烈、伤亡后果之重,占据地铁防灾措施的首位。列车车厢一旦发生火灾,热辐射、有毒烟气和火焰射流等将在三维空间内形成湍流耦合灾害场,其温度跃迁速度可达开放环境的 6~8 倍^[2]。尤为严峻的是,侧向多开口列车结构迥异于传统轴对称火灾羽流模型假设—开口处的空气卷吸效应与纵向活塞风形成非稳态流场,导致顶棚下方产生周期性热振荡,这种热不稳定性将加速可燃物热解速率^[3],加剧火灾危险性。因此,研究侧向多开口地铁列车顶棚火灾特性对于该类空间消防安全具有重要意义,特别是对顶棚温度特征参数的预测,是评价火灾隐患和指导消防应急救援决策的关键因素。

目前,关于侧向多开口地铁列车结构的研究通常采用试验研究、理论分析和数值模拟法,重点关注火灾时顶棚下方烟气温度分布、烟气流动规律、通风和排烟模式和火源特性等方面。NG 等^[4]分析了 1/15 列车模型在通风受限条件下的火焰特征。姜学鹏等^[5]利用火灾模拟软件研究了不同车门开闭状态下车厢火灾发展情况。SHI Conglin 等^[6]通过全尺寸地铁列车车厢试验研究了热释放速率、侧向开口破裂特性、火灾烟气浓度和温度分布特性。彭敏等^[7]通过试验研究了侧向多开口车厢火灾发展的影响因素。INGASON^[8]在 1/10 的模型中,测定了车厢热释放速率,表明车厢内火灾发展主要受通风(开口数量)因素的控制。LÖNNERMARK 等^[9]通过 1/3 地铁车厢模型研究了地铁车厢内初始火势蔓延和发展特征。PENG Min 等^[10-11]研究了侧向多开口狭长车厢端部火的辐射热流、温度分布和烟层高度特性。钟茂华等^[12]采用全尺寸试验获取了实体车站火灾过程中的烟气扩散特征参数。XI Yanhong

等^[13-14]设计了侧开口狭长列车模型,通过试验模拟车窗破裂研究了不同开口尺寸的侧向单开口狭长车厢从燃料控制到通风控制的车厢内温度特性,并定性分析了火焰溢出特征。YANG Juntao 等^[15]以全尺寸地铁站为例,研究了屏蔽门开启方式、地铁几何特性和通风速度对火灾烟雾流向站台和车内乘客疏散的影响。上述分析看出,传统研究多分析侧向多开口地铁列车火灾发生时的热烟气动力学特性、火灾扩散规律以及逃生过程等方面,并建立大量经验模型。但由于火灾燃烧特性的复杂多样性,传统经验模型在真实工程应用中难以很好地预测不同现实场景下的火羽流特征参数^[16]。其主要原因是传统经验模型受特定试验环境和理论简化的限制。

鉴于此,笔者拟结合人工智能技术,提出一种自适应数据生成算法——遗传算法 (Genetic Algorithm, GA) 优化的反向传播神经网络 (Back-Propagation Neural Network, BPNN) 模型,将传感器系统采集的“大而粗”时空尺度温度特征参数转化为火灾的精细温度场。模型以 BPNN 为核心,该网络由多层神经元构成,可在输入层逐级传递并线性组合多源特征,并通过权重与阈值的反向传播训练逼近最小误差,实现非线性映射与复杂模式预测。然而 BPNN 易陷入局部极小,故引入 GA,其全局优化能力可在种群迭代中不断演化,最终为 BPNN 提供最优或近似最优的初始权重与阈值,以期提升火灾温度特征参数预测精度。

1 地铁列车和隧道模型设计

以某市地铁 B 型 6 编组地铁列车及隧道为原型建立数值模型。隧道总长为 360.0 m,隧道断面尺寸为 6.0 m×4.8 m (长×高),车厢尺寸为 120 m×2.8 m×3.8 m (长×宽×高),单节列车尺寸为 20 m×2.8 m×3.8 m (长×宽×高),2 节车厢中间连接处为联通状态,列车两端为封闭状态。隧道模型截面设计为拱形,材料为混凝土,密度为 2 280.0 kg/m³;地铁车厢的墙壁材料均为铁,密度为 7 850.0 kg/m³,

隧道两端为开启状态。每节车厢一侧各有 4 扇车门,车门尺寸为 1.4 m×0.2 m×1.8 m(长×宽×高)。当车厢内发生火灾,车厢一侧靠近站台的门全开模拟人员逃生。具体模型如图 1 所示。




图 1 地铁车厢和隧道模型

Fig. 1 Model of subway carriages in tunnel

火源位于列车正中心处,尺寸为 2.0 m×2.0 m×0.2 m(长×宽×高)。热释放速率分别取 2.5、5.0、7.5、10.0 MW,燃料为正庚烷。地铁车厢采用机械供风,纵向风速为 1.5 m/s。环境温度设定为 25℃,模拟时间统一设置为 500 s。模拟工况见表 1。

表 1 模拟工况

Table 1 Simulated fire conditions

序号	热释放速率/MW
1	2.5
2	5.0
3	7.5
4	10

隧道地铁列车模型中热电偶位置设置如下:

1) 在列车内热电偶距顶棚 0.6 m 处,火源左右各 20.0 m 内均间隔 0.5 m,左右较远位置均间隔 1 m,共设 161 个热电偶。

2) 隧道内热电偶距顶棚 0.6 m,距火源由近及远位置间隔依次为 1、5 和 10 m,共设 79 个。

根据前人研究^[17]分析和确定网格尺寸。结合下式,选取 0.1~0.5 m 中 4 种不同尺寸的网格进行独立性检验,具体尺寸见表 2。

$$D^* = \left(\frac{Q}{\rho_\infty c_p T_\infty \sqrt{g}} \right)^{\frac{2}{5}} \tag{1}$$

式中: D^* 为特征直径; Q 为热释放速率,kW; ρ_∞ 为环境密度,kg/m³; c_p 为定压比热,kJ/(kg·K); T_∞ 为环境温度,K; g 为重力加速度,m/s²。

为兼顾精度和计算成本,将地铁车厢模型划分为 4 个区域,列车车厢火源两侧 60 m 分别选取网格 1 和网格 2,而隧道两端 120 m 处分别选取网格 3 和网格 4。

表 2 网格尺寸方案

Table 2 Mesh size scheme

序号	长×宽×高/(m×m×m)	网格总数
1	0.1×0.1×0.1	10 368 000
2	0.2×0.2×0.2	1 260 000
3	0.4×0.4×0.4	162 000
4	0.5×0.5×0.5	82 944

2 地铁列车车厢温度预测模型与方法

2.1 BPNN 模型结构

BPNN 是典型的 3 层前馈网络:输入层、隐藏层、输出层^[18]。输入层接收外部特征 X ,每个圆圈对应一个特征维度;信号继续向右进入隐藏层,先经激活函数 f_1 得到隐藏神经元 α_i ,再经 f_2 得到 β_i ,从而把原始输入映射为更高层次的表征;随后 β_i 送入输出层,产生最终预测值。隐藏神经元 α_i 和 β_i ,见下式。输出值与期望结果比较后得到误差,迭代更新连接各神经元的权重和偏置 b ,直至网络输出逼近目标精度。

$$\alpha_i = \sum_{j=1}^n w_{ij} + b_i \tag{2}$$

$$\beta_i = \sum_{j=1}^n k_{ij} \alpha_j + c_i \tag{3}$$

式中: i 为隐藏层的神经元个数; j 为输入层所有节点个数; n 为特征数; w 为权重; k 为输出层神经元个数; c 为偏置参数。

2.2 GA 优化算法结构

GA 的优化结构可概括为编码—初始化—评价—进化循环—终止输出 5 个环节^[19]。首先,把待求问题的可能解抽象为一组“染色体”,常用二进制串、实数串或排列串表示;随后随机生成一定规模的初始种群,每个染色体即一个潜在解。接着,依据具体问题的目标设计适应度函数,为每条染色体打分,优劣立判。在每次迭代中,以高适应度优先原则从当前种群选取父代,当达到预设的迭代次数、满意解阈值或时间上限等终止条件时,输出种群中适应度最高的染色体,即为算法寻得的最优解。

2.3 超参数确定

神经网络的主要超参数包括神经元数量、学习率和训练迭代次数等,超参数的设定会影响模型预测结果准确性。因此,模型训练期间应当优化超参数,以确保预测结果达到预期。

1) 迭代次数。在 GA-BPNN 模型训练过程中,

迭代次数决定了学习算法遍历整个训练数据集的次数。每次迭代均代表着每个数据都有可能修正内部模型参数。然而,并非迭代次数越多,模型表现就越好,更关键的是要考虑模型准确性^[20]。结合研究^[21]设定6种不同的迭代次数:250、500、1 000、1 500、2 000、3 000,确定出最佳迭代次数。在保持其他参数不变前提下,调整模型迭代次数,并分别计算出对应测试集的均方根误差(Root Mean Square Error, RMSE)及决定系数 R^2 见表3。

表3 不同迭代次数下模型的评估指数
Table 3 Evaluation indices of the model under different iterations

迭代次数	RMSE	R^2
250	5.403 0	0.971 7
500	5.185 4	0.973 3
1 000	5.617 4	0.970 0
1 500	6.008 9	0.970 1
2 000	6.779 7	0.968 7
3 000	7.283 7	0.964 5

由表3可知:随着迭代次数增加,测试集的RMSE首先降低,从5.4030降至5.1854。随后,随着迭代次数增加,测试集RMSE值逐步增加,从5.1854逐渐增大到7.2837。而测试集 R^2 呈现与RMSE相反的变化趋势。当迭代次数为250次时, R^2 为0.9717;迭代次数增加到500次, R^2 值增加到0.9733。随后,随着迭代次数增加, R^2 逐步降低。综合考虑,最终选择RMSE值最小, R^2 值最接近1的迭代次数。因此,GA-BPNN模型迭代次数确定为500。

2) 学习率。学习率是神经网络训练中一个可调整的超参数,通常取值在0.001~0.01之间。一般来说,较大的学习率可以让模型更快地学习,而较小的学习率通常需要花费大量训练时间。因此,通过多次试验确定出一个合适的学习率值0.001。

3) 激活函数。在隐藏层中,第*i*个隐藏神经元 α_i 携带的信息由激活函数 f_1 传递到 β_i 。然后,激活函数 f_2 进一步处理 β_i 并传递给输出层。常见的3种激活函数包括Sigmoid、Relu和Tanh函数。使用隐藏层 f_1 和输出层 f_2 中的激活函数,见下式。

$$f_1(\alpha_i) = \frac{1}{1 + \exp(-2\alpha_i)}$$

(4)

$$f_2(\beta_i) = \beta_i$$

(5)

最后,通过归一化热电偶采集的温度数据,形成训练与测试集并确定最佳隐含层节点;随后将BP网络初始权重和阈值编码为染色体,以RMSE作为

适应度,GA通过选择—交叉—变异循环迭代直至适应度低于阈值,输出最优初始权值;最后将这一组权值赋给BP网络,用归一化后的温度-距离-时间-热释放速率数据进行常规反向传播训练,即可一次性预测顶棚火灾任意纵向位置的顶棚温度分布,具体流程如图2所示。




图2 GA-BPNN模型算法结构
Fig.2 GA-BPNN model algorithm structure

3 GA-BPNN模型预测结果分析

3.1 地铁列车车厢温度特征参数预测结果分析

文中车厢温度预测模型中迭代次数取500次,学习效率取0.001;激励函数选为Sigmoid函数。最大遗传代数取60,种群规模设置为15,交叉概率与变异概率分别取0.09和0.05。迭代适应度下降曲线和神经网络训练状态变化分别如图3和图4所示。在第26轮后,适应度值从0.01704迅速下降到0.01636。在第54轮训练中收敛,适应度值下降为0.01625并保持不变。从第1轮到第54轮,梯度的降低,表明模型正在逐渐接近最优解,模型预测能力有所提高。该网络达到设定阈值并在第62轮训练中就已完成收敛,梯度降低到0.00048448。

利用GA-BPNN模型预测地铁列车车厢温度并画出温度预测图的时间为27.38s,响应时间较短。GA-BPNN模型的车厢温度测试集的误差线图以及回归拟合如图5和图6所示。可以看出,列车车厢温度预测数据均紧密接近于 $y=x$ 的零误差线。虽然预测值与真实值仍存在偏差,但误差范围在20℃以内。图中的空心圆点代表预测结果,斜线表示最优估计,即预测结果与测试真实值相近。GA-BPNN预测模型可根据输入的3个特征量准确预测出隧道




图3 车厢温度适应度变化曲线

Fig. 3 Change curve of the carriage temperature adaptability




图4 车厢温度训练状态

Fig. 4 Temperature state diagram of neural network

地铁车厢发生火灾后的温度分布,且预测偏差较小。在不同火源功率下,车厢顶棚温度的最大误差为 19.10°C ,平均误差为 8.17°C 。

随着迭代次数增加,适应度曲线逐渐下降,在迭代 35 次后的变化幅度不大。表明该模型逐步适应训练过程中的数据分布,并能够更好地泛化到测试数据中。在训练过程中,梯度最初缓慢下降,在第 21 轮时,梯度略有增加,但仍保持在 10^{-2} 数量级。在第 60 轮训练中收敛且网络达到设定阈值,梯度为 0.000 595 22,从第 1 轮—第 60 轮迭代中,梯度的降低表明模型正在逐渐接近最优解,这意味着模型的预测能力有所提高。此外,表明模型具有一定鲁棒性,在训练过程中面临噪声和干扰时可保持稳定性。




图5 车厢温度预测值与真实值对比

Fig. 5 Comparison of predicted and actual values




图6 车厢温度训练集与验证集的回归拟合

Fig. 6 Fitting of training and the verification set

为进一步量化 GA-BPNN 模型的预测性能,根据预测值和真实值计算出其性能指标平均绝对误差 (Mean Absolute Error, MAE)、RMSE 和 R^2 。平均绝对误差为 8.17,均方根误差为 9.76。神经网络模型训练集和测试集 R^2 值分别为 0.97 和 0.99。表明基于神经网络的预测模型能够以较高精度预测模拟结果。

3.2 地铁隧道温度特征参数预测结果分析

同样,设置训练集数量为 518 个,测试集数量为 130 个。模型中迭代次数取 500 次,学习效率取为 0.001;激励函数选为 Sigmoid 函数;最大遗传代数取 60,种群规模设置为 15,交叉概率与变异概率分别取 0.09 和 0.05,适应度曲线和回归预测如图 7 和

图 8 所示。




图 8 神经网络隧道温度训练状态

Fig. 8 Neural network training process for tunnel temperature prediction

图 9 展示了不同火灾工况下 GA-BPNN 预测隧道温度测试集的误差,图 10 为神经网络训练集与测试集的回归拟合图。图 9 中预测散点值与 $x=y$ 的参考线几乎重合,说明模型训练准确度较高。预测数据中整体数据出现误差的概率较低,个别数据预测存在较大误差,但整体误差偏小。隧道顶板温度的最大误差为 13.73℃,平均误差为 3.98℃,94% 的误差值小于 10℃。由此可知:GA-BPNN 模型在预测隧道火灾温度方面表现较为出色。

为进一步量化 GA-BPNN 模型预测性能,根据




图 9 隧道温度预测值与真实值对比

Fig. 9 Comparison of predicted and actual values




图 10 隧道温度训练集与验证集的回归拟合图

Fig. 10 Fitting of training and verification set

预测值和真实值计算出其性能指标 MAE、RMSE 和 R^2 。MAE 为 3.95, RMSE 为 5.63。训练集和测试集 R^2 值分别为 0.98 和 0.98。

整体来讲,GA-BPNN 预测模型对地铁车厢火灾顶棚温度数据的学习效果较好,可准确预测测试集内 4 种火灾工况下沿程各测点温度,并获得满意的预测结果。

3.3 模型对比

为进一步验证 GA-BPNN 算法的预测准确性,使用 BPNN 预测模型作为对比,更加直接地对比显示模型的预测效果。同时为了控制变量,运用与 GA-BPNN 模型相同的输入输出数据进行模拟。图 11 展示了 GA-BPNN 模型和 BPNN 模型的车厢温度预测误差对比图,图 12 为 GA-BPNN 模型和

BPNN 模型的隧道温度预测误差对比图。




图 11 GA-BPNN 和 BPNN 模型的车厢温度预测误差对比

Fig. 11 Comparison of GA-BPNN and BPNN model of prediction error in train carriages




图 12 GA-BPNN 和 BPNN 模型的隧道温度预测误差对比

Fig. 12 Comparison of GA-BPNN and BPNN model of prediction error in tunnels

可以看出,利用 GA 优化算法能有效防止 BPNN 模型陷入局部最优的情况,大大降低预测误差。GA-BPNN 模型预测结果误差范围大部分在 $\pm 5\%$ 内,且 GA-BPNN 模型的测试值样本误差分布较为集中,

最大误差为 $28.32\text{ }^{\circ}\text{C}$;BPNN 模型虽然预测准确率仍在 92%左右,但误差分布在 $-10\%\sim 20\%$ 的较多,最大误差在 70%以上,训练样本误差和测试样本误差分布比较分散,最大误差达到 $107.47\text{ }^{\circ}\text{C}$ 。

GA-BPNN 预测模型的车厢温度 MAE 和 RMSE 分别达到 10.25 和 15.03,未优化的 BPNN 模型的车厢温度 MAE 和 RMSE 分别为 16.41 和 25.75,预测结果的 MAE 和 RMSE 分别减少 37.53% 和 41.63%;GA-BPNN 预测模型的隧道温度 MAE 和 RMSE 分别为 3.83 和 6.05,未优化的 BPNN 模型的隧道温度 MAE 和 RMSE 分别为 5.36 和 7.67,预测结果的 MSE 和 RMSE 分别减少 28.54% 和 21.12%,决定系数 R^2 提高 1.8%。

基于 GA-BPNN 预测模型得到的预测值十分接近真实值,测试误差均值比 BPNN 模型低 20%左右,模型精度有了明显提高。从比较结果中发现,GA-BPNN 得到的预测结果明显优于传统 BPNN 模型的预测结果。

4 结 论

1) 采用 GA 优化 BPNN,预测侧向多开口地铁列车和隧道火灾时的温度特征参数,有助于提高神经网络模型训练效率和预测精度。

2) 根据预测值和真实值计算出车厢温度性能指标,MAE 为 8.17,RMSE 为 9.76, R^2 为 0.99;隧道温度性能指标 MAE 为 3.95,RMSE 为 5.63, R^2 值为 0.98。同时,基于 GA-BPNN 预测模型得到的预测值接近真实值,测试误差均值比 BPNN 模型低 20%左右,模型精度有明显提高。

3) 与传统 BPNN 模型相比,GA 优化算法可显著提高预测模型准确性。提出的基于 GA 的 BPNN 预测模型具有理论和实用价值,为火灾温度特征参数高效预测提供了一种有效途径。

参 考 文 献

- [1] 汤青慧,刘硕,张瑾. 基于 WSR-可拓云理论的地铁车站火灾安全韧性评估[J]. 中国安全科学学报, 2025, 35(1): 154-162.
TANG Qinghui, LIU Shuo, ZHANG Jin. Resilience assessment of fire safety in subway stations based on WSR-Extension cloud theory[J]. China Safety Science Journal, 2025, 35(1): 154-162.
- [2] 彭敏,潘翔骁,何坤,等. 侧向多开口轨道列车火灾烟气输运特性[J]. 中国安全科学学报, 2024, 34(5): 129-138.
PENG Min, PAN Xiangxiao, HE Kun, et al. Study on smoke transport characteristics of fire inside rail train with multiple lateral openings[J]. China Safety Science Journal, 2024, 34(5): 129-138.
- [3] 雷斌,杜依潼,寻天祥,等. 地铁换乘站火灾排烟及疏散路径研究[J]. 中国安全生产科学技术, 2025, 21(6): 140-148.

LEI Bin, DU Yitong, XUN Tianxiang, et al. Research on fire smoke exhaust and evacuation paths in subway transfer station [J]. Journal of Safety Science and Technology, 2025, 21(6): 140–148.

[4] NG Y W, CHOW W K, CHENG Chihonn, et al. Scale modeling study on flame colour in a ventilation-limited train car pool fire[J]. Tunnelling and Underground Space Technology, 2019, 85: 375–391.

[5] 姜学鹏, 肖倪琪, 路世昌. 不同车门开闭状态下地铁车厢火灾特性研究[J]. 消防科学与技术, 2021, 40(1): 76–81.

JIANG Xuepeng, XIAO Niqi, LU Shichang. Fire characteristics of metro cabin under different doors opening and closing conditions[J]. Fire Science and Technology, 2021, 40(1): 76–81.

[6] SHI Congling, ZHONG Maohua, CHEN Changkun, et al. Metro train carriage combustion behaviors: full-scale experiment study [J]. Tunnelling and Underground Space Technology, 2020, 104: DOI:10.1016/j.tust.2020.103544.

[7] 彭敏. 侧向多开口地铁列车车厢火灾燃烧特性研究[D]. 合肥: 中国科学技术大学, 2021.

PENG Min. Study on combustion characteristics of fires inside subway train with multiple lateral openings [D]. Hefei: University of Science and Technology of China, 2021.

[8] INGASON H. Model scale railcar fire tests[J]. Fire Safety Journal, 2007, 42(4): 271–282.

[9] LÖNNERMARK A, INGASON H, LI Yingzhen et al. Fire development in a 1/3 train carriage mock-up[J]. Fire Safety Journal, 2017, 91: 432–440.

[10] PENG Min, SHI Long, HE Kun, et al. Experimental study on fire plume characteristics in a subway carriage with doors[J]. Fire Technology, 2020, 56(2): 401–423.

[11] PENG Min, MING Yuyang, WU Zhenkun, et al. Experimental study on fire characteristics of sidewall fires in a long-narrow compartment with multiple lateral openings[J]. Case Studies in Thermal Engineering, 2023, 51: DOI:10.1016/j.csite.2023.103515.

[12] 钟茂华, 程辉航, 陈俊洋, 等. 地铁车站火灾全尺寸实验设计与工程实践[J]. 实验技术与管理, 2022, 39(9): 1–8.

ZHONG Maohua, CHENG Huihang, CHEN Junfeng, et al. Full-scale experimental design and engineering practice of metro station fire [J]. Experimental Technology and Management, 2022, 39(9): 1–8.

[13] XI Yanhong, ZHOU Zhihan, MAO Jun, et al. Maximum ceiling temperature and longitudinal distribution in a corridor-like enclosure with opening[J]. Tunnelling and Underground Space Technology, 2023, 134: DOI: 10.1016/j.tust.2023.104994.

[14] XI Yanhong, ZHOU Zhihan, LIAN Huanqiang, et al. Temperature variation inside a corridor-like enclosure under limited ventilation[J]. Tunnelling and Underground Space Technology, 2022, 126: DOI:10.1016/j.tust.2022.104539.

[15] YANG Juntao, YANG Yun, WANG Helan, et al. Effect of the open ways of screen doors on fire smoke in a subway platform [J]. Procedia Engineering, 2011, 11: 416–423.

[16] HUANG Dongmei, WANG Panpan, LI Wei, et al. Modeling, response and BPNN-PID control of symmetric multistable galloping energy harvesters[J]. Chaos, Solitons & Fractals, 2025, 199: DOI:10.1016/j.chaos.2025.116736.

[17] BEYLER C L, HIRSCHLER M M. The SFPE handbook of fire protection engineering[M]. London: Springer New York, 2016: 102–134.

[18] 吕淑然, 田江雪, 党鑫宇. 基于改进灰狼优化 BP 网络的城中村火灾预测[J]. 中国安全科学学报, 2025, 35(8): 196–204.

LYU Shuran, TIAN Jiangxue, DANG Xinyu. Fire prediction in urban villages based on improved grey wolf optimization BP network [J]. China Safety Science Journal, 2025, 35(8): 196–204.

[19] 黄欣然. 时变路网下接驳轨道交通的社区公交路径规划研究[D]. 大连: 大连交通大学, 2025. 6.

HUANG Xinran. Research on route planning of community bus connecting rail transit under time-dependent road network [D]. Dalian: Dalian Jiaotong University, 2025. 6.

[20] 赵思琦. 突发事件下城市轨道交通网络韧性修复分析[D]. 大连: 大连交通大学, 2025. 6.

ZHAO Siqi. Analysis of urban rail transit network resilience repair under emergency events[D]. Dalian: Dalian Jiaotong University, 2025. 6.

[21] 白慧. 基于神经网络的隧道火灾温度能见度预测研究[D]. 成都: 西南交通大学, 2022. 6.

BAI Hui. Research on temperature and visibility prediction of tunnel fire based on neural network [D]. Chengdu: Southwest Jiaotong University, 2025. 6.

作者简介： 吴振坤（1990—），男，甘肃张掖人，博士，讲师，主要从事轨道交通火灾防控及监测预警等方面的研究。E-mail: TB21120027B0@cumt.edu.cn。

