

DOI: 10.13382/j.jemi.B2104047

基于阵列漏磁信号分析的无刷直流电机 高阻接触故障诊断研究^{*}

武智超¹ 王 慧¹ 王吉亮¹ 王骁贤¹ 陆思良^{1,2}

(1. 安徽大学电气工程与自动化学院 高节能电机及控制技术国家地方联合工程实验室 合肥 230601;

2. 西南交通大学牵引动力国家重点实验室 成都 610031)

摘 要: 无刷直流电机具有效率高、能量密度高、噪音低等优点进而被广泛应用于汽车、工业自动化、航空航天等领域。高阻接触(high resistance connection, HRC)故障是电机的典型故障之一,该故障严重时会导致急剧温升乃至火灾,因而无刷直流电机的HRC故障研究具有重要的意义。通常采用电流电压信号分析的方法诊断HRC故障,但现有的方法仍存在局限与不足。针对此问题,设计了一种新的结合阵列漏磁信号分析和机器学习的方法实现无刷直流电机HRC故障的定位和定量分析。首先通过安装在电机外壳的霍尔传感器阵列采集多通道漏磁信号,利用神经网络分析漏磁信号的时域特征实现电机HRC故障检测和定位。在确定故障相之后,利用另一个神经网络模型分析漏磁信号频域特征实现HRC故障的定量分析。实验结果表明,提出的方法检测和定位故障的精度为98.75%,故障定量分析的平均均方根误差为0.018 Ω 。该方法具有非侵入式测量、易于实现、效率高等优点,对提升无刷直流电机HRC故障检测精度和效率具有促进作用。

关键词: 无刷直流电机;HRC故障诊断;霍尔传感器阵列;漏磁信号;神经网络

中图分类号: TM12;TP306+.3 **文献标识码:** A **国家标准学科分类代码:** 460

Fault diagnosis of high resistance connection in brushless DC motor based on analysis of array leakage flux signals

Wu Zhichao¹ Wang Hui¹ Wang Jiliang¹ Wang Xiaoxian¹ Lu Siliang^{1,2}

(1. National Engineering Laboratory of Energy Saving Motor and Control Technology, School of Electrical

Engineering and Automation, Anhui University, Hefei 230601, China; 2. Traction Power State

Key Laboratory, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Brushless DC motors (BLDCMs) have been intensively used in automobiles, industry automations, and aeronautics and astronautics due to their advantages including high efficiency, high power density, and low noise. High resistance connection (HRC) fault is one of the typical motor faults. A severe HRC fault will cause serious temperature rise and even fire, and hence diagnosis of HRC fault in BLDCM is of significant. Generally, the HRC faults are detected by analyzing the motor current and voltage signals. However, there still deficiencies in the existed methods. This study designs a new method that combines the analysis of the array leakage flux signals and machine learning technology to realize location and quantitative analysis of HRC fault in BLDCM. First, multi-channels of flux signals captured by a Hall sensor array that installed on the motor shell are sampled. A neural network model based on the time-domain features is designed to detect and localize the HRC faults. Subsequently, another neural network model based on the frequency-domain features is used to quantitatively analyze the HRC fault degree. The experimental results indicated that the accuracy of fault detection and localization is 98.75% and the averaged root mean square error of quantitative analysis is 0.018 Ω . The proposed method is noninvasive, easy to implement with high efficiency, hence, it will improve the accuracy and efficiency of HRC fault detection in BLDCM.

Keywords: BLDCM; HRC fault diagnosis; Hall sensor array; leakage flux signal; neural network

0 引言

无刷直流电机 (brushless DC motor, BLDCM) 是一种永磁电机,具有效率高、能量密度高、控制简单等优点而广泛应用于新能源汽车、工业工控自动化以及航空航天等领域。长时间负载运行的 BLDCM 不可避免地发生电气或机械故障,如果不能及时地诊断故障将有可能导致温升过热乃至火灾,造成停机损失和危害人员安全。因此,电机的状态监测和故障诊断具有十分重要的意义^[1-2]。

高阻接触 (high resistance connection, HRC) 故障是电机典型电气故障之一。该故障导致电机三相电流不平衡,进而引起温升和过热,严重时会导致电机烧毁甚至火灾。HRC 故障通常通过分析电机的电流电压信号进行诊断^[3-4]。例如文献[5]提出一种两步骤法实现了 BLDCM 的 HRC 故障定位和定量分析,但该方法需要接入电机的控制系统采集零序电压和三相电流,对采集系统要求较高。

除了电流电压等监测手段^[6-7],基于电机漏磁信号分析的方法也是能够实现电机状态监测和故障诊断的有效方法^[8-10]。电机的杂散磁通是泄露在电机机壳外的磁通,杂散磁通受到电机故障的影响,因此可以通过漏磁信号分析反映电机的状态^[11-12]。文献表明,漏磁信号分析可以检测多种类型的故障,包括定子故障、转子故障^[13]、匝间短路故障^[14-15]、转子断条^[16]、气隙偏心^[17]、机械故障^[18-19]等。基于漏磁信号分析的方法具有容易实现、非侵入式测量等特点,并且可以独立于电机的控制系统实现信号测量,适合于电机的在线监测诊断。

然而,利用漏磁信号分析检测 BLDCM 的 HRC 故障尚未见文献报道,同时由于 BLDCM 采用方波控制和 PWM 调速,因此 BLDCM 的漏磁信号成分复杂,不易于直接分析。为此,本文提出一种新方法^[20],利用机器学习从 BLDCM 阵列漏磁信号中学习提取特征以实现 HRC 故障定位和定量分析。研究结果表明本文方法能够有效实现预期目标,该方法对于提高 BLDCM 的状态监测和故障诊断精度和效率具有较高的应用价值。

1 HRC 故障定位和定量分析方法

本文方法通过两个步骤实现:1) 利用经典的反向传播神经网络 (back propagation neural networks, BPNN) 实现故障检测和故障相的定位;2) 在确定故障相的基础上定量评估 HRC 的故障程度。由于漏磁信号所携带的信息和传感器安装位置强相关,因此本文设计一个霍尔传感器阵列同步采集三通道的漏磁信号。

1.1 定位故障相

通过分析采集到的漏磁信号的时域特征将 BLDCM 分为健康(H)状态、A 相故障、B 相故障、C 相故障共 4 类状态,其对应的分类标签分别为 1、2、3、4。3 相 HRC 故障通过分别在定子绕组对应相外接电阻设置,外接电阻的阻值设置为 0.1~2 Ω,以 0.1 Ω 间隔递增。因此每一类故障包含 20 组不同故障等级的数据。随后,从 3 路同步采集的漏磁信号中构造时域特征,特征矩阵表示如下:

$$\mathbf{F}_1 = [\mathbf{H}, \mathbf{A}, \mathbf{B}, \mathbf{C}] \quad (1)$$

以矩阵 $\mathbf{A}$ 为例具体说明构造方法,如下所示:

$$\mathbf{A} = [a_{1,1}, a_{1,2}, a_{1,3}, \dots, a_{i,j}, \dots, a_{20,1}, a_{20,2}, a_{20,3}]^T \quad (2)$$

式中: $a_{i,j}$ 表示 A 相故障级别为 i , 第 j 个传感器的漏磁输出信号, $i = 1, 2, \dots, 20$ 分别表示外接串联电阻大小为 $i/10 \Omega$, $j = 1, 2, 3$ 分别表示 3 通道传感器输出。假设 $a_{i,j}$ 的离散信号长度为 N , 则矩阵 $\mathbf{A}$ 的特征维度为 $60N \times 1$ 。矩阵 $\mathbf{B}$ 和 $\mathbf{C}$ 的构造方式与 $\mathbf{A}$ 一致。矩阵 $\mathbf{H}$ 中由于没有故障等级,因此采用 3 通道健康信号根据式(2)的形式补充数据,使其维度和故障信号的特征维度一致。

随后,利用具有输入层、隐含层、输出层的 BPNN 对提取特征进行降维融合以实现分类。以 A 相故障信号特征为例,提取的特征 $\mathbf{A} = \mathbf{A}[i]$, $i = 1, 2, \dots, 60N$ 作为输入层,其隐含层表示为:

$$HID[j] = f\left(\sum_{i=1}^{60N-1} w_{ij} \mathbf{A}[i] - c_j\right) \quad j = 1, 2, \dots, J \quad (3)$$

式中: J 为隐含层的节点数; w_{ij} 和 c_j 分别为网络的权重和偏置; $f(\cdot)$ 为网络激励函数。

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (4)$$

网络的输出层表示如下:

$$O[r] = f\left(\sum_{j=1}^J g_{jr} HID[j] - d_r\right) \quad r = 1, 2, \dots, R \quad (5)$$

式中: R 为输出节点的数量; g_{jr} 和 d_r 分别为权重和偏置。

$HID[j]$ 和 $O[r]$ 通过训练不断迭代更新,如下所示:

$$\begin{cases} w_{ij} = w_{ij} + \eta HID[j] (1 - HID[j]) \mathbf{A}[i] \sum_{r=1}^R g_{jr} e_r \\ g_{jr} = g_{jr} + \eta HID[j] e_r \\ c_j = c_j + \eta HID[j] (1 - HID[j]) \sum_{r=1}^R g_{jr} e_r \\ d_r = d_r + e_r; i = 1, \dots, 60N; j = 1, \dots, J; r = 1, \dots, R \end{cases} \quad (6)$$

式中: η 为学习率; e_r 为预测误差。

$$e_r = T_1[r] - O[r] \quad r = 1, 2, \dots, R \quad (7)$$

式中: $T_1[r]$ 为预设的目标输出。最终,式(1)的维度为 $60N \times 4$ 的特征矩阵对应的训练目标输出为:

$$T_1[r] = [1, 2, 3, 4] \quad (8)$$

1.2 故障定量分析

通过 1.1 节提出的方法能够检测电机是否存在故障以及实现 A 相、B 相、C 相故障定位。在确定故障相之后,可以进一步定量分析故障等级,具体过程介绍如下。首先根据每一相不同故障等级的数据构造和训练另一个用于定量分析的 BPNN 模型。在该模型中,使用频域特征进行定量分析。以 A 相故障的定量分析为例,构造的频域特征如下:

$$\mathbf{F}_2 = [\mathbf{X}_1, \mathbf{X}_2, \cdots, \mathbf{X}_{20}]$$

(9)

式中: $\mathbf{X}_i$ 表示外接串联电阻大小为 $i/10\ \Omega$ 时的 3 通道输出信号的傅里叶变换。

$$\mathbf{X}_i = [Y_{i,1}, Y_{i,2}, Y_{i,3}]^T$$

(10)

式中: $Y_{i,1}[k]$ 为 1 通道漏磁信号 $y_{i,1}[n]$ 的傅里叶变换。

$$Y_{i,1}[k] = \sum_{n=0}^{M-1} y_{i,1}[n] W_M^{kn} \quad k = 0, 1, \cdots, M-1$$

(11)

其中:

$$W_M = e^{-j\frac{2\pi}{M}}$$

(12)

式中: M 为信号长度。随后,与 1.1 节的流程类似构造一个 BPNN 模型对不同故障等级的数据进行训练。输入的频域特征的维度为 $3M \times 20$,对应式(9)的 A 相训练目标输出表示为:

$$T_2[r] = [0.1, 0.2, \cdots, 2]$$

(13)

最后用均方根误差 (root-mean-square error, RMSE) 来衡量故障定量分析的精度,计算公式如下:

$$RMSE = \sqrt{\frac{\sum_{i=1}^P (T_i - R_i)^2}{P}}$$

(14)

式中: T_i 是期望输出; R_i 是实际预测输出; P 是测试样本总数。

1.3 算法流程总结

本文提出的 HRC 故障定位和定量分析的两步骤方法的算法流程如图 1 所示。通过对多通道漏磁信号的分析,可以实现 BLDCM 非侵入式、高效的 HRC 故障检测。

2 实验装置

为了验证本文提出的方法的有效性,设计了一个实验装置如图 2 所示。测试 BLDCM 通过联轴器连接一个相同型号的电机作为发电机,发电机产生的交流电经过 AC-DC 整流接入一个电子负载。BLDCM 的参数如表 1 所示,实验在匀速条件下进行测试。

HRC 故障设置如图 3 所示,图 3 中, R_a 为模拟 HRC 故障发生在 A 相时在绕组串联的电阻。本文中,外接电阻分别串联在 A、B、C 相的相线上模拟不同相的 HRC 故




图 1 算法流程
Fig. 1 Algorithm flow chart




图 2 实验装置
Fig. 2 Experimenting setup

障,电阻阻值为 $0.1 \sim 2\ \Omega$,以 $0.1\ \Omega$ 间隔递增。

表 1 BLDCM 参数

Table 1 The parameters of the BLDCM

型号	额定电压	额定功率	极对数	相数
80BL110S50	48 VDC	500 W	2	3

本文实验选用的是霍尔传感器检测电机漏磁信号,霍尔传感器具有体积小、灵敏度高、响应速度快、可靠性高等特点。3 个霍尔传感器(49E, 16 mV/mT)安装在电机的外壳表面,以电机转轴为圆心的 11 点、1 点和 3 点钟方向,分别对应 A、B、C 三相定子绕组。3 通道霍尔传感器信号通过 USB 接口的 NI 数据采集卡同步采集和记录,信号采集频率为 4 kHz 。




图 3 BLDCM 的 HRC 故障示意图

Fig. 3 Illustration of HRC fault in BLDCM




图 4 传感器安装位置示意图

Fig. 4 Illustration of the installation of Hall sensors

3 故障检测和定位实验结果

首先验证本文方法利用多通道漏磁信号分析检测和定位 HRC 故障的有效性。在健康和不同故障相状态下同步采集的 3 通道漏磁信号波形如图 5 所示。从图 5 可以看到,传感器 1 的位置与定子绕组的直线距离最近,因此传感器 1 测得的漏磁信号幅值相对较高。

图 5(b)~(d) 分别为 A、B、C 相 HRC 故障分别为 $1\ \Omega$ 时的 3 通道传感器波形。与图 5(a) 的健康状态相比可以看出,当 A 相发生 HRC 故障时,传感器 1 和 2 的漏磁信号幅值增强,传感器 3 的漏磁信号幅值变小。从图中可见,当 HRC 故障相和故障程度变化时,其信号幅值和波形都会发生变化,本文根据这一原理从信号中提取特征,结合机器学习方法实现电机 HRC 故障的检测。

随后,采用 BPNN 网络对电机 4 种状态进行分类。根据 1.1 节的方法,每一段信号长度 $N = 175$ 个采样点,一个样本包含 3 通道漏磁信号,20 组故障等级,因此样本的特征维度为 10 500,BPNN 模型将高维特征降维并输出电机状态类型(1~4)。每一类电机状态中选择 2 400 组作为训练集,800 组作为测试集。经过训练后网络的测试结果如图 6 所示。从图 6 可见,除了少许预测值偏离真实值之外,大部分预测值与真实标签值相符,分类准确率计算得到 98.75%,因此该方法可以实现




图 5 电机不同状态下的漏磁信号

Fig. 5 Leakage flux signals for different motor conditions

BLDCM 的 HRC 故障检测和故障相定位。

4 故障定量分析结果

在确定 BLDCM 的故障位置之后,进一步定量分析 HRC 故障的等级。根据 1.2 节的方法利用同一故障相不同故障等级的数据进行 BPNN 建模,为了验证本文方法的有效性和鲁棒性,通过两组实验来验证定量分析的结果。实验 1 从 20 类故障等级中随机选择 17 类作为神经网络训练集,剩下 3 类作为预测集。实验 2 从 20 类数据里随机选择 16 组作为神经网络训练集,剩下 4 类作为预测集。本文选择的训练集与预测集如表 2 所示。




图 6 HRC 故障检测和故障相定位结果
Fig. 6 Results of HRC fault detection and localization

表 2 HRC 故障定量分析数据说明

Table 2 Data description of HRC fault quantitative analysis

实验	训练集/ Ω	验证集/ Ω
1	0.1~0.5; 0.7~1.1; 1.3~1.7; 1.9~2.0	0.6; 1.2; 1.8
2	0.1~0.2; 0.4~0.6; 0.8~1.1; 1.3~1.6; 1.8~2.0	0.3; 0.7; 1.2; 1.7

实验 1 的训练样本数和预测样本数分别为 1 360 和 240,实验 2 的训练样本数和预测样本数分别为 1 280 和 320。最终 A、B、C 相的 HRC 故障定量测试结果如图 7 所示。从图中可见 HRC 故障等级的预测值在实际值上下波动,总体上预测数据和期望数据的增长趋势一致。进一步地,预测数据和期望数据之间的 RMSE 误差根据式 (14) 计算,最终结果如表 3 所示。从表格数据中可见, HRC 故障等级预测的 RMSE 较小,6 个实验的平均误差为 0.018 Ω 。以上结果表明本文提出方法能够有效实现 BLDCM 的 HRC 故障定位和定量评估。

表 3 HRC 故障定量分析误差

Table 3 RMSE of HRC fault evaluation

实验	A 相/ Ω	B 相/ Ω	C 相/ Ω
1	0.017	0.007	0.021
2	0.007	0.017	0.038

5 讨论

本文通过漏磁信号分析实现电机故障,考虑到漏磁信号是从电机内部穿过机壳被传感器采集,因此机壳材料及几何参数会影响故障诊断的精度。本文所测试的电机机壳为铝制材料,为了验证方法鲁棒性,在电机机壳和传感器之间加装厚度为 1 mm 的硅钢片以模拟钢制机




图 7 HRC 故障的定量分析结果
Fig. 7 Quantitative analysis results of HRC fault

壳,并采集相应的漏磁信号进行对比分析。传感器阵列的输出波形如图 8 所示,可见模拟钢壳的漏磁信号幅值小于铝壳的幅值,该结果说明漏磁信号穿过钢壳后进一步衰减。




图 8 健康电机在模拟钢壳条件下的漏磁信号波形
Fig. 8 Leakage flux signal of the healthy motor with simulative steel shell.

随后,对电机故障相进行定位分析,结果如图 9 所示,除了部分预测值偏离真实值之外,大部分预测值与真实标签值相符,分类准确率计算得到 87.81%,该结果小于铝壳实验的分类精度 98.75%。对 HRC 进行定量分析的结果如表 4 所示,6 个实验的平均 RMSE 误差为

0.035 Ω,该结果高于铝壳实验的误差 0.018 Ω。以上对比实验结果表明,本文方法能够对模拟钢壳的 BLDCM 进行 HRC 故障定位和定量评估,但诊断精度低于铝壳电机。考虑到本文实验中电机的功率较小,实际工厂中的大功率电机的漏磁信号强度、机壳材料和参数、环境干扰因素等都与实验室不同,因此本文方法要推广到工业应用时,还需要从传感器灵敏度、信号处理方法等方面进行进一步改进提高。




图 9 电机在模拟钢壳下的 HRC 故障检测和故障相定位结果

Fig. 9 Results of HRC fault detection and localization for the motor with simulative steel shell

表 4 电机在模拟钢壳下的 HRC 故障定量分析误差

Table 4 RMSE of HRC fault evaluation or the motor with simulative steel shell.

实验	A 相/Ω	B 相/Ω	C 相/Ω
1	0.027 8	0.060 5	0.05
2	0.036 4	0.024 8	0.011 6

6 结 论

本文提出一种结合阵列漏磁信号分析和神经网络模型的方法用于检测、定位、定量评估 BLDCM 的 HRC 故障。通过在 BLDCM 三相定子绕组背面的电机外壳上安装 3 通道的霍尔传感器阵列并同步采集漏磁信号,从漏磁信号中分别提取时域并设计 BPNN 网络实现特征降维和故障检测定位。在确定 HRC 故障相之后,从漏磁信号中提取频域特征,设计另一个 BPNN 网络实现对故障的定量分析。实验结果表明本文方法对故障检测和定位的精度为 98.75%,故障定量分析的平均 RMSE 误差为 0.018 Ω。该方法具有非侵入式测量、易于实现、精度效率高等优点,在 BLDCM 的状态监测和故障诊断上具有较高的应用前景。

参考文献

[1] 余发山,高勇. 基于 AGA 优化 RBF 神经网络的矿井通风机故障诊断[J]. 电子测量技术, 2017, 40(9):

241-245.
YU F SH, GAO Y. Fault diagnosis of mine ventilator based on AGA optimized RBF neural network [J]. Electronic Measurement Technology, 2017, 40(9) : 241-245.
[2] 谢佳琪,尤伟,沈长青,等. 基于改进卷积深度置信网络的轴承故障诊断研究[J]. 电子测量与仪器学报, 2020, 34(2) :36-43.
XIE J Q, YOU W, SHEN CH Q, et al. Research on bearing fault diagnosis based on improved convolutional deep confidence network [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34 (2) : 36-43.
[3] 王慧. 无刷直流电机定子绕组不平衡故障诊断与评估研究[D]. 合肥:安徽大学, 2020.
WANG H. Fault diagnosis and evaluation of brushless DC motor stator windings unbalance analysis[D]. Hefei: Anhui University, 2020.
[4] ZHANG J, HANG J, DING S, et al. Online diagnosis and localization of high-resistance connection in PMSM with improved fault indicator[J]. IEEE Transactions on Power Electronics, 2016, 32(5) : 3585-3594.
[5] WANG H, LU S, QIAN G, et al. A two-step strategy for online fault detection of high-resistance connection in BLDC motor [J]. IEEE Transactions on Power Electronics, 2019, 35(3) : 3043-3053.
[6] 卞皓,王晓琳,邓智泉. 基于定子电流的无刷直流电机轴承故障诊断[J]. 南京航空航天大学学报, 2020, 52(2) : 224-231.
BIAN H, WANG X L, DENG ZH Q. Bearing fault diagnosis of brushless DC motor based on stator current[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2020,52(2) : 224-231.
[7] 许爱华,闫俊泉,伍旭灿,等. 基于 VMD 和 MP 算法的旋转机械故障特征提取[J]. 国外电子测量技术, 2017, 36(8) : 11-17.
XU AI H, YAN J Q, WU X C, et al. Rotating machinery fault feature extraction based on VMD and MP algorithm [J]. Foreign Electronic Measurement Technology, 2017, 36(8) : 11-17.
[8] LIU X, LIU C, PONG P W T. Velocity measurement technique for permanent magnet synchronous motors through external stray magnetic field sensing[J]. IEEE Sensors Journal, 2018, 18(10) : 4013-4021.
[9] DA Y , SHI X D, KRISHNAMURTHY M, A new approach to fault diagnostics for permanent magnet synchronous machines using electromagnetic signature analysis[J]. IEEE Transactions on Power Electronics,

- 2013, 28(8): 4104-4112.
- [10] ROMARY R, PUSCA R, LECOINTE J P, et al. Electrical machines fault diagnosis by stray flux analysis [C]. 2013 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD), 2013: 247-256.
- [11] HU G U I, ZHANG Q I, PAN M C, et al. Simulation and analysis of leakage magnetic field of PMSM based on consol multiphysics [C]. DEStech Transactions on Computer Science and Engineering, 2018.
- [12] PASTOR-OSORIO P A, ANTONINO-DAVIU J, QUIJANO-LOPEZ A. Misalignment and rotor fault severity indicators based on the transient DWT analysis of stray flux signals [C]. 2019 IEEE Energy Conversion Congress and Exposition (ECCE), 2019: 3867-3871.
- [13] LIU X, MIAO W, XU Q, et al. Inter-turn short-circuit fault detection approach for permanent magnet synchronous machines through stray magnetic field sensing [C]. IEEE Sensors Journal, 2019, 19(18): 7884-7895.
- [14] REHMAN A U, CHEN Y, HUANG G, et al. Stator inter-turns short circuit fault detection in DFIG using empirical mode decomposition method on leakage flux [C]. 2020 International Conference on Sensing, Measurement & Data Analytics in the Era of Artificial Intelligence (ICSMD), IEEE, 2020: 184-187.
- [15] PANAGIOTOU P A, ARVANITAKIS I, LOPHITIS N, et al. Analysis of stray flux spectral components in induction machines under rotor bar breakages at various locations [C]. 2018 XIII International Conference on Electrical Machines (ICEM), IEEE, 2018: 2345-2351.
- [16] XU C, QIU C, WU X. Eccentricity faults diagnosis based on motor stray magnetic field signature analysis [C]. 2017 Chinese Automation Congress (CAC), IEEE, 2017: 5577-5582.
- [17] 鲍晓华, 吕强, 王汉丰. 基于齿部磁场分析的大型潜水电机气隙偏心故障研究[J]. 电工技术学报, 2016, 31(8): 90-95.
- BAO X H, LV Q, WANG H F. Air gap eccentric fault study of large submersible motor based on tooth magnetic field analysis [J]. Transactions of China Electrotechnical Society, 2016, 31(8): 90-95.
- [18] FEDIDA V, ROUVE L L, CHADEBEC O, et al. Stray magnetic field analysis applied to the internal unbalances diagnosis of low power single phase induction motor [C]. 2016 XXII International Conference on Electrical Machines (ICEM), IEEE, 2016: 2352-2358.
- [19] 宫文峰, 陈辉, 张美玲, 等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. 仪器仪表学报, 2020, 41(1): 195-205.
- GONG W F, CHEN H, ZHANG M L, et al. Intelligent fault diagnosis method for motor bearing based on deep learning [J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 195-205.
- [20] WANG L H, ZHAO X P, WU J X, et al. Motor fault diagnosis based on short-time Fourier transform and convolutional neural network [J]. Chinese Journal of Mechanical Engineering, 2017, 30(6): 1357-1368.

作者简介




武智超, 2019 年于哈尔滨商业大学获得学士学位, 现为安徽大学硕士研究生, 主要研究方向为电机故障诊断。

E-mail: 496968987@qq.com

Wu Zhichao received her B. Sc. degree in 2019 from Harbin University of Commerce.

Now she is M. Sc. candidate in Anhui University. Her main research interest includes motor fault diagnosis.



陆思良 (通信作者), 2010 年于中国科学技术大学获得学士学位, 2015 年于中国科学技术大学获得博士学位, 现为安徽大学副教授, 主要研究方向为机电系统创新设计与智能运维。

E-mail: lusiliang@mail.ustc.edu.cn

Lu Siliang (Corresponding author) received his B. Sc. degree in 2010 from University of Science and Technology of China, Ph. D. degree in 2015 from USTC. Now he is an Associate Professor in Anhui University. His main research interests include innovative design and intelligent maintenance of electromechanical systems.