

基于多描述补偿预测的地铁道岔短时动作 超负荷预警方法^{*}

文 豪¹ 黄 瑞¹ 谢光祥²

(1. 武汉铁路职业技术学院铁道通信与信号学院, 430205, 武汉; 2. 武汉地铁运营有限公司, 430019, 武汉)

摘 要 [目的] 地铁折返道岔动作频繁且工况复杂, 很容易进入超负荷动作从而引发卡阻等机械故障, 对此提出一种短时动作负荷预测及超负荷预警评估方法。[方法] 围绕地铁道岔短时动作超负荷预警展开研究, 阐述道岔短时状态预警评估方法。基于提出的多描述加权预测机以及自适应核密度估计等方法, 描述如何实现动作负荷的区间预测以及预警评估指标的计算, 并说明了预警评估流程。据此建立动作超负荷预警应用方案, 并依托武汉地铁道岔动作数据进行实证测试。[结果及结论] 首先, 实时连续地采集道岔功率曲线特征点, 计算均方根值得到道岔动作负荷特征序列作为预测输入; 然后, 设计多描述互补预测机制, 并采用 ELM (极限学习机) 作为基预测器, 建立多描述互补预测机进行短时动作负荷特征多步范围预测, 构成预测特征集; 最后, 以预测特征集元素为样本, 基于自适应核密度估计方法计算预测时段道岔动作负荷特征的概率密度函数和整体取值置信区间, 并结合历史负荷特征取值置信区间定义预测时段的动作超负荷度作为预警评估指标。实证测试结果显示: 对于故障前负荷特征数据, 预测估计的置信区间覆盖率可达 94.2%, 且置信区间宽度基本契合实际值区间宽度变化; 当预警评估门限为 0.63 时, 各测试案例均能在道岔故障前第 4~9 次动作时成功发出预警。测试结果验证了超负荷预警方法的有效性。

关键词 地铁; 道岔; 超负荷预警; 多描述补偿预测; 自适应核密度估计

中图分类号 U213.6⁺8

DOI: 10.16037/j.1007-869x.2024.01.005

Metro Turnout Short-term Action Overload Early-warning Method Based on Multi-description Complementary Prediction

WEN Hao¹, HUANG Rui¹, XIE Guangxiang²

(1. Institute of Railway Communication and Signal, Wuhan Railway Vocational College of Technology, 430205, Wuhan, China; 2. Wuhan Metro Operation Co., Ltd., 430019, Wuhan, China)

Abstract [Objective] Metro turnback turnouts undergo frequent movements and complex working conditions, making them prone to overload actions that lead to mechanical failures such as jamming and blockage. A method for predicting short-term action loads and assessing overload early-warnings is proposed. [Method] Focusing on metro turnout short-term action overload early-warning, research is carried out expounding the assessment method for turnout short-term state early-warnings. Utilizing the proposed multi-description weighted prediction mechanism and adaptive kernel density estimation, the approach to achieve interval prediction of action loads and the calculation of early-warning assessment indicators are described, and the early-warning assessment process is outlined. Based on this, an application plan for action overload early-warning is established and empirically tested using turnout action data from Wuhan Metro. [Result & Conclusion] First, real-time continuous collection of turnout power curve characteristic points is conducted, and the root mean square value is calculated to obtain the characteristic sequence of turnout action loads as the input for prediction. Then, a multi-description complementary prediction mechanism is designed, using ELM (extreme learning machine) as the base predictor to establish a multi-description complementary prediction machine to carry out multi-step range prediction of short-term action load characteristics, forming a prediction feature set. Lastly, taking the elements of the prediction feature set as samples, the probability density function and the overall value confidence interval of the turnout action load characteristics during the prediction period is calculated using an adaptive kernel density estimation method. Combining this with the confidence interval of historical load characteristics, the action overload degree during the prediction period is defined as the early-warning assessment indicator. Empirical test results show that for pre-fault load characteristic data, the coverage rate of the estimated confidence interval by prediction reaches 94.2%, and the confidence interval width general-

^{*} 湖北省教育厅科学研究计划指导性项目“基于机器学习的地铁道岔故障风险预警方法及应用研究”(B2022527)

ly matches the actual value interval width changes. When the early-warning assessment threshold is set at 0.63, all test cases can successfully issue early-warnings during the 4th to 9th actions before turnout faults occur. The test results validate the effectiveness of the overload early-warning method.

Key words metro; turnout; overload early-warning; multi-description complementary prediction; adaptive kernel density estimation

作为地铁行车最关键的基础设备,道岔一旦故障轻则导致延误,重则造成脱轨。地铁折返线道岔动作频繁,受自身磨损及周边环境影响,经常进入短时动作超负荷状态,进而引发卡阻等机械故障。相比断线、短路等迹象微弱的电气故障,机械故障的状态劣化过程更容易被观测捕捉,具有可预警的应用价值。若能在故障前预知风险,提前调配抢修资源或变更折返线,则可大大降低故障影响,甚至避免故障发生。可见,道岔短时超负荷动作预警对保障地铁行车安全有重大意义。

现有道岔故障预测和状态预警方面的研究特点鲜明。文献[1-2]建立状态退化模型来预测设备的剩余使用寿命;此方法用于拟合设备失效演化过程,不适合短时状态突变感知。文献[3-4]对功率监测曲线进行特征提取,学习、挖掘状态阈值可实现实时的故障预测及诊断;但其仅通过识别当前已形成的动作曲线异常来预测故障的发生,较为片面,既容易误判,也不易提前发现问题。文献[5]利用多步单点预测的电流时域特征预先诊断故障,并根据诊断结果进行实时故障预测;其预测效果依赖于预测的准确性和故障诊断方法的可靠性。

由于道岔周界环境复杂,动作特征易在短时内发生各类变化,故采用确定性预测难以适应复杂的场景变化。对此,本文提出基于多描述补偿预测的道岔短时动作超负荷预警方法。

1 道岔动作负荷特征

功率曲线是用来表征道岔动作状态负荷的常用信号。根据故障诊断经验和研究,道岔异常动作时的功率曲线普遍有明显上扬或波动上浮等现象,本文以道岔转换过程中采样点功率曲线的均方根值 R 作为动作负荷特征。若 R 在短时内异常波动连续增大,则表明道岔很可能进入超负荷动作期,易发生故障。

2 道岔短时动作负荷的区间预测

2.1 多描述补偿预测机制

短时预测序列长度有限。为了能在尽量小的误差范围内得到更多用于整体取值置信区间估计的预测值,进而充分表征预测时段的动作状态,本文基于多描述编码思想^[6]提出多描述补偿预测机制。

首先,设原始序列为 $\{R(i) \mid i=1,2,\dots,2L\}$ ($2L$ 为原始序列长度),将采样所得的两组奇偶互补序列 $\{R(1),R(3),\dots,R(2L-1)\}$ 及 $\{R(2),R(4),\dots,R(2L)\}$,视为稀疏度为 0.5 的原始序列信息描述;然后,用基预测器对 $\{R(i)\}$ 预测,得到预测序列 $\{r(j) \mid j=1,2,\dots,2l\}$,再对两组奇偶互补采样序列预测得 $\{r_o(j) \mid j=1,3,\dots,2l-1\}$ 、 $\{r_e(j) \mid j=2,4,\dots,l\}$;最后,根据给定的权值序列 $\{k_1,k_2,\dots,k_{2l}\}$,由 r 和 r' 交织加权,得到预测序列每单点预测值 $r_f(j)$:

$$r_f(j) = \begin{cases} r(j)k_j + (1 - k_j)r_o\left(\frac{j+1}{2}\right), & j \text{ 为奇数} \\ r(j)k_j + (1 - k_j)r_e\left(\frac{j}{2}\right), & j \text{ 为偶数} \end{cases} \quad (1)$$

依据时间序列特性,任一单点预测值 $r_f(j)$ 都可从不同描述角度由原序列连续预测或其采样序列等间隔预测得到,且必有其一误差更小;在各自完成预测之后将两者加权,可对权值学习寻优来促使结果更靠近真实值。若对各 k_j 都训练 n 个值,则可以得到 $2nl$ 个期望范围内变化的扩大样本,用于整体置信区间估计。

2.2 建立多描述加权预测机

以训练效率高和泛化能力好的 ELM(极限学习机)^[7]作基预测器,基于预测机制建立的多描述加权预测机如图 1 所示。

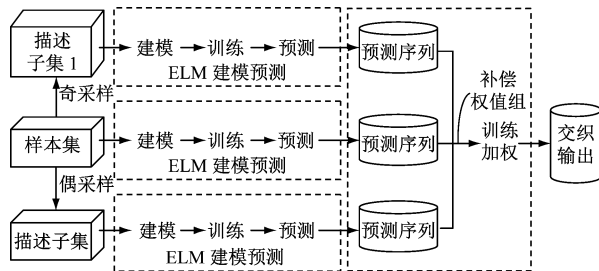


图 1 基于预测机制建立的多描述极限预测机

Fig. 1 Multi-description limit prediction machine based on prediction mechanism

预测模型的学习过程分两步:

第一步:ELM 训练,使模型具备预测能力。具体方法参考文献[7]。

第二步:将预测序列 $\{r_t(j)\}$ 作为输入,对每一步单点预测值都训练 1 组变化步长为 b 的补偿权值,得到 n 步的补偿权值序列 $\{k_j, k_j + b, \dots, k_j + (n-1)b | j=2l\}$,进而得到补偿权值矩阵 $K_{2l \times n}$ 用于构造取值变化的预测特征集,期望在小范围内包络或尽量接近真实值。

给定权值域 B ,设加权后,第 u 行第 v 列单点预测值为 T_{vu} ,第 v 列单点实值为 V_v ,定义预测特征集在 $K_{2l \times n}$ 下的预测损失 $\ell(K_{2l \times n})$:

$$\left\{ \begin{aligned} \ell(K_{2l \times n}) &= \frac{1}{2nl} \sum_{v=1}^{2l} \sum_{u=1}^n |T_{vu} - V_v| + \\ &\quad \lambda D_{\text{KL}}(F_T \| F_P) \end{aligned} \right. \quad (2)$$

$$D_{\text{KL}}(F_T \| F_P) = \sum_{\Omega} (F_T + 1) \left| \lg \frac{F_T + 1}{F_P + 1} \right|$$

式中:

$D_{\text{KL}}(\cdot)$ ——Kullback-Leibler 散度修改式;

F_T, F_P ——分别为真实序列和预测特征集在同样样本空间 Ω 下的离散累积概率分布;

λ ——正则比例系数。

其中, $\frac{1}{2nl} \sum_{v=1}^{2l} \sum_{u=1}^n |T_{vu} - V_v|$ 为预测误差损失, $\lambda K_L(F_T \| F_P)$ 为概率分布损失。

覆盖到 Q 个样本,第二步的学习目标就是得到使总损失最小的补偿权值矩阵 $\bar{K}_{2l \times n}$:

$$\bar{K}_{2l \times n} = \arg \min \frac{1}{Q} \sum_Q \ell(K_{2l \times n}) \quad (3)$$

综上,多描述加权预测机的实质是实现可靠的序列单点值范围预测,以扩大得到预测特征集用于整体取值置信区间估计。

2.3 自适应核密度估计置信区间

以预测特征集为样本,基于 AKDE(自适应核密度估计)法推测未来短小时内动作负荷特征的概率分布,以得到具有概率意义的取值置信区间。

设有预测特征集 $\{X_t | t=1, 2, \dots, M\}$,则预测值 x 的核密度估计函数为:

$$\hat{f}(x; h) = \frac{1}{M} \sum_{i=1}^M \frac{1}{h} \varphi\left(\frac{|x - X_t|}{h}\right) \quad (4)$$

式中:

$\varphi(\cdot)$ ——核函数,选取高斯核表征;

h ——核带宽,用根据第 t 个预测特征位置自适应确定的可变值 h_t 代替。

由此,自适应高斯核密度估计函数 $\hat{f}_A(x; h_t)$ 可表示为:

$$\hat{f}_A(x; h_t) = \frac{1}{M} \sum_{i=1}^M \frac{1}{h_t \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x - X_t}{h_t} \right)^2} \quad (5)$$

其中,由文献[8]可得 h_t 的求解方式为:

$$h_t = \omega \left\{ \left[\prod_{m=1}^M \hat{f}(X_m; h_p) \right]^{\frac{1}{M}} / \hat{f}(X_t; h_p) \right\}^{\frac{1}{2}} \quad (6)$$

式中:

h_p ——由样本标准差 σ 主导的最优固定带宽,

$h_p = 1.06\sigma M^{-\frac{1}{5}}$;

ω ——带宽参数。

$\hat{f}_A(x)$ 反映了预测空间的概率密度分布,故基于当前预测特征集的预测值置信区间 $[c_1, c_2]$ 与对应置信水平 P 的关系可表示为:

$$P = \int_{c_1}^{c_2} \hat{f}_A(x) dx \quad (7)$$

由式(7),在给定置信水平(本文试验计算统一取 95.4%)下,可根据 $\hat{f}_A(x)$ 估计预测值的置信区间 $[c_1, c_2]$ 。

3 超负荷预警评估

3.1 预警评估指标

定义预测的道岔动作特征值整体超负荷状态程度为超负荷度 S ,并将之作为预警评估指标。首先,采集大量不同时期历史动作负荷特征样本;然后,利用式(7)计算可得,基于历史动作负荷特征值的、在同一 P 下的置信区间 $[z_1, z_2]$ 。 $[z_1, z_2]$ 用来反映道岔动作负荷特征取值的历史经验水平,可据此计算 S ,进而衡量道岔状态安全性。 S 取值为:

$$S = \begin{cases} 1, & c_1 \geq z_2 \\ 0, & c_2 \leq z_2 \\ \int_{z_2}^{c_2} \hat{f}_A(x) dx, & \text{其他} \end{cases} \quad (8)$$

S 越接近 1,说明预测水平整体超过历史经验水平上限的概率越大、超标量越多,道岔短小时内因超负荷动作引起故障的可能性就越大。

3.2 预警评估流程

道岔短时动作超负荷预警评估流程如图 2 所示。

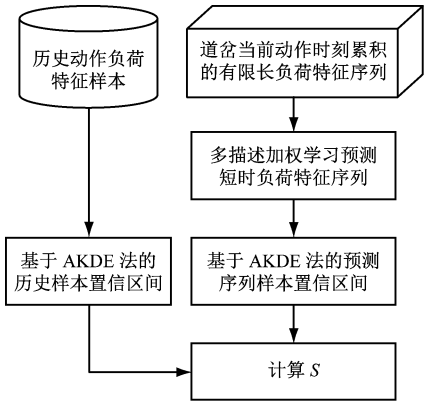
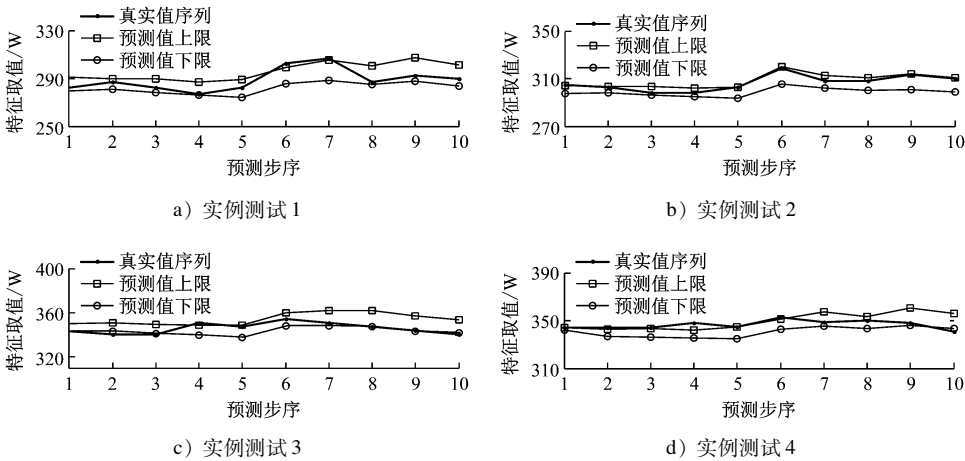


图 2 道岔短时动作超负荷预警评估流程
Fig. 2 Turnout short-term action overload early-warning evaluation process



注:特征取值为功率值。
图 3 每步单点的预测值上下限及真实值曲线
Fig. 3 Upper and lower limits of predicted values and true value curves for the single point of each step

由图 3 可见,由预测序列每一步单点预测值连成的上下限曲线包络范围不仅能将真实值序列基本包络在内,还能在较小的包络范围内有效反映出真实值序列的趋势变化。

4.3 整体取值置信区间估计

以真实故障案例当天道岔连续动作产生的负荷特征序列 R 为实例(故障前数据变化特征明显,能更好地反映方法效果),自当日运营开始一段时间后,以 10 次动作为一个短时预测单位及间隔,进行时段性整体动作负荷置信区间估计测试,直至故障发生前停止。图 4 为两个故障案例发生故障前的特征序列及估计的整体取值置信区间。

由图 4 可以看出,每个案例各短时预测单位的

4 实证测试

4.1 测试数据及主要参数设定

实证测试数据均来源于武汉地铁实际运营时的道岔数据,包括非故障日数据和超负荷动作故障案例当日数据。以功率值作为特征取值。取 $L = 10, l = 5$;补偿权值范围为 $[0, 1]$ 且 $b = 0.05$,每步单点预测值均设 $n = 11$ 个补偿权值。

4.2 单点值范围预测

选取 4 组不同道岔及其转辙机为对象,先分别采集大量历史动作负荷特征样本 R 序列用于预测模型训练,再分别从其日常单方向动作数据中任意选取 1 组长为 30 的 R 序列用于测试。主要测试预测序列每一步的单点预测值变化范围。每步单点的预测值上下限及真实值曲线如图 3 所示。




图 4 两个案例发生故障前的特征序列及估计的整体取值置信区间
Fig. 4 Feature sequence and estimated global value confidence interval before failure occurrence in the two cases

整体置信区间基本能在一个恰当小的宽度内将所属 10 个序列值都包络在内。参照文献[9]计算总

体区间覆盖率 F_{ICR} : 案例 2 的 F_{ICR} 达 94.2%, 接近 95.4% 的置信度; 与案例 2 相比, 案例 1 的 F_{ICR} 整体波动变化更大, 虽由于预测时滞性导致 F_{ICR} 降低, 但 F_{ICR} 仍能接近 90%。此外, 置信区间宽度会随着序列波动情况而改变, 且在大多数情况下和实际序列值变化区间宽度高度契合。

表 1 各故障案例动作超负荷预警评估指标的变化情况

Tab.1 Changes in action overload early-warning evaluation indicators for various fault cases

| 案例编号 | S 的变化 |
|------|--|
| 1 | 0→...→0→0.12→0→0→0.65→0.64→0.97→1.00 |
| 2 | 0→...→0→0.33→0.35→0.2→0→0→0.58→0.7→0.72→0.68→0.91→0.67→0.63 |
| 3 | 0→...→0→0.32→0.67→0.79→1.00→1.00→1.00→1.00→0.88 |
| 4 | 0→...→0→0.19→0.41→0.06→0→...→0→0.09→0.22→0→...→0→0.74→0.83→1.00→1.00→1.00→1.00→1.00→1.00→1.00→1.00 |
| 5 | 0→...→0→0.12→0.38→0.1→0→...→0→0.17→0→...→0→0.21→0→...→0→0.5→0.56→0.62→0.22→0→...→0→0.79→0.76→1.00→1.00→1.00→1.00 |
| 6 | 0→...→0→0.35→0.26→0.17→0.19→0.15→0→0→0.63→1.00→1.00→1.00→1.00→1.00→1.00→1.00→1.00 |
| 7 | 0→...→0→0.11→0.25→0.04→0.14→0.02→0→...→0→0.06→0→...→0→0.12→0.42→0.87→1.00→1.00→1.00→1.00 |
| 8 | 0→...→0→0.08→0→0.04→0.48→0.26→0→...→0→0.04→0.52→0.75→0.94→0.96→0.89→0.74→0.23→0.41→0.65→0.97 |

根据指标推进情况分析: 当预警评估门限取 0.63 时, 不仅都能在临近故障前成功预警, 且能抵抗非临近故障期的虚警; 预警提前动作次数为 4~9 次, 契合短时预测和预警的设定, 可为主动应急处置争取时间。

5 结语

本文围绕地铁道岔短时动作超负荷预警展开研究, 提出多描述加权预测机, 并结合自适应核密度估计等手段实现动作负荷区间预测及超负荷度量, 从而建立短时状态预警评估方法。该预警评估方法特点为:

- 1) 建立一种机器学习的短时序列单点范围预测模型, 可优化预测性能的同时获得更多表征道岔后续动作负荷的预测值。
 - 2) 用自适应核密度估计法计算预测时段整体的负荷置信区间实现超负荷预警评估, 以适应不确定性场景, 且利于及时发现问题争取应急时间。
- 利用武汉地铁真实运营数据测试验证了此方法不仅可以精确地对短期负荷特征进行范围预测和置信区间估计, 而且更能够实现综合性能可靠的超负荷预警评估, 可作为智能化预警的实用方案。

参考文献

[1] EKER O F, CAMCI F, GUCLU A, et al. A simple state-based

4.4 超负荷预警评估测试

按照图 2 的状态预警评估流程对武汉地铁 8 起故障案例当日数据进行复盘预警评估。预警评估自故障当天运营开始第 20 次道岔动作后开始, 执行至故障发生前。表 1 为各故障案例动作超负荷预警评估指标的变化情况。

prognostic model for railway turnout systems[J]. IEEE Transactions on Industrial Electronics, 2011, 58(5): 1718.

[2] 李园祥. 基于神经网络的道岔转辙机退化模型的研究[D]. 北京: 北京交通大学, 2020.

LI Yuanxiang. Research on degradation model of turnout switch based on neural network[D]. Beijing: Beijing Jiaotong University, 2020.

[3] 钟志旺, 陈建译, 唐涛, 等. 基于 SVDD 的道岔故障检测和健康评估方法[J]. 西南交通大学学报, 2018, 53(4): 842.

ZHONG Zhiwang, CHEN Jianyi, TANG Tao, et al. SVDD-based research on railway-turnout fault detection and health assessment [J]. Journal of Southwest Jiaotong University, 2018, 53(4): 842.

[4] 于苡健. 基于数据挖掘的道岔故障预测方法研究[D]. 兰州: 兰州交通大学, 2020.

YU Yijian. Research on turnout fault prediction method based on data mining[D]. Lanzhou: Lanzhou Jiatong University, 2020.

[5] 张友鹏, 江雪莹, 赵斌. 融合粗糙集与灰色模型的道岔故障预测[J]. 铁道科学与工程学报, 2019, 16(9): 2331.

ZHANG Youpeng, JIANG Xueying, ZHAO Bin. Turnout fault prediction based on Rough Set and Grey Model[J]. Journal of Railway Science and Engineering, 2019, 16(9): 2331.

[6] GOYAL V K. Multiple description coding: compression meets the network[J]. IEEE Signal Processing Magazine, 2001, 18(5): 74.

[7] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1/2/3): 489.




图8 列车自主控制系统在交叉道岔区段运行场景效率提升率

Fig.8 Improved efficiency ratio of autonomous train control system in crossover turnout segment operation scenario

5 结语

为了安全高效的列车运行,定义道岔安全区域为列车自主控制系统在道岔区段控制的资源,提出道岔控制算法,并在单开道岔区段和交叉道岔区段两种常见的城市轨道交通运营场景进行了资源利用效率定量分析。

仿真结果证明,与现有的 CBTC 系统相比,列车自主控制系统的安全间隔和道岔通过时间效率有所提升。本研究可为列车自主控制系统的设计提供参考。在具体工程应用过程中,应结合具体项目特点进行适应性分析,实现效率安全可靠的提升。

参考文献

- [1] SCHUMANN T. Increase of capacity on the Shinkansen High-speed Line using virtual coupling[J]. International Journal of Transport Development and Integration, 2017, 1(4): 666.
- [2] 杜恒, 孙军国, 张强, 等. 基于地面无线锁及区域控制器的新一代 CBTC 系统方案[J]. 都市快轨交通, 2017, 30(4): 91.
- DU Heng, SUN Junguo, ZHANG Qiang, et al. A new generation

of CBTC system without CI and ZC[J]. Urban Rapid Rail Transit, 2017, 30(4): 91.

- [3] 卿建强, 雷成健, 梁波. 列车自主运行控制系统研究[J]. 控制与信息技术, 2021(4): 95.
- QING Jianqiang, LEI Chengjian, LIANG Bo. Research on train autonomous circumambulation system[J]. Control and Information Technology, 2021(4): 95.
- [4] 黄苏苏, 冯浩楠. 基于车车通信的 CBTC 系统[J]. 城市轨道交通研究, 2021, 24(6): 188.
- HUANG Susu, FENG Haonan. CBTC system based on train-train communication[J]. Urban Mass Transit, 2021, 24(6): 188.
- [5] 冯浩楠, 白广争, 于健洁, 等. 以列车为中心的自主控制系统功能及运营场景研究[J]. 城市轨道交通研究, 2022, 25(10): 115.
- FENG Haonan, BAI Guangzheng, YU Jianjie, et al. Research on functions and operation scenario of train-centric autonomous train control system[J]. Urban Mass Transit, 2022, 25(10): 115.
- [6] 冯浩楠, 郑泽熙, 白广争, 等. 以列车为中心的自主控制系统的列车工作模式[J]. 城市轨道交通研究, 2022, 25(12): 198.
- FENG Haonan, ZHENG Zexi, BAI Guangzheng, et al. Train operation mode of train-centric autonomous control system[J]. Urban Mass Transit, 2022, 25(12): 198.
- [7] 柳晓峰, 李耘茏. 100 km/h 速度等级 A 型地铁车辆[J]. 电力机车与城轨车辆, 2010, 33(1): 5.
- LIU Xiaofeng, LI Yunlong. A-type metro vehicle of 100 km/h speed grade[J]. Electric Locomotives & Mass Transit Vehicles, 2010, 33(1): 5.

· 收稿日期:2023-01-27 修回日期:2023-05-06 出版日期:2024-01-10
Received:2023-01-27 Revised:2023-05-06 Published:2024-01-10
· 通信作者:王延峰,讲师,wang79yf@126.com
· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

(上接第 26 页)

- [8] BOTEV Z I, GROTHOWSKI J F, KROESE D P. Kernel density estimation via diffusion[J]. The Annals of Statistics, 2010, 38(5):2916.
- [9] HUANG C, ZHAO Z, WANG L, et al. Point and interval forecasting of solar irradiance with an active Gaussian process[J]. IET Renewable Power Generation, 2020, 14(6): 1020.

· 收稿日期:2021-07-09 修回日期:2021-08-31 出版日期:2024-01-10
Received:2021-07-09 Revised:2021-08-31 Published:2024-01-10
· 通信作者:文豪,讲师,工程师,406590052@qq.com
· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license