

基于 ARIMA-SVR 模型的轨道交通车辆关键 设备检修偶换件数量预测^{*}

王玥龙^{1,2} 刘 鹏^{1,2} 姚伟君²

(1. 中国铁道科学研究院集团有限公司机车车辆研究所, 100081, 北京;

2. 北京纵横机电科技有限公司, 100094, 北京)

摘 要 [目的] 准确预测轨道交通车辆关键设备检修偶换件数量, 可为科学的备件管理提供依据, 提高检修经济性。但是现有预测方法准确性不足, 预测效果差, 因此有必要针对检修偶换件数量预测问题进行深入研究。[方法] 根据轨道交通车辆设备检修偶换件数据的特性, 构建了检修偶换率 (即偶换件更换比例) 和检修量的月度时间序列。通过深入研究时间序列预测算法, 并对比各类预测算法的效果, 综合考虑准确性与泛化能力, 提出了一种结合 ARIMA (自回归综合移动平均法) 与 SVR (支持向量回归算法) 的计算方法。首先利用 ARIMA 进行偶换率的预测, 然后运用 SVR 进行检修量的预测, 最后结合偶换率与检修量的预测结果来计算偶换件的预测数量。此外, 还结合了 ARIMA 预测的置信区间与无监督聚类 IForest (孤立森林) 算法, 提出了一种偶换率异常检测方法。[结果及结论] 以高度阀和制动夹钳单元这两种典型产品的高级修数据为例, 对所提出的预测方法进行了验证计算。结果表明, 与现有的历史平均法相比, 该方法的预测准确性得到了显著提升, 并且能够有效地检测出历史和当前的检修偶换率异常情况。

关键词 轨道交通车辆; 偶换件; 自回归综合移动平均法; 支持向量回归算法; 孤立森林

中图分类号 U270.38

DOI:10.16037/j.1007-869x.2025.03.046

Forecasting Spare Parts Demand for Critical Rail Transit Vehicle Equipment Based on ARIMA-SVR Model

WANG Yue-long^{1,2}, LIU Peng^{1,2}, YAO Wei-jun²

(1. Locomotive & Car Research Institute, China Academy of Railway Sciences Co., Ltd., 100081, Beijing, China;

2. Beijing Zongheng Electro-Mechanical Technology Co., Ltd., 100094, Beijing, China)

Abstract [Objective] Accurately forecasting the demand for spare parts during critical rail transit vehicle equipment maintenance provides a foundation for scientific spare parts man-

agement and improves maintenance cost-efficiency. However, existing forecasting methods lack accuracy and exhibit poor performance. Thus, an in-depth study of spare parts demand forecasting in maintenance is necessary. [Method] Based on the characteristics of spare parts data for rail transit vehicle maintenance, monthly time series are constructed for the replacement rate (i.e., the proportion of parts replaced) and maintenance amount. After thoroughly investigating time series forecasting algorithms and comparing their performance, comprehensively considering their accuracy and generalization, a combined method leveraging ARIMA (autoregressive integrated moving average) and SVR (support vector regression) is proposed. ARIMA is used to predict replacement rates, while SVR is applied to forecast maintenance amount. Finally, the spare parts forecast is calculated by combining the prediction results of both. Additionally, an anomaly detection method for replacement rates is proposed by integrating ARIMA's confidence intervals with the unsupervised clustering algorithm IForest (Isolation Forest). [Result & Conclusion] Taking advanced maintenance data of height valve and brake caliper unit two typical products as example, validation and calculation of the proposed forecasting method is conducted. Results show that compared to the existing historical average method, the proposed method significantly improves forecasting accuracy and effectively detects anomalies in both historical and current replacement rates during maintenance.

Key words rail transit vehicle; spare parts; ARIMA; SVR; IForest

当前,我国轨道交通行业已逐步迈向“设计建造与运营维护并重”的新阶段。在此阶段,定期预防性检修所需物料被明确区分为必换件与偶换件。必换件的成本与数量均处于可控状态,而偶换件则需依据实际运用情况及检修标准进行综合判定,其

^{*} 中国铁道科学研究院集团有限公司科研项目(2019YJ016)

数量呈现出明显的不确定性与波动性。科学的备件管理策略,对于提升检修效率及优化维修经济性而言,具有举足轻重的作用。若能实现对偶换件数量的精准预测,无疑将为备件管理的科学化提供坚实支撑。

针对偶换件数量的预测问题,传统方法往往依赖于历史数据的简单平均值,这种方法因缺乏对历史数据的深入剖析而准确性欠佳。鉴于此,本文深入分析了车辆设备偶换件的数据特征,并通过对比各类预测算法的性能,提出了一种综合运用 ARIMA(自回归综合移动平均法)、SVR(支持向量回归算法)与 IForest(孤立森林)算法进行偶换件数量预测及异常检测的新方法。最终,通过实例计算验证了该方法的准确性与稳定性。

1 偶换件数量预测模型

1.1 数据预处理

通常情况下,检修列车会按月进行定期检修。在此过程中,会收集月度偶换件不合格数量及检修量数据,进而计算出偶换率月度时间序列 Y_t 与检修量月度时间序列 Z_t 。对于历史平均偶换率低于 5% 或高于 95% 的零件,直接采用历史平均偶换率作为预测结果。

在实际检修工作中,偶换率的设定值通常每 3 个月进行 1 次调整。因此,需要预测未来 3 个月的偶换率,并结合预测的检修量来指导备件采购与库存管理。基于此,偶换件数量的预测问题可以被分解为偶换率预测与检修量预测两个子问题。

1.2 基于 ARIMA 进行偶换率预测

基于车辆设备偶换率呈现出小样本、非周期、不规则变动的特点,本文提出了一种基于 ARIMA 的偶换率预测方法^[1-3]。该方法的预测流程如图 1 所示。

1.2.1 平稳性检验

时间序列平稳是进行预测的基础,针对时间序列 Y_t 和时滞 k ,平稳性意味着时间序列的均值和方差不变,且自协方差仅与时滞 k 有关。在此,采用 ADF(增强的 Dickey-Fuller 检验法)单位根检验法,该方法基于统计假设检验,用于检测非平稳时间序列。

1.2.2 平稳处理

针对非平稳时间序列,本文采用线性拟合去趋势和差分平稳处理 2 种方法。

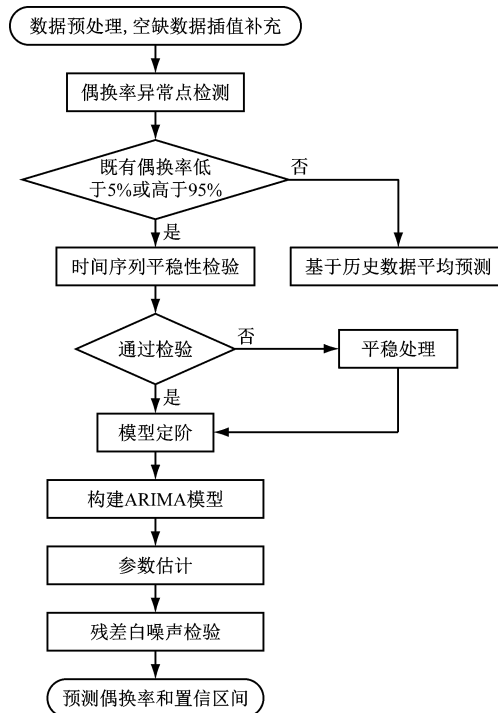


图 1 偶换率预测流程图

Fig. 1 Diagram of replacement rates forecasting process

对于平稳性检验中,含时间趋势项和截距项的平稳序列,采用线性拟合去除趋势的方法:①对原时间序列 Y_t 进行一阶线性拟合,得到趋势序列 T_t ;②将原完整序列减去趋势序列,得到去趋势序列 $W_t = Y_t - T_t$;③对去趋势序列进行预测,得到未来 k 期预测结果序列 W_{t+k} ;④利用拟合方程计算未来 k 期响应序列 T_{t+k} ;⑤将趋势还原,形成最终的预测序列 $Y_{t+k} = W_{t+k} + T_{t+k}$ 。

对于无截距项和趋势项的非平稳序列,则采用差分平稳处理方法,具体步骤如下:①对原序列进行一阶差分处理,得到差分序列 $W_t = Y_t - Y_{t-1}$;②对差分序列进行平稳性检验,升阶至序列平稳,上限为二阶;③对差分平稳序列进行预测,得到未来 k 期预测结果序列 W_{t+k} ;④通过差分还原,形成最终的预测序列 Y_{t+k} 。

1.2.3 模型定阶

ARIMA 模型的构建需明确自回归阶数 p 与移动平均阶数 q 。本研究采用基于 AIC(赤池信息量准则)与 BIC(贝叶斯信息量准则)的定阶策略,采用交叉验证法,寻找 1 组 p 和 q 值,使信息量 S_{AIC} 和 S_{BIC} 最小。具体定义式为:

$$S_{AIC} = -2\ln L + 2k \quad (1)$$

$$S_{BIC} = -2\ln L + k\ln n \quad (2)$$

式中:

L ——ARIMA 模型的极大似然估计的似然函数;

k ——参数个数,含有截距项为 $k = p + q + 1$,不含截距项为 $k = p + q$;

n ——样本容量。

1.2.4 构建 ARIMA 模型

根据模型定阶确定的 p 和 q 值,对平稳处理后的序列构建 ARIMA 模型计算式为:

$$W_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \cdots + \phi_p w_{t-p} + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \cdots + \theta_q e_{t-q} + e_t \quad (3)$$

式中:

w_t ——平稳序列样本;

e_t ——残差序列;

ϕ_1, \cdots, ϕ_p 和 $\theta_1, \cdots, \theta_q$ ——待估参数。

1.2.5 参数估计

极大似然法利用联合概率密度函数,使用样本数据的所有信息,同时有利于结合 AIC 与 BIC 准则使用,故此处采用极大似然估计法。

由构建的 ARIMA 模型和样本值,根据参考文献[1]中公式,计算得到极大似然估计量 $\hat{\phi}_p$ 和 $\hat{\theta}_q$,进而求得方差估计量 $\hat{\sigma}_e$ 。

1.2.6 残差白噪声检验

根据 ARIMA 模型的定义,需要对残差的估计序列进行白噪声检验。这里采用 LB 检验法,其基于一系列滞后阶数,判断序列总体的自相关性是否存在。

根据参考文献[1]中的公式计算得到 LB 检验统计量 Q ,如果统计量超过自由度为 $K-p-q$ 的卡方分布的临界值,即在给定显著性水平 α 下,如果 $Q > \chi^2_{1-\alpha, K-p-q}$ 则拒绝原假设,残差存在自相关性,不符合 ARIMA(p, q)模型。

1.2.7 预测偶换率

根据式(3)对平稳序列进行未来期的预测,然后根据 1.2.2 进行原序列还原,即可得到预测序列 \hat{Y}_{t+1} ,进而递推得到 $\hat{Y}_{t+2}, \hat{Y}_{t+3}$ 。

1.2.8 计算置信区间

通过残差白噪声检验的 ARIMA(p, q)的模型,若残差符合正态分布,则对给定的置信水平 $1 - \alpha$,可用标准正态百分位数 $Z_{1-\alpha/2}$ 得到预测置信区间 $(\hat{Y}_{t+1} - Z_{1-\alpha/2} \sqrt{\hat{\sigma}_{et}}, \hat{Y}_{t+1} + Z_{1-\alpha/2} \sqrt{\hat{\sigma}_{et}})$ 。

1.3 检修量预测

检修量与客运量具有相关性,所以应结合客运数据进行预测。选取全国铁路客运周转量月度时间序列 K_t 和检修量月度时间序列 Z_t 作为输入数据,采用 SVR 模型进行预测^[4]。

1) 采用前五期检修量和前一期铁路客运周转量为输入,当期检修量为输出,进行训练:输入序列 $Z_{t-1}, Z_{t-2}, Z_{t-3}, Z_{t-4}, Z_{t-5}, K_{t-1}$,输出序列 Z_t 。其中: Z 为检修量, K 为铁路客运周转量, t 为当期。

2) 选择高斯核函数 $K(x, x_i)$,并对模型超参数进行交叉验证选择。

3) 构建 SVR 模型,引入拉格朗日乘子 \hat{a}_i, a_i ,计算得到支持向量的系数 $w_i = \hat{a}_i - a_i$,进而得到待估参数 b ,得到决策函数如式(4):

$$f(x) = \sum_{i=1}^m w_i K(x, x_i) + b \quad (4)$$

4) 运用决策函数,预测未来三期的结果 $\hat{Z}_{t+1}, \hat{Z}_{t+2}, \hat{Z}_{t+3}$ 。

1.4 偶换件数量预测

根据未来三期检修偶换率预测结果 $\hat{Y}_{t+1}, \hat{Y}_{t+2}, \hat{Y}_{t+3}$ 与检修量预测结果 $\hat{Z}_{t+1}, \hat{Z}_{t+2}, \hat{Z}_{t+3}$,将两项数据对应相乘后求和即可得到未来三期的偶换件预测

总数量: $\hat{H} = \sum_{i=1}^3 (\hat{Y}_{t+i} \cdot \hat{Z}_{t+i})$,同时结合置信区间,可计算出 95% 置信度下偶换件总数的上、下限 \hat{H}_{\min} 和 \hat{H}_{\max} 。

2 偶换率异常检测方法

偶换率异常检测分为 2 个方面:一是历史数据的分析与检测,另一方面是当前偶换件检查结果的考量。

2.1 历史偶换率异常点检测

本文采用 IForest 算法^[5],筛选出异常点,再结合样本标准差综合判断,给检修人员提供提示,检测方法如下:

1) 构建二叉树模型,选取偶换率时间序列 Y_t ,随机选择一个起始节点,并在最大值和最小值之间随机选择一个值 y ,将样本中小于该值的数据划到左分支,大于等于该值的划到右分支。

2) 在左右 2 个分支数据中,递归上述步骤,直到数据不可再分或二叉树达到最大深度。

3) 计算数据 y 的异常分值时,先要估算它的路径长度。假设训练样本中同样落在 y 所在叶子节点

的样本数为 T_{size} , 则数据 y 的路径长度 $h(y)$ 计算式为:

$$h(y) = e + C(T_{\text{size}}) \quad (5)$$

式中:

e ——数据 y 从根节点到叶节点过程中经过的边数目;

$C(T_{\text{size}})$ ——表示在一棵用 T_{size} 条样本数据构建的二叉树的平均路径长度。

平均路径长度 $C(n)$ 计算式为:

$$C(n) = 2[\ln(n-1) + E] - \frac{2(n-1)}{n} \quad (6)$$

式中:

n ——样本数量;

E ——欧拉常数。

4) 对样本各数据 y 的路径长度 $h(y)$ 的负值进行量纲一化处理, 得到异常分值 $S_{\text{core}}(y)$, 取 0.95 为临界值, 超过 0.95 的样本为异常点。

5) 计算偶换率时间序列 Y_t 的标准差, 判断异常点的偏离程度。

由此, 检修人员可调取检测出的异常期偶换件检查数据, 分析该数据异常原因。

2.2 基于 ARIMA 置信区间的当前期异常点检测

依据预测结果和置信区间, 给出一定置信度下的偶换率上限和下限, 并据此判定当前检查出的偶换率是否异常。

3 实例计算

以某型高度阀四级修偶换件阀体组件作为实例, 本研究选取了 2019 年 4 月至 2021 年 9 月期间共计 30 期的检修数据, 其中最后三期数据被保留用于后续的验证环节。

首先进行数据预处理步骤: 基于前 27 期的数据, 我们计算得到了偶换率的月度时间序列 Y_t 以及检修量的月度时间序列 Z_t 。同时, 还选取了 2019 年 4 月至 2021 年 6 月的铁路客运周转量月度数据, 构建了客运周转量的时间序列 K_t 。

进一步计算得知, 历史平均偶换率为 16.48%, 该值位于 5% ~ 95% 的范围内, 因此满足进行后续预测的条件。

随后进入历史偶换率异常检测的环节: 利用 IForest 算法, 计算得到了各期的异常点分值。经过量纲一化处理, 成功识别出了分值超过 0.95 的异常点, 具体如图 2 所示。检测结果表明: 第 22 期的结

果为异常, 其偶换率为 0.534 1, 这一数值超出了样本均值的三倍标准差 0.512 0。




图2 历史偶换率异常点检测

Fig. 2 Anomaly detection of historical replacement rates

最后, 进行基于 ARIMA 的偶换率时间预测, 首先进行平稳性检验, 如表 1 所示。

表1 平稳性检验

Tab.1 Stationarity test

| 不平稳类型 | P 值 | t 统计量 | 临界值 | 检验结果 |
|----------|---------|----------|----------|------|
| 无截距项和趋势项 | 0.218 4 | -1.160 5 | -1.949 7 | 非平稳 |
| 带截距项 | 0.029 2 | -3.234 7 | -2.980 4 | 平稳 |
| 带截距项和趋势项 | 0.025 6 | -3.924 9 | -3.596 6 | 平稳 |

针对含趋势项和截距项的平稳序列, 采用线性拟合去除趋势的方法, 对偶换率时间序列进行线性拟合, 得到趋势序列 T_t 。将原偶换率序列减去趋势序列, 得到去趋势序列 $W_t = Y_t - T_t$ 。

分别取参数 $p = \{1, 2, 3\}$ 和 $q = \{1, 2, 3\}$ 交叉配组, 构建 ARIMA(p, q) 模型, 对模型进行极大似然参数估计, 返回似然函数值, 计算 AIC 与 BIC 信息量, 结果如图 3 所示。选取 AIC 与 BIC 信息量最小的参数值 $p=2$ 和 $q=2$, 构建 ARIMA(2,2) 模型: $W_t = \phi_1 W_{t-1} + \phi_2 W_{t-2} + \theta_1 e_{t-1} + \theta_2 e_{t-2} + e_t$ 。




图3 AIC 与 BIC 信息量交叉验证

Fig. 3 AIC and BIC information cross validation

对待估参数通过极大似然估计得到: $\hat{\phi}_1 = 1.715, \hat{\phi}_2 = -0.804, \hat{\theta}_1 = -2.000, \hat{\theta}_2 = 1.000, \hat{\sigma}_e =$

0.075 6, 得到回归模型如下: $\hat{W}_{t+1} = 1.715w_t - 0.804w_{t-1} - 2e_t + e_{t-1}$ 。

对残差进行白噪声检验, 计算得到 Q 统计量为 14.474, 95% 置信区间下检验临界值为 31.410, 所以不能拒绝原假设, 残差无相关性, 检验通过。

预测得到未来三期的 \hat{W}_{t+1} 、 \hat{W}_{t+2} 、 \hat{W}_{t+3} , 对序列进行趋势还原, 得到偶换率预测结果 \hat{Y}_{t+1} 、 \hat{Y}_{t+2} 、 \hat{Y}_{t+3} , 同时得到 95% 置信区间, 与真实数据、现有方法进行对比, 如表 2 所示。

表 2 未来三期预测结果对比

Tab. 2 Comparison of forecast results in the next three phases

| 期数 | 真实偶换率 | 历史平均偶换率 | ARIMA 预测偶换率 | 95% 置信区间 |
|------|---------|---------|-------------|-------------------|
| 28 期 | 0.199 4 | 0.164 8 | 0.270 9 | 0.126 1 或 0.415 7 |
| 29 期 | 0.370 4 | 0.164 8 | 0.275 4 | 0.124 8 或 0.426 0 |
| 30 期 | 0.281 0 | 0.164 8 | 0.281 6 | 0.125 1 或 0.438 1 |
| 平均值 | 0.283 6 | 0.164 8 | 0.276 0 | |

从表 2 的结果可以发现: 历史平均偶换率折合每百件的预测误差为 12 件, 而基于 ARIMA 预测误差为 1 件, 准确率提升显著。

将结果与 3 种典型机器学习算法 BP(误差反向传播神经网络)、SVR(支持向量回归)、LSTM(长短期记忆神经网络)进行对比^[6-7], 如表 3 所示, 评估模型的准确性、稳定性和泛化能力。

表 3 不同预测方法对比

Tab. 3 Comparison of different forecasting methods

| 方法 | 偶换率 | | | |
|-------|---------|---------|---------|---------|
| | 真实 | 第一次预测 | 第二次预测 | 第三次预测 |
| ARIMA | 0.283 6 | 0.276 0 | 0.276 0 | 0.276 0 |
| BP | 0.283 6 | 0.142 9 | 0.203 7 | 0.195 0 |
| SVR | 0.283 6 | 0.153 1 | 0.153 1 | 0.153 1 |
| LSTM | 0.283 6 | 0.335 8 | 0.377 2 | 0.332 3 |

经过对比可以发现, 机器学习算法的预测稳定性较差, 如果增加网络复杂度, 会造成过学习降低泛化能力, 且机器学习算法无法给出预测的置信区间, 故基于 ARIMA 的预测方法更符合要求。

基于 ARIMA 置信区间的当前期异常点检测。根据偶换率预测结果和置信区间, 绘制偶换率预测图(如图 4 所示)。未来三期的偶换情况均在 95% 置信区间内, 符合该零部件的偶换规律。

分别选取高度阀(30 期数据)和制动夹钳单元

(23 期数据)四级修典型偶换件的数据进行计算, 结果如表 4 所示。




图 4 偶换率预测结果

Fig. 4 Prediction results of replacement rates


表 4 典型偶换件预测结果

Tab. 4 Forecasting results of typical spare parts

| 名称 | 历史平均法误差/% | ARIMA 预测误差/% | 异常预警 |
|-------|-----------|--------------|---------------|
| 活塞杆组件 | -20 | 1 | 第 10 期结果异常 |
| 垫圈 | -44 | -7 | 第 10 期结果异常 |
| 减压阀座 | -19 | -7 | 第 27、28 期结果异常 |
| 制动杠杆 | 7 | 1 | 第 5 期结果异常 |

表 4 的结果表明, 本方法提升了预测准确率, 且可对当期偶换件异常情况进行识别。如减压阀座, 识别出第 27、28 期偶换率异常升高, 提示重点关注。

基于 SVR 支持向量回归的检修量预测。选取阀体组件前五期检修量和前一期铁路客运周转量为输入, 当前期检修量为输出, 并预留最后三期数据为验证样本。构建训练样本并进行超参数交叉验证, 如图 5 所示。



注: 惩罚系数 C 为 1; 核函数参数 g 为 4; 交叉验证均方误差 V_{MSE} 为 0.096 048。

图 5 超参数交叉验证等高线

Fig. 5 Hyperparameter cross validation contour

选取惩罚系数 $C = 1$ 和核函数参数 $g = 4$ 进行

建模训练,共得到 22 个支持向量、各支持向量系数 $\{w_i, i=1,2,\dots,22\}$ 和常数项系数 $b=-1.4824$,进而通过决策函数预测未来三期的检修量 198、168 和 126,预测的均方误差和相关系数如下:

训练数据均方误差 MSE 值为 0.000 101 113,相关系数 R 为 99.98%。

验证数据均方误差 MSE 值为 0.027 118 900,相关系数 R 为 91.03%。

绘制检修量回归预测图(如图 6 所示),发现基于既有检修量和铁路客运周转量通过 SVR 进行回归预测的效果比较理想,泛化能力较为可靠。




图6 检修量预测

Fig.6 Maintenance amount forecasting

根据阀体组件未来三期的检修偶换率预测结果 0.270 9、0.275 4、0.281 6 与检修量预测结果 198、168、126,将两项数据对应相乘后求和,可得未来三期偶换件预测数量 $\hat{H}=135$,同时给出 95% 置信度下的上、下限 $\hat{H}_{\min}=62$ 和 $\hat{H}_{\max}=209$,真实偶换数量为 171,在预测的置信区间内,结果正常。

4 结语

针对检修偶换件数量预测问题,本文提出一种基于 ARIMA 和 SVR 的预测方法,较现有历史平均法能够更加充分挖掘历史数据的规律,增加临近期的权重影响,实现更为准确的短期预测,并通过实例进行验证计算。另一方面,本方法综合铁路客运周转量的历史数据,采用 SVR 模型实现了检修量短期准确预测,弥补了现有方法在该方面的空白。同时,本方法还具备偶换率异常检测功能,通过 IForest 算法实现了历史偶换率异常识别,基于 ARIMA 预测的置信区间实现了未来期偶换率合理范围预测两部分内容。

本方法不仅可以指导检修备件的管理,还可以

检测偶换件异常情况,对提升检修工作的合理性、经济性提供了重要支撑。

参考文献

- [1] CRYER J D, CHAN K S. 时间序列分析及应用[M]. 北京:机械工业出版社,2021.
CRYER J D, CHAN K S. Time series analysis with applications in R[M]. Beijing: China Machine Press, 2021.
- [2] 王伟,周伟,华雪东,等. 基于 ARIMA 和 LSTM 混合神经网络的短交通流预测方法:CN112529299A[P]. 2021-03-19.
WANG Wei, ZHOU Wei, HUA Xuedong, et al. Short traffic flow prediction method based on ARIMA and LSTM hybrid neural network CN112529299A[P]. 2021-03-19.
- [3] 梅飞,刘皓明,李玉杰,等. 一种基于 ARIMA 和相空间重构 SVR 的母线净负荷预测方法:CN107944612A[P]. 2018-04-20.
MEI Fei, LIU Haoming, LI Yujie, et al. A busbar net load forecasting method based on ARIMA and phase space reconstruction SVR: CN107944612A[P]. 2018-04-20.
- [4] 帅春燕,谢亚威,单君,等. 基于 SSA-SVR 模型的城市轨道交通短时进站客流预测[J]. 都市快轨交通, 2022, 35(5): 76.
SHUAI Chunyan, XIE Yawei, SHAN Jun, et al. Prediction of short-term inbound passenger flow of urban rail transit based on the singular spectrum analysis and support vector regression model [J]. Urban Rapid Rail Transit, 2022, 35(5): 76.
- [5] 习佳星,沈钢,许承焯. 地铁车辆车轮轮缘异常磨损检测中的箱线图算法和改进孤立森林算法[J]. 城市轨道交通研究, 2022, 25(12): 127.
XI Jiaxing, SHEN Gang, XU Chengzhuo. Boxplot algorithm and improved isolated forest algorithm in metro vehicle wheel flange abnormal wear detection [J]. Urban Mass Transit, 2022, 25(12): 127.
- [6] 王宇轲. 基于 BA-BP 算法的汽车配件需求预测系统研究与实现[D]. 成都:西南交通大学, 2017.
WANG Yuke. Research and implementation of auto parts demand forecasting system based on BA-BP algorithm [D]. Chengdu: Southwest Jiaotong University, 2017.
- [7] 陈强. 针对 BA-FRVM 的研究及用于汽车典型故障件的数量预测[D]. 成都:西南交通大学, 2017.
CHEN Qiang. Research on BA-FRVM and its application in the quantity prediction of typical automobile fault parts [D]. Chengdu: Southwest Jiaotong University, 2017.

· 收稿日期:2022-12-26 修回日期:2023-09-22 出版日期:2025-03-10

Received: 2022-12-26 Revised: 2023-09-22 Published: 2025-03-10

· 通信作者:王玥龙,高级工程师,wy19758@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