

# 面向城市轨道交通智能运维的数据耦合性与独立一致性研究

倪弘韬<sup>1</sup> 胡佳乔<sup>1</sup> 吴 强<sup>1</sup> 李 楠<sup>2</sup> 陈君林<sup>2</sup>

(1. 中车南京浦镇车辆有限公司, 210031, 南京; 2. 清华大学环境学院, 100084, 北京)

**摘 要** [目的]智能运维背景下,现有算法准确率低,导致虚警率高,因此有必要开展列车运营数据的耦合性分析与独立一致性研究。[方法]从统计和数据驱动的角度对耦合性与独立一致性进行定义;根据加速度绝对值变化率将列车运行状态分为4个阶段:静止、平稳运行、启动加速及制动减速,并分别生成对应数据切片综合分位图、相关系数等方法;对牵引系统、制动系统累计正线运营数据进行分析,量化系统间的耦合关系;通过构建线性回归模型、支持向量机模型、LightGBM模型和K-近邻模型对于数据进行解耦处理,使牵引制动系统数据呈现正态性,相关变量服从独立性与一致性,以满足联合条件概率分布的前置条件。[结果及结论]数据解耦操作能够提升系统间原始数据的独立一致性;从工程实用角度出发,LightGBM模型在实时与离线状态下表现出最优的性能,在所有量化分析中均取得了50%及以上的优化率;采用解耦后的数据,能够在故障样本较少或者缺失的情况下,实现对潜在故障的预警功能,能有效降低智能运维的虚警率,同时提升故障预测的准确性。

**关键词** 轨道交通;智能运维;故障预警;支持向量机;LightGBM模型;K-近邻模型

**中图分类号** TP312:U231

**DOI:**10.16037/j.1007-869x.2024.05.002

## Research on Data Coupling and Independent Consistency for Urban Rail Transit Intelligent Operation-maintenance

NI Hongtao<sup>1</sup>, HU Jiaqiao<sup>1</sup>, WU Qiang<sup>1</sup>, LI Nan<sup>2</sup>, CHEN Junlin<sup>2</sup>

(1. CRRC Nanjing Puzhen Co., Ltd., 210031, Nanjing, China; 2. School of Environment, Tsinghua University, 100084, Beijing, China)

**Abstract** [Objective] In the context of intelligent operation-maintenance, existing algorithm exhibits low accuracy, resulting in high false alarm rates, hence it is necessary to conduct analysis of data coupling and independent consistency in train operation data. [Method] The definition of coupling and independent consistency are established from both statistical and

data-driven perspectives. Train operation states are divided into four stages based on the absolute value change rate of acceleration: stationary, stable operation, start-up acceleration, and brake deceleration. Corresponding data slices are generated, and comprehensive quantile plots and correlation coefficients are utilized to analyze the cumulative mainline operation data of traction and braking systems, quantifying the coupling relationship between systems. Linear regression, support vector machine, LightGBM, and K nearest neighbors models are constructed to decouple the data, rendering the traction and braking system data normal, with related variables conforming to independence and consistency, so as to meet the prerequisites of a joint conditional probability distribution. [Result & Conclusion] The research findings indicate that data decoupling enhances the independent consistency of raw data between systems. From an engineering perspective, the LightGBM model exhibits optimal performance in both real time and offline states, achieving no less than 50% optimization rates across all quantitative analyses. By utilizing decoupled data, it becomes feasible to issue early warnings for potential faults even in cases of limited or missing fault samples, effectively reducing false alarm rates in intelligent operation-maintenance while enhancing fault prediction accuracy.

**Key words** rail transit; intelligent operation-maintenance; fault early-warning; support vector machine; LightGBM model; K-nearest neighbors model

目前,常见的智能运维算法通常建立在数据满足正态性、独立性的假设之上<sup>[1]</sup>,但由于列车系统的复杂性<sup>[2]</sup>,上述假设在实际数据中并不成立,这就导致了其算法准确率低,虚警率高。为探索列车运营数据的耦合性与独立一致性<sup>[3]</sup>,使用正态性假设下基于协方差的解耦方法,通过单车级与车队级运营数据对比,选取最优方案,并将其结合到统计过程控制与智能运维故障预警模块中。

## 1 目标数据集

### 1.1 简述

本文所研究的线路1个月所产生的数据总量为6 427.4万条,车辆按500 ms周期向着地面发送数据包,单日数据量在125万至300万条之间。

单包数据包含7 220个字段,其中5 666个单值特征字段,1 108个二值特征字段,多值字段449个。

### 1.2 构建样本

本文采用某项目01列车进行数据分析,其单日数据包总计约为14.4万条;选取牵引系统中的13个多值变量,包括电网电压、中间电流、逆变电流、电机综合速度、电机温度等;选取制动系统中的42个多值变量,包括总气制动力、参考速度、载荷、EP(电空转换)阀可能制动力值等。牵引系统(部分)信号热力相关系数图截图如图1所示。由图1可知:矩阵左对角线颜色最深。其表示变量与其自身相关度越高,颜色越浅则表示变量之间关系越弱。




图1 牵引系统(部分)信号热力相关系数图截图

Fig. 1 Screenshot of traction system (partial) signal heat map correlation coefficient diagram

## 2 定义

### 2.1 耦合性

从统计和数据驱动角度将解耦定义为概率上的非独立性<sup>[4]</sup>,即存在 $m_A$ 维向量 $\mathbf{a}$ 和 $m_B$ 维向量 $\mathbf{b}$ ,使得 $P(\mathbf{X}_A = \mathbf{a}, \mathbf{X}_B = \mathbf{b}) \neq P(\mathbf{X}_A = \mathbf{a})P(\mathbf{X}_B = \mathbf{b})$ ,得到向量集合 $\mathbf{X}_A$ 和向量集合 $\mathbf{X}_B$ 非独立,则认为子系统A和子系统B的变量存在一定的耦合性。

### 2.2 解耦

当系统A和系统B的变量存在耦合性时,需要对其进行解耦<sup>[5]</sup>。将解耦过程定义为对任意一个子系统的变量进行函数变换<sup>[6]</sup>。例如,假设系统B中的变量保持不变,将系统A中的随机向量 $\mathbf{X}_A$ 变换为 $\mathbf{X}_{A,\sim} = d(\mathbf{X}_A, \mathbf{X}_B)$ ,其在数据集中各个样本的观测值也相应变换为 $\mathbf{x}_{A,\sim} = d(\mathbf{x}_A, \mathbf{x}_B)$ 。本文旨在寻找变换 $d(\cdot)$ ,使得 $c(d(\mathbf{x}_A, \mathbf{x}_B), \mathbf{x}_B)$ 尽可能小。

## 3 构建模型

本文尝试构建4个解耦模型,将制动系统作为自变量(系统A),牵引系统作为因变量(系统B),逐个训练预测模型,将预测所得的残差作为解耦后的结果。

### 3.1 线性回归模型

建立多个多元线性回归模型对目标变量进行预测,针对系统A的变量 $X_{i,A}$ ,想要消除其与系统B之间的联系,通过如下模型进行转换  $\forall i = 1, 2, \dots, m_A$ :

$$X_{i,A,\sim} = \beta_{i0} + \sum_{j=1}^{m_B} \beta_{ij} X_{j,B} \quad (1)$$

$$X_{i,A,\sim} = X_{i,A} - X_{i,A,\sim} \quad (2)$$

式中:

$\beta_{i0}$ ——线性回归模型的截距项;

$X_{j,B}$ ——系统B的变量;

$\beta_{ij}$ —— $X_{j,B}$ 的回归系数,  $j = 1, 2, \dots, m_B$ ;

$X_{i,A,\sim}$ ——线性回归的预测值;

$X_{i,A,\sim}$ ——线性回归模型残差项,也为解耦结果。

根据已知观测值,采用矩阵形式则可以表示为:

$$\mathbf{x}_{i,A} = [\mathbf{1} \quad \mathbf{x}_B] \boldsymbol{\beta}_i + \mathbf{x}_{i,A,\sim} \quad (3)$$

$$\mathbf{x}_A = [\mathbf{1} \quad \mathbf{x}_B] \boldsymbol{\beta} + \mathbf{x}_{A,\sim} \quad (4)$$

其中:  $\boldsymbol{\beta}_i = [\beta_{i0} \quad \beta_{i1} \quad \dots \quad \beta_{im_B}]^T$ ;  $\boldsymbol{\beta} = (\boldsymbol{\beta}_1 \quad \boldsymbol{\beta}_2 \quad \dots \quad \boldsymbol{\beta}_{m_A})$ 。

式中:

$[\mathbf{1}, \mathbf{x}_B] \in R^{N(1+m_B)}$ ——系统B的变量加一列1向量组成的矩阵,1向量的加入是为了给模型加入截距项。

求解线性回归模型利用最小化均方误差的原则,可解得  $\boldsymbol{\beta} = ([\mathbf{1} \quad \mathbf{x}_B]^T [\mathbf{1} \quad \mathbf{x}_B])^{-1} [\mathbf{1} \quad \mathbf{x}_B]^T \mathbf{x}_A$ , 其中有  $[\mathbf{1} \quad \mathbf{x}_B]^T (\mathbf{x}_A - [\mathbf{1} \quad \mathbf{x}_B]^T \boldsymbol{\beta}) = 0$ , 即  $[\mathbf{1} \quad \mathbf{x}_B]^T \mathbf{x}_{A,\sim} = 0$ 。当数据经过标准化后,协方差矩阵与Pearson相关系数的计算相同,  $[\mathbf{1} \quad \mathbf{x}_B]^T \mathbf{x}_{A,\sim} = 0$  说明解耦后的变量与系统B中的变量线性相关系数为0。

### 3.2 支持向量机

构建一组超平面

$$g_i(\mathbf{x}_B) = \mathbf{w}^T \mathbf{x}_B + b_i \quad (5)$$

使得在间隔 $\epsilon$ 内,包裹所有数据点 $\mathbf{x}_{n,C,A}$ ,其中C表示n行的所有,即满足  $g_i(\mathbf{x}_{n,C,B}) - \mathbf{x}_{ni,A} < \epsilon, \forall n = 1, \dots, N$ 。优化目标为正则项  $\frac{1}{2} \|\mathbf{w}\|^2$ ,为了保证模型

的可行性,将违反约束的点作为惩罚项:

$$\min_{w_i, b_i} \frac{1}{2} \|w\|^2 + C \sum_{n=1}^N L(g_i(x_{n,C,B}), x_{ni,A}) \quad (6)$$

$$L(g_i(x_{n,C,B}), x_{ni,A}) = \begin{cases} |g(x_{n,C,B}) - x_{ni,A}| - \epsilon, & \text{若 } |g(x_{n,C,B}) - x_{ni,A}| > \epsilon \\ 0, & \text{其他} \end{cases} \quad (7)$$

式中:

$L(g_i(x_{n,C,B}), x_{ni,A})$ ——损失函数,如果预测值和观测值的偏差在  $\epsilon$  范围内,则不进行损失惩罚,否则将偏差加入损失函数中;

$C$ ——损失函数的惩罚因子。

### 3.3 LightGBM 模型

定义目标函数生成分支规则:

1) 定义集合  $R_{1,B}(j, s) = \{x_{n,C,B} \mid x_{nj,B} \leq s\}$ ,  $R_{2,B}(j, s) = \{x_{n,C,B} \mid x_{nj,B} > s\}$ 。

2) 定义目标函数为:

$$\min_{j,s} \left[ \min_{c_1} \sum_{n=1,2,\dots,N; x_{n,C,B} \in R_{1,B}(j,s)} (x_{ni,A} - c_1)^2 + \min_{c_2} \sum_{n=1,2,\dots,N; x_{n,C,B} \in R_{2,B}(j,s)} (x_{ni,A} - c_2)^2 \right] \quad (8)$$

式中:

$C_1$ ——集合  $R_{1,B}$  的期望;

$C_2$ ——集合  $R_{2,B}$  的期望;

$$\min_{c_1} \sum_{n=1,2,\dots,N; x_{n,C,B} \in R_{1,B}(j,s)} (x_{ni,A} - c_1)^2 \quad \text{—— 第一}$$

类内的因变量取值差异;

$$\min_{c_2} \sum_{n=1,2,\dots,N; x_{n,C,B} \in R_{2,B}(j,s)} (x_{ni,A} - c_2)^2 \quad \text{—— 第二}$$

类内的因变量取值差异。

3) 求解使得上述目标函数最小的变量下标  $j$  和分支阈值  $s$ ,即可按照  $x_{nj,B}$  的取值是否大于  $s$  进行分支。

上述规则的直观含义为,在每次分支时,选取最优的变量下标  $j$  和分支阈值  $s$ ,使得分支过后生成的两类数据内的因变量取值差异尽可能小。

### 3.4 K-近邻模型

以  $I_{1,B}, I_{2,B}, \dots, I_{m,B}$  作为自变量,以  $I_{i,A}$  作为因变量时,对于一个新到达的数据,即其自变量观测值为  $z_{n,C,B}$ 。则 K-近邻算法使用式(9)给出  $z_{ni,A}$  的估计值:

$$z_{ni,A}^{\wedge} = \frac{1}{k} \sum_{z_{n,C,B} \in N_k(z_{n,C,B})} z_{ni,A} \quad (9)$$

式中:

• 8 •

$N_k(z_{n,C,B})$ ——在训练集中距离  $z_{n,C,B}$  最近的  $k$  个自变量观测值。

式(9)中,  $k$  将在 3 ~ 20 之间进行试验标定,取最优结果进行评价。

## 4 数值试验

### 4.1 试验前置条件

本文采用 4 个评价指标对目标系统间的耦合性进行分析。

#### 4.1.1 K-S 检验

K-S(柯尔莫哥罗夫-斯米尔诺夫)检验对随机变量  $X_{i,A}$  对应的观测值  $z_{1i,A}, z_{2i,A}, \dots, z_{Ni,A}$ , 其样本经验分布函数为:

$$F_{i,A}(z) = \frac{1}{N} \sum_{n=1}^N I(z_{ni,A} \leq z) \quad (10)$$

假设式(10)中,  $I_{i,A}$  已经经过标准化,即样本均值为 0, 方差为 1, 则 K-S 统计量定义为:

$$S_{K-S} = \sup_x |F_{i,A}(z) - \Phi(z)| \quad (11)$$

式(11)中,  $S_{K-S}$  值域为  $[0, 1]$ , 统计量越大, 表示数据的分布与正态分布的差距越大。  $S_{K-S}$  的取值较大并不代表解耦程度较差, 而是表示此时 Pearson(皮尔逊)线性相关系数的可靠性较低。

#### 4.1.2 Pearson 线性相关系数

Pearson 线性相关系数绝对值定义为:

$$\frac{\sum_{n=1}^N (x_{ni,A} - x_{l,A,-})(x_{nj,B} - x_{j,B,-})}{\sqrt{\sum_{n=1}^N (x_{ni,A} - x_{l,A,-})^2} \sqrt{\sum_{n=1}^N (x_{nj,B} - x_{j,B,-})^2}} \quad (12)$$

式(12)中, Pearson 系数越小, 表示两系统线性关系越低。

#### 4.1.3 Spearman 相关系数

Spearman(斯皮尔曼)相关系数的取值范围在 -1 和 1 之间, 越接近于 0 表示次序变量的相关性越弱。

#### 4.1.4 $\phi$ 相关系数绝对值

对于系统 A 中的第  $i$  个变量  $X_{i,A}$ , 根据其取值范围将其划分成 2 类: 当该变量的取值落在第一类内时, 令新的类别型随机变量  $I_{i,A} = 1$ ; 否则, 令  $I_{i,A} = 0$ 。同样, 将系统 B 中的第  $j$  个变量进行划分, 并定义出类别变量  $I_{j,B}$ 。按如下规则构造出这两个变量的列联表:

令  $n_{11}$  为样本中  $I_{i,A} = 1, I_{j,B} = 1$  的样本个数;

令  $n_{12}$  为样本中  $I_{i,A}=1, I_{j,B}=0$  的样本个数;

令  $n_{21}$  为样本中  $I_{i,A}=0, I_{j,B}=1$  的样本个数;

令  $n_{22}$  为样本中  $I_{i,A}=0, I_{j,B}=0$  的样本个数;

令  $n_{ih} = n_{i1} + n_{i2} (i=1, 2)$ ;

令  $n_{sj} = n_{1j} + n_{2j} (j=1, 2)$ 。

根据上述统计结果,计算出  $\phi$  系数:

$$\phi = \frac{n_{22}n_{11} - n_{12}n_{21}}{\sqrt{n_{1h}n_{2h}n_{s1}n_{s2}}} \quad (13)$$

其中  $n_{1h} = n_{11} + n_{12}$ ;  $n_{2h} = n_{21} + n_{22}$ ;  $n_{s1} = n_{11} + n_{21}$ ;  $n_{s2} = n_{12} + n_{22}$ , 当  $\phi$  系数接近于 0 时, 表示分类变量  $I_{i,A}$  和  $I_{j,B}$  较满足独立性。

#### 4.1.5 Box-Cox 变换

统一对牵引系统(系统 B)中的 13 个变量进行解耦变换。如表 1 所示, 通过加速度变化将运行过程分为 4 个阶段。

表 1 运行阶段分类表

Tab. 1 List of operation stages

速度/(m/s)	加速度/(m/s <sup>2</sup> )	运行阶段
0	0	静止不动
>0	<0.5	平稳运行
>0	≥0.5	起动加速
>0	≤0.5	制动减速

为使数据更好地呈现正态性, 采用 Box-Cox 转换后进行类比。

#### 4.1.6 原始数据评估结果

对原始数据的评估结果进行汇总。其中, 由于 Box-Cox 变换不更改变量数值在所有样本中的排序, 因此 Spearman 系数和  $\phi$  相关系数的取值也不会改变, 即这 2 列数据使用原始数据, 其评估结果如表 2 所示。

表 2 原始数据评估结果

Tab. 2 Evaluation results of raw data

分组	统计值	Box-Cox 变换评估值			
		K-S	Pearson	Spearman	$\phi$
静止	最大值	0.428 9	0.710 1	0.502 8	0.351 1
	平均值	0.229 9	0.117 8	0.109 4	0.065 3
加速	最大值	0.434 2	0.999 9	1.000 0	0.993 6
	平均值	0.143 5	0.112 7	0.124 5	0.069 5
平稳	最大值	0.443 3	0.999 4	0.999 9	0.994 4
	平均值	0.178 1	0.092 5	0.112 5	0.065 3
减速	最大值	0.435 9	1.000 0	1.000 0	0.993 0
	平均值	0.137 8	0.115 1	0.122 8	0.076 2

#### 4.2 单列验证结果

对模型进行编号: 1(线性回归); 2(支持向量机); 3(LightGBM); 4(K-近邻)。为简化分析, 仅呈现模型所生成的加权值。单列解耦后各数值提升率如表 3 所示。

由于  $S_{K-S}$  不直接反馈试验样例独立一致性, 因此不参与该部分评价。综上, 除了支持向量机模型的表现较差以外, 其余 3 个模型的表现基本接近。在 Pearson 指标上, 线性回归模型和 LightGBM 模型效果较好, 在 Spearman 指标上, K-近邻模型的效果较好。

表 3 各模型较原始数据独立性提升率

Tab. 3 Independency improvement rates of each model compared to raw data

模型	统计值	Box-Cox 变换独立性提升率/%		
		Pearson	Spearman	$\phi$
1	最大值	61.8	31.4	71.3
	平均值	71.5	35.8	50.8
2	最大值	18.0	1.6	54.1
	平均值	-43.2	-48.0	13.8
3	最大值	65.1	40.6	54.5
	平均值	61.2	46.8	19.5
4	最大值	67.9	63.0	59.6
	平均值	57.2	57.0	21.1

#### 4.3 多列验证结果

对于原始数据而言, 先对  $S_{K-S}$  进行了统计。统计结果显示: 各个列车的  $S_{K-S}$  在原始数据上、Box-Cox 变换后, 分位数变换后, 所得到的计算结果(平均值或最大值)十分接近。Pearson、Spearman 与  $\phi$  相关系数均呈现与  $S_{K-S}$  相同分布情况。各列车的运行规律、正态性统计结果和耦合性统计结果在数值上基本类似; 若仅用 1 列列车进行训练, 则就平均值指标来看, 能够达到的解耦程度与分别训练能够达到的解耦程度差距不大。若要追求小量级的精度, 依然有必要针对各列车分别训练模型, 逐个进行解耦。

#### 5 故障预警优化

解耦的最终目的就是为了将结果应用在列车的智能运维与故障检测中。本文采用休哈特控制图来评估故障是否即将发生:

$$\bar{\bar{x}}_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \sim N\left(\mu_0, \frac{\sigma_0^2}{n}\right) \quad (14)$$



式中:

$\mu_0$ ——总体分布的真实均值;

$\sigma_0$ ——总体分布的真实方差。

进而计算均值控制的中心线、 $L_{UC}$  (95% 置信上限);  $L_{CL}$  (95% 置信下限)):

$$\begin{cases} L_{UC} = \mu_0 + Z_{\alpha/2} \frac{\sigma_0}{\sqrt{n}}, & C_L = \mu_0 \\ L_{CL} = \mu_0 - Z_{\alpha/2} \frac{\sigma_0}{\sqrt{n}} \end{cases} \quad (15)$$

式中:

$Z_{\alpha/2}$ ——正态分布的上  $\alpha/2$  分位数。

采用如下均值上下限,即上下限构成了  $1 - \alpha$  的置信区间。本文采取  $3\sigma$  原则,即  $Z_{\alpha/2} = 3$ ,对应  $\alpha = 0.0027$ 。


对  $\mu_0$ 、 $\sigma_0$  进行估计:

$$\begin{cases} \mu_{0,1} = \frac{1}{m} \sum_{j=1}^m \bar{x}_j, s_i = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2}, \\ \sigma_{0,1} = \sum_i s_i / mc_4 \end{cases} \quad (16)$$

式中:

$c_4$ ——查表常数,在样本量较大时,接近 1。

图 2 为牵引制动力预警控制图。由图 2 可知:解耦后的数据更贴合实际运营情况,相较于经验阈值,能够大大降低故障预警误报率。



注:牵引力为正,制动力为负。

图 2 牵引制动力预警控制图

Fig. 2 Diagram of traction and braking force early-warning control

## 6 结语

本文对列车牵引制动系统进行数据解耦,通过特征变换的方式使得 2 个子系统的特征之间具有较强的独立性,并将解耦工作与预测工作进行了等价转换;除了支持向量机模型外,其他 3 个模型均能达到较好的解耦效果;其中, Pearson 系数和  $\phi$  相关系

数的优化程度均不低于 60%。

LightGBM 依赖的模型假设较少,且预测速度较快,故本文选用 LightGBM 模型进行大规模的多列车数值试验;结果发现该模型在各列车上的表现趋于一致,可知采用 LightGBM 训练出的模型具有较强泛用性,其在计算能力有限的情况下,能够通过少量数据训练出能够应用于多列车解耦的模型。最后,使用控制图法,分析牵引系统,能够有效降低虚警率,提升智能运维故障预警的准确率。

## 参考文献

- [1] 周婧,王意洁,阮炜,等. 面向海量数据的数据一致性研究[J]. 计算机科学, 2006, 33(4): 137.  
ZHOU Jing, WANG Yijie, RUAN Wei, et al. Research on massive data oriented data consistency[J]. Computer Science, 2006, 33(4): 137.
- [2] 覃洪波. 基于综合联调的城市轨道交通综合监控系统接口管理研究[J]. 工程建设与设计, 2021(12): 81.  
QIN Hongbo. Research on interface management of the integrated monitoring system of urban rail transit based on integrated joint survey [J]. Construction & Design for Engineering, 2021 (12): 81.
- [3] 刘小强. 多模态数据耦合的城市地表覆盖三维分类[D]. 南京: 南京大学, 2020.  
LIU Xiaoqiang. Three-dimensional classification of urban land cover through multi-modal data coupling[D]. Nanjing: Nanjing University, 2020.
- [4] 邓丽君. 考虑多维数据耦合的综合能源时间序列预测方法研究[D]. 长沙: 湖南大学, 2021.  
DENG Lijun. Research on comprehensive energy time series forecasting method considering multi-dimensional data coupling[D]. Changsha: Hunan University, 2021.
- [5] 汪璐. 面向海量数据的实时计算一致性研究[D]. 西安: 西安电子科技大学, 2014.  
WANG Lu. Research on real time computing consistent for massive data[D]. Xi'an: Xidian University, 2014.
- [6] KOU G, ERGU D, SHANG J. Enhancing data consistency in decision matrix: adapting Hadamard model to mitigate judgment contradiction[J]. European Journal of Operational Research, 2014, 236(1): 261.

· 收稿日期:2023-11-12 修回日期:2024-02-03 出版日期:2024-05-10

Received:2023-11-12 Revised:2024-02-03 Published:2024-05-10

· 通信作者:倪弘韬,工程师,nihongtao1996@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