

# 基于 FOA-BP 神经网络模型的城市轨道交通 列车车门故障预诊断\*

温凯越<sup>1</sup> 仇维斌<sup>2</sup> 丁先泽<sup>1</sup> 欧红香<sup>1</sup>

(1. 常州大学安全科学与工程学院, 213164, 常州; 2. 无锡学院交通控制工程系, 214105, 无锡)

**摘要** [目的] 为了在城市轨道交通(以下简称“城轨”)列车车门发生故障前展开预防性维修,避免人员和财产受到损害,保证城轨列车的运行安全性,有必要研究城轨列车车门故障的预诊断。[方法] 以城轨列车车门发生故障前的异常电流信号作为研究对象,设计了一种 FIR(有限冲激响应)滤波器,对采集到的城轨列车车门电流信号数据进行数据滤波与量纲一化处理;通过 FOA(果蝇优化算法)-BP(反向传播)神经网络模型,对量纲一化后不同车门的关门状态学习样本数据进行学习训练,并输出测试结果;对比分析 FOA-BP 与 BP 神经网络模型训练后的输出结果。[结果及结论] 采用 FIR 滤波器+汉宁窗函数法能够有效去除高频噪音的干扰,保留能够正确反映电流变化趋势的低频信号部分;相比于传统 BP 神经网络模型,采用 FOA-BP 神经网络模型进行训练,具有训练方法简洁、训练时间短、诊断精度大幅提高等优点;FOA-BP 神经网络模型的真实输出值与期望输出值误差小于 1%,能够满足城轨列车车门故障精准诊断的需求。

**关键词** 城市轨道交通;列车车门;神经网络模型;故障预诊断

中图分类号 U270.386

DOI:10.16037/j.1007-869x.2025.05.048

## Prediction of Urban Rail Transit Train Door Faults Based on FOA-BP Neural Network Model

WEN Kaiyue<sup>1</sup>, QIU Weibin<sup>2</sup>, DING Xianze<sup>1</sup>, OU Hongxiang<sup>1</sup>

(1. School of Environmental and Safety Engineering, Changzhou University, 213164, Changzhou, China; 2. School of Transportation and Vehicle Engineering, Wuxi University, 214105, Wuxi, China)

**Abstract** [Objective] In order to carry out preventive maintenance before urban rail transit (URT) train doors fail, avoid personnel and property damage, and ensure the operation

safety of URT trains, it is necessary to study the pre-diagnosis of URT train door failures. [Method] Taking the abnormal current signal of URT train door before failure as the research object, a FIR (finite impulse response) filter is designed to filter and dimensionally normalize the collected URT train door current signal data; the FOA (fruit fly optimization algorithm)-BP (back propagation) neural network model is used to train the closed state learning sample data of different doors after dimensional normalization, and output test results; FOA-BP results and output results after BP neural network models training are compared and analyzed. [Result & Conclusion] The FIR filter + Hanning Window function method can effectively remove the interference of high-frequency noise and retain the low-frequency signal part that can correctly reflect the current change trend. Compared with the traditional BP neural network model, the FOA-BP model has the advantages of simple training method, short training time and greatly improved diagnostic accuracy. The error between the actual output value and the expected FOA-BP model output value is less than 1%, satisfying accurate diagnosis needs of URT train door faults.

**Key words** urban rail transit; train door; neural network model; fault pre-diagnosis

## 0 引言

在城市轨道交通(以下简称“城轨”)列车运行过程中,安全事故一旦发生,极易造成较大的人员伤亡和财产损失<sup>[1]</sup>。目前,我国的城轨列车大多采用塞拉门系统,其具有节约空间、密封性能良好等特点<sup>[2]</sup>。由于城轨列车的运行密度较大,在长期反复的车门开关过程中,其各部件之间的磨损频繁,最终导致了车门各方面的性能有所下降,进而增加了故障率<sup>[3]</sup>。

\* 工信部环保安全技术服务平台项目(2020-07-3-1);2022 年江苏省研究生实践创新计划项目(SJ CX22\_1368);常州大学教育教学研究重点课题(GJY2021005);2022 年江苏省研究生教育教学改革重点课题(苏学位字函[2022]4 号)

城轨列车车门在运维过程中存在的问题主要表现为故障部位不易发现、故障隐患排除困难、检修周期长、维修成本高、故障概率高等。车门的机械结构较为复杂,在车门闭合位置附近存在一处弯道区域,该区域易发生机械故障,故障发生则会引起车门电流信号变化,因此提取城轨列车车门电流信号的特征值数据并进行相关预处理,对于车门故障预诊断具有重要的意义。

城轨列车车门的电流、电压及霍尔信号等参数变化可以反映车门的开关门状态,由于最初采集到的原始数据存在较多干扰信号,不能通过数据曲线特点直接有效地判断车门是否存在故障隐患,故有必要先对原始数据进行初步滤波等预处理,使得数据曲线更加平滑,能够直观地反映数据曲线的特点。随着信息化时代的到来,机器学习算法渐渐成为国内外学术界的热点话题,为了有效预测设备故障,故障预测方法也逐渐增多,其中,支持向量机与人工神经网络算法在故障预测方面应用最多。文献[4]利用BP(反向传播)神经网络搭建了AISI1045钢材疲劳寿命预测模型,并取得了良好的疲劳寿命预测结果。然而,BP神经网络极易陷入局部极小点,因此往往需要对其进行改进与优化。

本文采用窗函数法,设计了一种FIR(有限冲激响应)滤波器对城轨列车车门电流信号数据进行滤波与量纲一化处理,获得能够反映电流信号整体趋势的平滑数据曲线;构建并训练了FOA(果蝇优化算法)-BP神经网络模型,通过FOA-BP神经网络模型处理FIR滤波数据,并与BP神经网络训练后的输出结果进行对比分析。本文研究可为城轨列车车门实际运行过程中的故障预诊断提供一种参考方法。

## 1 车门数据预处理

### 1.1 原始车门数据采集

以常州市某公司研制的城轨列车车门为研究对象,该车门安装在某车辆段试验车上。选用公司现有车门控制器硬件及测试软件作为采集设备。在列车运行过程中,由门控器向外发送数据,并由专门设置的上位机采集车门数据。每执行一次开关门循环,便能采集到一组开门及关门的过程数据,其中正常或非正常开关门可以由人为设定参数进行模拟。

本文所选取的数据为城轨列车车门在试验车上采集的车门关门数据,采集对象为随机抽取的不同车厢、不同位置的若干车门,试验车上的空调等设备在正常工况下运行。以驱动电机的电流信号数据为例,首先对每个状态良好的车门采集100组关门电流数据,作为车门处于健康状态的学习样本。然后,对该车门的弯道区域分别施加3 kg和10 kg的重力负载,用于模拟车门运行一段时期后,门体将会出现不同级别的阻力异常,因此各采集60组电流数据作为学习样本。由于采集环境较为复杂,门体在弯道区域的运行也不够平滑,故采集到的电流信号不能直接用于训练,需对数据进行预处理。

数据采集过程中有以下几个要点需注意:①每组数据以城轨列车车门开门-关门为一个完整过程;②采集的每个数据点均带有时间戳;③数据采集需能获取开关门通、断时刻及通、断持续时间的数据,并能记录开门开始时间点、开门结束时间点、关门开始时间点及关门结束时间点;④数据采集需能获取车门开门、关门过程中的母线电压、电动机电流及车门位移等连续信号参数。

### 1.2 数据滤波方法

数字滤波器具有较高的稳定性与精度,其中包括IIR(无限冲激响应)滤波器与FIR滤波器。相较于IIR滤波器,FIR滤波器为线性相位延迟滤波器,且其稳定性较高、信号处理速度较快,因此采用FIR滤波器对城轨列车车门数据进行滤波处理。

相较于其他设计方法,采用窗函数法设计FIR滤波器具有运算量更小、原理及应用更为简洁的优点。在窗函数法中,汉宁窗法能够大幅提高频谱幅值精度,故本文选取汉宁窗法设计FIR滤波器来处理列车车门不同关门状态下的数据。

### 1.3 滤波处理结果

设置采样频率为1 000 Hz、截止频率为50 Hz、指定阶数为10的汉宁窗设计FIR低通滤波器。针对城轨列车车门滑槽摩擦力增大导致开关门过程出现卡顿的故障,对5种城轨列车车门不同关门状态的电流信号数据进行滤波处理,以城轨列车车门弯道负载10 kg关门状态为例,数据处理前后的电流信号如图1所示。经过滤波处理后的电流数据曲线波动幅度明显小于原始数据曲线,保留了可以直观反映曲线趋势与特点的低频信号部分,信号中的高频部分噪声得到了有效去除。




图1 数据处理前后的电流信号

Fig. 1 Current signals before and after data processing

## 2 车门数据学习算法

对于车门滑槽摩擦力增大导致车门开关门过程出现卡顿的现象,在不同故障情况下,不同车门经过滤波处理后的电流数据曲线大体趋势相近,但具体值可能稍有区别。当初始车门电流数据滤波处理后,需选择合适的智能算法对车门数据进行自学习,学习完成后,当后续车门相关数据导入时,算法可根据学习结果自行判断车门状态是否正常,实现列车车门故障的预诊断。

### 2.1 BP神经网络算法

BP神经网络是一种多层前馈神经网络,其通常分为3层,通过不断改变阈值与权值,最终逼近所需的计算结果,并尽可能减小输出误差。

BP神经网络算法调整权系数的步骤如下:

步骤1 调整输出层权系数;

步骤2 调整隐含层权系数;

步骤3 计算每个样本 $P$ 的输入模式所对应的二次型准确函数;

步骤4 得到系统对 $N$ 个样本的总准确函数。

相较于其他算法,BP神经网络算法能够更靠近

任意非线性映射关系,同时拥有良好的泛化能力。但BP神经网络模型也有缺点,在训练网络的过程中,隐含层节点太多会降低收敛速度,增加训练时间,则会出现局部最优的问题。此外,BP神经网络算法学习不稳定,当训练新样本时,旧样本会趋于消失。

### 2.2 果蝇算法

FOA是一种新兴的智能优化算法,这种算法是从粒子群算法等发展而来的,目前已广泛应用于工程、财务、管理等领域。FOA具有寻优速度快、精度高、不易陷入局部最优等特点,其主要用于结合遗传算法进行多目标组合优化。

本文提出一种FOA-BP神经网络算法模型,改进了原模型容易陷入局部最优的缺点,进而使城轨列车车门故障预诊断的诊断结果更为准确。

### 2.3 FOA-BP神经网络算法

FOA-BP神经网络算法的计算步骤为:

步骤1 初始化网络,确定神经元个数,计算阈值数与权值数,将其作为果蝇个体。

步骤2 赋予各阈值与权值搜寻全局最优值的随机距离与方向,计算味道浓度判定值,代入适应度函数,并计算网络适应度函数的最优值。

步骤3 更新已求出的各项坐标与最优值。

步骤4 反复执行步骤2,若适应度函数值相比前一代更优,则执行步骤5;反之,则返回步骤1并重新确定初始值。

步骤5 将所得到的最优阈值与权值代入BP神经网络得到FOA-BP神经网络模型,将测试数据代入FOA-BP神经网络模型,并加以验证。

## 3 基于FOA-BP神经网络模型的车门故障预诊断

### 3.1 提取特征向量

由于城轨列车车门电流信号的频率十分丰富,其频带能量会受故障影响而发生变化,故选取频带能量作为电流信号的特征向量,通过小波包分解获得该向量。

本文采用Sym8小波方法对处理后的电流信号进行降噪分解,之后通过db1小波进一步进行小波包分解,利用得到的特征向量结合车门关门状态建立车门故障模型。样本数据包含城轨列车车门正常关门数据、车门弯道负载3 kg非正常关门数据及车门弯道负载10 kg非正常关门数据。对不同城轨



列车车门各采集 60 组电流曲线数据作为学习样本,其中 50 组作为学习样本,10 组作为测试样本进行分析。

利用小波包分解法将振动信号的频率(0~1 Hz)平均分成 3 个频带。对特征向量进行量纲一化处理,则有:

$$X = [E_1 \ E_2 \ E_3] \quad (1)$$

式中:

$X$ ——振动信号频率的特征矩阵;

$E_1$ 、 $E_2$ 、 $E_3$ ——第 1、2、3 个频带的特征向量。

部分训练样本的特征向量如表 1 所示。

表 1 部分训练样本的特征向量

Tab. 1 Characteristic vectors of partial training samples

序号	特征向量			故障向量
	$E_1$	$E_2$	$E_3$	
1	0.096 0	0.002 5	0.000 8	[1 0 0]
2	0.100 6	0.004 8	0.000 9	[1 0 0]
3	0.655 8	0.038 7	0.008 3	[0 1 0]
4	0.478 6	0.026 4	0.007 5	[0 1 0]
5	0.266 2	0.007 7	0.004 0	[0 0 1]
6	0.387 4	0.009 2	0.005 3	[0 0 1]

### 3.2 设置 FOA-BP 神经网络模型各项参数

基于城轨列车车门关门电流信号的特征向量,确定所提 FOA-BP 神经网络模型的输入层包含 8 个节点,输出层包含 3 个节点。设定网络学习效率为 10%,进行 1 000 次训练,目标误差为 0.1‰。

若网络拟合数据过少会导致数据失真,反之则出现数据过拟合,从而降低模型的泛化能力。本文选取 10 个隐含层节点,并依次增加数量至 20 个,期间寻找到最优的隐含层节点数为 15 个,随后确定迭代次数为 100 次,果蝇群体数为 30。FOA 适应度函数  $f(i)$  可以表示为:

$$f(i) = \text{norm}((T_{\text{outtr}} - T_{\text{out}}), 2) \quad (2)$$

式中:

$i$ ——第  $i$  个果蝇;


$T_{\text{outtr}}$ ——理想输出矩阵;

$T_{\text{out}}$ ——实际输出矩阵。


### 3.3 车门故障预测结果分析

代入 FOA 适应度函数的最优阈值、权值,即可得到 FOA-BP 神经网络模型。采用 BP 神经网络模型与 FOA-BP 神经网络模型对城轨列车车门电流数据进行训练测试,2 种网络模型的训练曲线如图 2

所示。由图 2 可知:BP 神经网络模型经过 73 次迭代训练后才达到期望的最佳误差;FOA-BP 神经网络模型经过 28 次迭代训练后就达到了期望的最佳误差。由此可知:相较于 BP 神经网络模型,FOA-BP 神经网络模型可以更快达到期望的最佳误差,训练效率更优。



a) BP 神经网络模型



b) FOA-BP 神经网络模型

图 2 2 种网络模型的训练曲线

Fig. 2 Training curves of two network models

车门系统正常运行视为不受外界力影响;当处于故障状态时,则受到相当于一定量弯道负载的负面影响,设车门处于轻微故障状态时的弯道负载为 3 kg,车门处于较大故障状态时的弯道负载为 10 kg。3 种工况下,BP 神经网络模型与 FOA-BP 神经网络模型诊断测试结果如表 2 和表 3 所示。通过 BP 神经网络模型训练后的第 3 组测试输出数据出现诊断失误情况,其输出结果偏离目标近 50%;第 4 组和第 5 组的输出结果与目标偏离也较大,分别为 36% 与 32%,输出结果无法逼近 0 或 1。相比之下,通过 FOA-BP 神经网络模型训练后的真实输出值与目标输出值相差均小于 1%,诊断精度获得了大幅提高。研究结果表明:FOA-BP 神经网络模型可对城轨列车车门关门故障实现更精确的预诊断。

表 2 3 种工况下 BP 神经网络模型诊断测试结果

Tab. 2 Diagnosis test results of BP neural network model under three working conditions

序号	期望输出			BP 神经网络输出		
	正常运行工况	弯道负载 3 kg 工况	弯道负载 10 kg 工况	正常运行工况	弯道负载 3 kg 工况	弯道负载 10 kg 工况
1	1	0	0	0.938 0	0.014 5	0.012 2
2	1	0	0	0.900 2	0.009 7	0.067 9
3	0	1	0	0.495 8	0.759 4	-0.112 1
4	0	1	0	0.345 0	0.647 7	-0.196 5
5	0	0	1	0.316 4	-0.297 9	0.945 3
6	0	0	1	0.007 7	0.155 3	1.003 5

表 3 3 种工况下 FOA-BP 神经网络模型诊断测试结果

Tab. 3 Diagnosis test results of FOA-BP neural network model under three working conditions

序号	期望输出			FOA-BP 神经网络输出		
	正常运行工况	弯道负载 3 kg 工况	弯道负载 10 kg 工况	正常运行工况	弯道负载 3 kg 工况	弯道负载 10 kg 工况
1	1	0	0	0.999 8	0.0013	0.000 6
2	1	0	0	1.000 1	-0.000 2	0.000 2
3	0	1	0	-0.000 3	1.000 2	0.000 6
4	0	1	0	0.000 1	1.000 0	0.000 3
5	0	0	1	-0.087 7	0.049 7	0.977 8
6	0	0	1	0.000 3	0.000 2	0.998 8

## 4 结语

本文提出一种 FOA-BP 神经网络模型,解决了训练过程中容易出现局部最优的问题,优化了 BP 神经网络的结构,在缩小训练时间的同时,大幅提高了训练效率。通过城轨列车关门电流数据对比了 FOA 和 BP 神经网络模型的训练输出结果。研究表明,在城轨列车车门故障预诊断方面,FOA-BP 神经网络模型比 BP 神经网络模型具备更高的预测精度,能够达到对城轨列车车门故障进行预诊断的目的。

## 参考文献

- [1] 王希良,李季瑶,廉梦珂,等. 基于复杂网络模型的地铁系统脆弱性分析[J]. 城市轨道交通研究, 2021, 24(8): 47.  
WANG Xiliang, LI Jiyao, LIAN Mengke, et al. Vulnerability analysis of metro system based on complex network model[J]. Urban Mass Transit, 2021, 24(8): 47.
- [2] 马润,秦云,欧红香. 基于遗传算法优化 BP 神经网络动车组塞拉门故障预测与诊断[J]. 工业安全与环保, 2020, 46(12): 14.  
MA Run, QIN Yun, OU Hongxiang. Fault prediction and diagnosis of sliding plug door in EMU based on genetic algorithms optimized BP neural network[J]. Industrial Safety and Environmental Protection, 2020, 46(12): 14.
- [3] 刘志亮,潘登,左明健,等. 轨道车辆故障诊断研究进展[J]. 机械工程学报, 2016, 52(14): 134.  
LIU Zhiliang, PAN Deng, ZUO Mingjian, et al. A review on fault diagnosis for rail vehicles[J]. Journal of Mechanical Engineering, 2016, 52(14): 134.
- [4] REZA KASHYZADEH K, MALEKI E. Experimental investigation and artificial neural network modeling of warm galvanization and hardened chromium coatings thickness effects on fatigue life of Al-Si 1045 carbon steel[J]. Journal of Failure Analysis and Prevention, 2017, 17(6): 1276.

· 收稿日期:2023-05-24 修回日期:2023-07-05 出版日期:2025-05-10  
Received:2023-05-24 Revised:2023-07-05 Published:2025-05-10  
· 第一作者:温凯越,硕士研究生,279174714@qq.com  
通信作者:欧红香,教授,760263761@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