

# 基于向量自回归模型和小波分析法的列车 充电机电流传感器故障检测方法

陈美霞 梁师嵩 胡佳乔

(中车南京浦镇车辆有限公司, 210031, 南京//第一作者, 正高级工程师)

**摘要** 梳理了列车充电机电流传感器的运行机理, 分析了两台充电机输出电流数据, 提出了基于向量自回归模型和小波分析法的列车充电机电流传感器故障检测方法。以南京地铁宁溧线(S7线)列车为例, 验证了该方法的准确性, 能够检测出故障并能判别出故障类型。

**关键词** 地铁列车; 传感器; 故障检测; 向量自回归; 小波分析  
**中图分类号** TP212.13

DOI:10.16037/j.1007-869x.2022.04.032

## Train Charger Current Sensor Fault Detection Method Based on VAR Model and Wavelet Analysis

CHEN Meixia, LIANG Shisong, HU Jiaqiao

**Abstract** The operation mechanism of train charger current sensor is sorted. The output current data of two chargers are analyzed. The train charger current sensor fault detection method based on VAR (vector autoregression) model and wavelet analysis is proposed. Taking Nanjing Metro Ningli Line (S7) train as an example, the accuracy of the method is verified, with faults being detected and fault types being identified.

**Key words** metro train; sensor; fault detection; VAR (vector autoregression); wavelet analysis

**Author's address** CRRC Nanjing Puzhen Co., Ltd., 210031, Nanjing, China

地铁列车传感器是自动控制系统和信息系统的核心元器件之一, 准确、快速地对传感器进行故障诊断, 对保障列车运行安全性与可靠性显得极其重要。

国内外传感器故障诊断的方法主要有基于解析模型、基于信号处理和基于知识的3种传感器故障诊断法。就诊断方法而言, 非线性较线性故障诊断法更具通用性。非线性故障诊断法主要包括基于核的主分量分析法(KPCA)、主曲线分析法和主成分分析法。KPCA性能受核参数的影响很大且核映

射后的数据不可被显性表示。主曲线分析法的理论基础是寻找嵌入高维空间的非欧氏低维流形, 它不具备通用性。小波分析法是将信号分解成一系列小波函数的叠加, 克服了传统的硬件冗余法和解析冗余法的缺点, 在时域、频域均具有良好的局部化性质, 综合了前两种方法的优点<sup>[1]</sup>, 更适用于与VAR(向量自回归)模型<sup>[2]</sup>相结合, 构建电流传感器故障检测方法。

本文以南京地铁宁溧线(S7线)列车充电机电流传感器故障检测为例, 利用VAR模型预测当前值的方式进行特征量加工, 提升模型高降噪能力与拟合效果, 并结合小波分析时频局部化方法, 实现传感器多类故障的诊断。

## 1 充电机电流传感器故障检测方法

充电机就是蓄电池充电模块(BCM), 是一个静止的变流装置<sup>[3]</sup>, 其作用是将三相交流电转变为直流。一般正常工作时, 两台充电机各为半列车的直流负载供电, 当一台充电机发生故障时, 另一台充电机为整列车的直流负载供电<sup>[4]</sup>。

根据传感器输出信号检测传感器故障的方法可分为模型构建和模型运行2个阶段。

1) 模型构建阶段: ①分析两台充电机输出电流的相关性, 利用历史电流数据, 建立VAR模型; ②根据不同故障所表现的特征, 构造合适的小波变换函数。

2) 模型运行阶段: ①利用列车充电机输出电流历史数据, 通过VAR模型预测当前时间电流值, 并与传感器实际输出值作对比; ②将预测值和实际输出值作为参数输入小波函数, 识别故障类型。

### 1.1 模型选择及构建

本文根据充电机输出电流和直流负载的特点, 将两台充电机所带直流负载都作为内生变量, 建立

时间序列模型。

1.1.1 VAR 模型定义

VAR 模型研究的是不同变量之间的互动关系,采用多方程联立形式。在模型的每一个方程中,通过内生变量对模型的全部内生变量滞后值进行回归,从而估计全部内生变量的动态关系<sup>[6]</sup>。

例如,变量  $y_{1,t}$  和  $y_{2,t}$  滞后 1 期的 VAR 模型见式 (1)。其中:  $\mu_{1,t}$ 、 $\mu_{2,t}$  为误差项,均服从正态分布,其协方差  $\text{Cov}(\mu_{1,t}, \mu_{2,t}) = 0$ ;  $\mu_1$ 、 $\mu_2$  为偏差;  $A$  为回归系数;  $t$  为时间。

$$\begin{cases} y_{1,t} = \mu_1 + A_{11,t}y_{1,t-1} + A_{12,t-1}y_{2,t-1} + \mu_{1,t} \\ y_{2,t} = \mu_2 + A_{21,t}y_{1,t-1} + A_{22,t-1}y_{2,t-1} + \mu_{2,t} \end{cases} \quad (1)$$

1.1.2 传感器故障小波分析法

列车充电机常用传感器为电子式电流互感器——霍尔电流传感器。霍尔电流传感器的故障类型有短路、断路、周期性干扰、偏置和冲击(脉冲)等,相应的故障原因及表现见表 1。

表 1 传感器故障类型、故障原因及表现<sup>[5]</sup>

Tab.1 Sensor fault types, causes and symptoms<sup>[5]</sup>

故障类型	故障原因及表现
短路	传感器线路短路等原因导致,输出信号接近于零
断路	传感器输出线路开路等原因导致,输出信号接近最大值
周期性干扰	传感器输出原信号受到某一频率的周期信号的干扰所致
偏置	传感器受到一个稳定信号的干扰所致
冲击	传感器受到某个脉冲信号的干扰所致

小波变换(wavelet transform)是一种新的分析方法,既继承和发展了傅里叶变换局部化思想,又克服了窗口大小不随频率变化等缺点,能够提供一个随频率改变的“时间-频率”窗口,是进行信号时频分析和处理的理想工具<sup>[7]</sup>。

小波分析法是一种窗口大小固定但形状可变(时宽和频宽可变)的时频局部化分析方法,具有自适应的时频窗口:高频段时,频率窗口增大,时间窗口减小;低频段时,时间窗口增大,而频率窗口减小。小波分析法的关键在于引入满足一定条件的基本小波函数以代替傅里叶变换中的基函数。小波基函数经伸缩和平移得到一族函数:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi_{a,b}\left(\frac{t-b}{a}\right), a > 0 \quad (2)$$

式中:

$\psi_{a,b}$ ——分析小波或连续小波;  
 $a$ ——尺度(伸缩)因子;  
 $b$ ——时间(平移)因子。

1.1.3 小波基函数的选择及小波构造

首先选取小波母函数  $\psi(t)$ 。在工程实践中,Molet 小波一般用于信号的表示和分类、图像识别和特征提取等;墨西哥草帽小波一般用于系统识别;样条小波一般用于材料探伤;Shannon 小波一般用于差分方程求解;Daubechies 小波一般用于数字信号处理。在 Daubechies 小波系中,各小波母函数都有自己的特点。由文献[8]可知,在用小波进行故障诊断时,部分应用 db3 小波,部分应用 db6 小波。本模型使用 db6 小波,并对 db6 小波进行 3 层分解:① 将小波基函数进行平移和伸缩,得到一簇小波基函数  $\psi_{a,b}(t)$ ,并利用计算机自动选择;② 将要分析的函数和做卷积,得到小波变换系数,本模型利用计算机自动输出小波变换系数;③ 输出经过小波变换得到的信号,即第 3 层低频信号 cA3、第 3 层高频信号 cD3、第 2 层高频信号 cD2 和第 1 层高频信号 cD1。

1.2 故障检测

图 1 为充电机传感器故障检测流程。以正常电流为  $(10 \pm 2)$  A、传感器输出电流最大值为 200 A 的传感器为例,模拟各种类型的故障,分析故障信号特点与故障信号经 3 层小波变换后的信号特点。

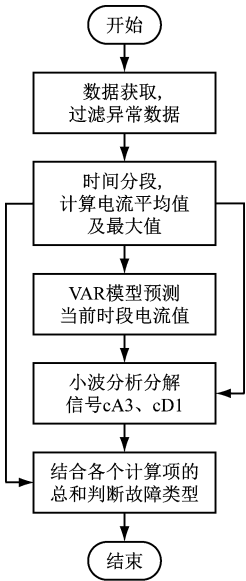


图 1 故障检测流程

Fig.1 Fault detection flowchart

通过大量数据分析,得到的故障类型与模型参数对应表见表 2。

表 2 故障类型与模型参数对应表

Tab.2 The correspondence between model output and fault types

故障类型	输出电流最大值/A	输出电流平均值/A	低频信号变化率/%	高频信号变化率/%
断路故障	200	200	2.80 ~ 2.85	0.36 ~ 0.40 (cD1 取极大值)
短路故障	0	0	<1	-0.40 ~ -0.36 (cD1 取极大值)
周期故障	0 ~ 200			0.36 ~ 0.40 (cD1 极大值与极小值相等)
偏置故障	0 ~ 200		1.70 ~ 2.80	≈0 (cD1 取极值的绝对值)
脉冲故障			与正常电流段接近	≈0.50 (cD1 取极大值)

2 电流传感器故障检测方法应用案例分析

以南京地铁宁溧线 T4 列车充电机电流传感器故障检测为例,采用 VAR 模型和小波分析法判断故障类型。以 2020 年 7 月 11 日 T4 列车为例,因列车正常运行,无传感器故障发生,故在模型运行阶段中的故障预测部分,采用人工设置故障来判断模型的有效性。人工设置故障参照表 2 进行故障触发场景处理。

2.1 数据处理

1) 数据特征构建:将充电机输出电流减去蓄电池充电电流构建特征“直流负载电流”。

2) 数据消噪:采用前后 1 个值求平均值的方法对 1)中得到的特征“直流负载电流”进行消噪。

3) 按照 3 min 间隔分割消噪后的直流负载电流数据,生成新的数据表。经过消噪和时间分割后的直流负载电流数据见图 2。

2.2 VAR 模型构建

2.2.1 计算内生变量相关系数

采用皮尔逊相关系数计算 A1、A2 车厢直流负载电流,得到 2 个直流负载电流的相关系数为 -0.56,两者为负相关。

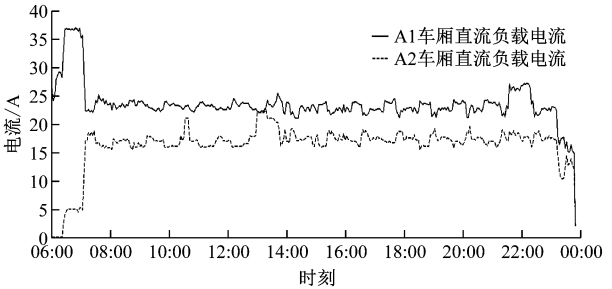


图2 按照 3 min 间隔分割后直流负载随时间变化曲线  
Fig.2 Variation curve of DC load over time according to 3 min segmentation

2.2.2 平稳性检验

ADF( Augmented Dickey-Fuller) 检验就是判断序列是否存在单位根:若序列平稳,就不存在单位根;否则,存在单位根。ADF 检验的原假设就是存在单位根,若得到的显著性检验统计量(即假设检验值)小于 3 个置信度(10%、5%、1%)对应的判断值,则对应应有(90%、95%、99%)的概率拒绝原假设。利用计算机实现 ADF 检验,结果见表 3。由表 3 可见,A1、A2 车厢直流负载电流 ADF 检验值均小于置信度对应的判断值,且假设检验结果均小于 0.05 时可以拒绝原假设。

表 3 直流负载电流 ADF 检验结果表

Tab.3 DC load current ADF test results

车厢	假设检验值	假设检验结果	滞后阶数	ADF 检验统计量判断值		
				置信度为 1%	置信度为 5%	置信度为 10%
A1	-8.275 012	0.000 001	2	-3.451 974	-2.871 063	-2.571 844
A2	-10.542 507	0.000 001	1	-3.451 902	-2.871 032	-2.571 827

2.2.3 协整检验

协整是从分析时间序列的非平稳性入手的,协整的意义在于检验回归方程所描述的因果关系是否是伪回归。利用计算机实现协整检验,结果见表 4。由表 4 可见,统计值小于 1% 的判断值,说明有 99% 的把握拒绝原假设,假设检验结果也小于

0.05,则 A1、A2 车厢直流负载电流存在协整关系。

2.2.4 模型定阶及参数估计

1) 模型定阶。分别设定阶数 1 ~ 10,使用赤池信息准则(AIC)和贝叶斯信息准则(BIC)综合判断模型阶数。利用计算机实现,综合 AIC 和 BIC 二者均最小的阶数为 4。

表 4 A1、A2 车厢直流负载电流协整检验结果

Tab.4 Test results of DC load current co-integration of compartments A1 and A2

统计值	假设检验结果	协整检验判断值		
		置信度 1%	置信度 5%	置信度 10%
-4.166 517	0.004 098	-3.932	-3.356	-3.058

2) 参数估计。使用最小二乘法(OLS),得到残差序列(residuals)相关性为-0.136 316,表明相关性较弱。

2.2.5 系数平稳性检验

VAR 模型除了要对原始数据进行平稳处理,还需要检验估计参数的稳定性。平稳性检验使用 CUSUM 检验,即 CUSUM 检验结果要无法拒绝原假设才可视为系数稳定。只有通过参数稳定性检验的模型才具有预测能力。利用计算机实现 CUSUM 检验,A<sub>1</sub>、A<sub>2</sub> 车厢的假设检验结果分别为 0.594 9、0.351 9,均大于 0.05,则原假设成立,即系数是平稳的。

2.3 构造故障检测序列

1) 利用 VAR 模型预测本时段直流负载电流。经过处理的数据大小为(308,2),截取第 196 至第 200 行数据作为研究对象。利用第 196 至 199 行的数据预测第 200 行的值,见表 5。由表 5 可见,VAR 模型预测准确率较高,可满足工程需求。

表 5 VAR 模型预测结果与实际值对比

Tab.5 Comparison between VAR model prediction result and actual value

车厢	直流负载电流 A	
	预测值	实际值
A1	23.703	23.720
A2	16.878	16.862

2) 利用预测到的本时段直流负载电流计算本时段充电机输出电流;同时,获取当前时段的蓄电池充电电流。预测的充电机输出电流等于预测的本时段直流负载电流与蓄电池充电电流之和。

3) 预测数据与实际数据进行连接。获取当前时段的实际充电机输出电流,与预测的充电机输出电流进行连接,形成序列,即故障检测序列。

2.4 小波分析法故障检测

1) 将上述得到的故障检测序列送入小波变换函数,根据实际充电输出电流值、第 3 层低频信号和第 1 层高频信号,对照表 2,进行故障检测。

2) 因实际数据中无故障标签数据,本文采用实际数据结合故障模拟的方式,构造故障序列。A1 车厢故障检测模型的输入参数、检测参数及模型输出见表 6。由表 6 可见,模型输出与表 2 对应正确,故模型具备预测能力。

表 6 A1 车厢故障检测模型的输入、检测参数及模型输出表

Tab.6 A1 vehicle fault detection model input, detection parameters and output

输入参数		检测参数		模型输出
输出电流最大值/A	输出电流平均值/A	低频信号变化率/%	高频信号变化率/%	
300.000	300.000	2.820	0.389	断路故障
0	0	3.200	-0.389	短路故障
80.560	26.700	0.380	0.387	周期故障
76.500	65.470	2.670	0.013	偏置故障
100.000	22.500	0.610	0.495	脉冲故障

3 结语

本文提出了列车充电机电流传感器故障检测方法,通过数据分析,构建 VAR 模型,利用小波转换识别充电机传感器故障,并制定故障类型判别标准。以南京地铁宁溧线 T4 列车为实际案例,利用充电机输出电流,按照该方法检测出了传感器故障,验证了该方法的有效性。该方法暂不能识别传感器其他类型故障。

参考文献

[1] 钱朋朋. 基于多方法结合的传感器故障诊断方法研究[D]. 沈阳:沈阳理工大学,2013.  
QIAN Pengpeng. Research on sensor fault diagnosis based on multi-algorithm integration method[D]. Shenyang: Shenyang Ligong University, 2013.

[2] 向智大. 航空发动机温度传感器故障分析[J]. 科学与财富, 2018(22):53.  
XIANG Zhida. Fault analysis of aeroengine temperature sensor[J]. Science & Wealth, 2018(22):53.

[3] 王乐天. 广州地铁 A2、A3 型电客车充电机带负载能力异常处理分析及整改措施[J]. 机电工程技术, 2014(6):229.  
WANG Letian. Analysis and improvement of the battery charger abnormal load capacity in A2 and A3 metro vehicle of Guangzhou[J]. Mechanical & Electrical Engineering Technology, 2014(6):229.

[4] 张伟. 1500 V 地铁充电机的方案研究[J]. 变频器世界, 2016(7):48.

(下转第 173 页)