

# 基于小波分析和神经网络的传感器故障诊断

李子凡,叶志锋,王彬

(南京航空航天大学 能源与动力学院,江苏 南京 210016)

**摘要:**结合多维度特征提取和故障识别方法,提出一种基于小波分析和神经网络的传感器故障诊断方法。运用小波变换模极大值特征提取方法和高频小波能量特征提取方法,在小波分解层数和小波类型两个不同维度对传感器信号进行特征提取,提取的特征矩阵具有序列特性。研究表明:特征矩阵相对于特征向量,对不同信号具有更明显的区分度;运用 LSTM 神经网络对传感器进行故障诊断,根据不同压力工况下的传感器特征数据集,训练针对不同压力工况的 LSTM 神经网络预测模型,提高了预测模型的泛化能力;对 LSTM 神经网络预测方法进行试验验证,基于预测模型对随机压力工况下发生的随机故障进行预测,预测准确率达到98.33%。

**关键词:**故障诊断;小波多分辨率分析;多维度特征提取;LSTM 神经网络

**中图分类号:**TP277 **文献标志码:**B **文章编号:**1671-5276(2023)04-0196-06

## Sensor Fault Diagnosis Based on Wavelet Analysis and Neural Network

LI Zifan, YE Zhifeng, WANG Bin

(College of Energy and Power Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

**Abstract:** By combining multi-dimensional feature extraction and fault identification methods, a sensor fault diagnosis method based on wavelet analysis and neural network is proposed. Wavelet transform module maximum feature extraction method and high-frequency wavelet energy feature extraction method are applied to extract sensor signal features in two different dimensions of wavelet decomposition level and wavelet type, and the extracted feature matrix has sequence characteristics. The research results show that the feature matrix has a more distinct degree of discrimination for different signals than the feature vector. The LSTM neural network is used to diagnose the fault of the sensor. According to the sensor feature data set under different pressure conditions, the LSTM neural network prediction model for different pressure conditions is trained, which improves the generalization ability of the prediction model. The LSTM neural network prediction method is tested and verified. Based on the prediction model, the random failures occurring under random stress conditions are predicted, and the prediction accuracy rate reaches 98.33%.

**Keywords:** fault diagnosis; wavelet multi-resolution analysis; multi-dimensional feature extraction; LSTM neural network

## 0 引言

传感器作为系统获取运行数据的重要部件,在现代化控制系统中有着大量的应用。控制系统能够根据传感器测量的数据来识别系统的运行状态,得出当前运行状态下的最优控制指令来调节系统的运行<sup>[1]</sup>。因此,系统的稳定运行很大程度上取决于传感器测量的数据是否准确。

在大部分工程应用中,传感器的工作环境充斥着高温、高压、粉尘、潮湿等恶劣条件,由精密器件组成的传感器长期工作在这种环境下,发生故障在所难免<sup>[2]</sup>。一旦传感器发生故障,将会使控制系统获取错误的运行数据,发出错误的控制指令,最终导致系统无法正常运行,这在某些情况下将是致命的<sup>[3-4]</sup>。因此,发展高效且实用的传感器故障诊断技术就显得尤为重要。

传统的传感器故障诊断技术包括基于定性经验的方法、基于解析模型的方法和基于数据驱动的方法。基于定性经验的方法包括专家系统、定性仿真等,需要结合经验知识进行故障诊断;基于解析模型的方法包括状态估计、

解析冗余等,需要对系统进行精确建模;基于数据驱动的方法包括信号分析、机器学习等,是直接对传感器数据进行分析来诊断故障的方法。由于传感器的精密程度越来越高,出现的故障也趋于复杂化,传统的故障诊断技术已经很难适应复杂化故障的诊断需求。随着机器学习、人工智能等方法的兴起,传感器故障诊断技术也得到了快速发展,不同的传感器故障诊断技术逐渐出现了融合的趋势。目前主流的传感器故障诊断方法是利用信号分析技术对传感器输出信号进行特征提取,然后利用机器学习、人工智能等方法,基于提取的特征数据训练分类、预测模型来进行传感器故障诊断。文献[5]基于主元分析特征抽取和 SVM 多类分类,实现了对流量传感器的故障诊断。该方法的故障诊断准确率较高,但需要训练多个 SVM 分类器,增加了故障诊断所需的时间。文献[6]以小波变换和神经网络为基础,使用正常传感器对故障传感器输出值进行预测。该方法提高了神经网络诊断和预测信号的精度,但是对带有噪声传感器信号的预测准确率会降低。文献[7]结合非线性无源观测器与 BP 神经网络,提出了一种

融合模型和数据的传感器故障诊断方法。该方法提高了故障诊断的鲁棒性和识别率,但是当建模精度无法保证时,对故障的识别率会降低。

本文提出了一种基于小波分析和神经网络的传感器故障诊断方法。首先通过多维度特征提取方法,从小波分解层数和小波类型两个不同维度对传感器信号进行特征提取,得到具有序列特性的特征矩阵;然后利用特征矩阵训练长短期记忆(LSTM)神经网络预测模型,对传感器故障进行诊断;设计传感器故障诊断系统,通过试验验证了此方法的可行性。

## 1 传感器信号特征提取



### 1.1 小波分析

函数  $f(t) \in L^2(R)$  的连续小波变换定义为

$$WT_f(a, \tau) = (f(t), \phi_{a, \tau}(t)) = \frac{1}{\sqrt{a}} \int f(t) \phi^* \left( \frac{t - \tau}{a} \right) dt \quad (1)$$

式中:  $a(a \neq 0)$  为尺度因子;  $\tau$  为平移因子。

令  $a = a_0^j, \tau = ka_0^j \tau_0$ , 代入式中, 得到离散小波变换:



(a) 正常信号

$$WT_f(j, k) = WT_f(a_0^j, ka_0^j \tau_0) = (f(t), \phi_{j, k}(t)) = \int_{-\infty}^{\infty} f(t) \phi_{j, k}^*(t) dt \quad (2)$$

式中:  $j$  为尺度指标;  $k$  为平移指标;  $WT_f(j, k)$  为离散小波系数。

通常取离散化参数  $a_0 = 2, \tau_0 = 1$ , 得到二进离散小波变换为



$$d_{j, k} = (f(t), \phi_{j, k}(t)) = \int_{-\infty}^{\infty} f(t) 2^{-\frac{j}{2}} \phi(2^{-j}t - k) dt \quad (3)$$

式中  $d_{j, k}$  为二进离散小波变换系数。

小波分析的放大倍数  $2^j$  会随着尺度指标  $j$  改变, 这就是小波分析的多分辨率特性。小波多分辨率分析通常由 Mallat 算法实现<sup>[8-9]</sup>。

### 1.2 传感器信号小波分解

对信号进行小波多分辨率分析, 可以得到不同尺度下信号对应于尺度空间的近似系数和对应于小波空间的细节系数。以周期故障为例, 运用小波多分辨率分析方法, 分别对正常信号和周期故障信号进行 6 层小波分解。传感器信号及对应的小波多分辨率分析结果如图 1 所示 (本刊黑白印刷, 相关疑问请咨询作者)。



(b) 周期故障信号

图 1 传感器信号及小波分析结果

### 1.3 信号特征提取

#### 1) 小波变换模极大值特征分析

信号的间断点也被称为奇异点, 是进行信号分析时的重点分析对象, 通常包含着信号的重要信息。信号的奇异性一般用 Lipschitz 指数  $\alpha$  来表征。

设信号  $x(t)$  在  $t_0$  及其某个领域具有以下性质:

$$x(t_0+h) - p_n(t_0+h) \leq o(h^\alpha) \quad (n < \alpha < n+1) \quad (4)$$

此式即为  $x(t)$  在  $t_0$  处的 Lipschitz 指数  $\alpha$  的定义式。

假设存在连续可微的小波函数  $\phi(t)$ , 其在无穷远处的衰减率为  $O(1/(1+t^2))$ 。若信号  $x(t)$  在区间  $[t_1, t_2]$  内的  $a$  尺度小波变换满足  $|WT_a x(t)| \leq ka^\alpha$ , 则  $x(t)$  在区间  $[t_1, t_2]$  内为均匀 Lipschitz 指数  $\alpha$ 。

对尺度因子  $a = 2^j$  的二进离散小波变换两边取对数, 得到

$$\ln |WT_{2^j} x(t)| \leq \ln k + j\alpha \quad (5)$$

式中二进离散小波变换的尺度指标  $j$  通过  $j\alpha$  项与 Lipschitz 指数  $\alpha$  联系起来。

对于不同的 Lipschitz 指数  $\alpha$ ,小波变换模极大值随着尺度指标  $j$  的变化趋势也不同。图 2 为 4 种突变信号的小波变换模极大值随尺度指标  $j$  的变化关系。其中,斜坡信号的 Lipschitz 指数  $\alpha$  大于 0;阶跃信号的 Lipschitz 指数  $\alpha$  等于 0;脉冲信号的 Lipschitz 指数  $\alpha$  小于 0。




图 2 不同信号小波变换模极大值随尺度指标  $j$  变化关系

若  $\partial WT_a x(t) / \partial t$  对任意尺度因子  $a_0$ ,在  $t_0$  处过 0 点,则称点  $(a_0, t_0)$  为信号  $x(t)$  的局部极值点。若对  $t_0$  任意邻域内  $t$ ,都有

$$|WT_a x(t)| \leq |WT_a x(t_0)| \quad (6)$$

则称点  $(a_0, t_0)$  为小波变换的模极大值点。

对传感器信号进行 6 层小波分解,得到细节系数  $d_1 \sim d_6$ 。对  $d_1 \sim d_6$  进行取模处理,得到  $d_1 \sim d_6$  的非负值,记为  $|d_1| \sim |d_6|$ 。提取  $|d_1| \sim |d_6|$  的最大值,记为  $D_1 \sim D_6$ , $D_1 \sim D_6$  即为模极大值。小波变换模极大值提取结果如图 3 所示。




图 3 小波变换模极大值随小波分解层数变化图

由图 3 可以看出,周期故障、干扰故障、偏差故障和短路故障的小波变换模极大值和正常信号相比区别较为明显。断路故障的小波变换模极大值和正常信号相比存在较小差异,但是区别不明显,用小波模极大值作为故障特征可能无法有效区分正常信号和断路故障信号。

### 2) 小波变换模极大值特征序列

以上研究中,对传感器信号进行小波变换模极大值特征提取采用的小波基函数都是 db5 小波。在分析过程中发现,db5 小波对于断路故障这一类缓变故障的分析效果不佳,对于小波分解层数维度上的故障特征区分不明显。在对断路故障信号采用其他 Daubechies 小波进行模极大

值特征提取后发现,不同 Daubechies 小波对断路故障的模极大值特征提取结果也各不相同。

以断路故障信号和正常信号为例,采用 db1~db10 小波对这两种传感器信号分别进行小波变换模极大值特征提取,得到的结果如图 4 和图 5 所示。




图 4 断路故障小波变换模极大值随小波类型变化图




图 5 正常信号小波变换模极大值随小波类型变化图

对比图 4 和图 5 可以看出,断路故障信号和正常信号的第 1~5 层模极大值结果很接近,但是第 6 层模极大值结果有明显差异。通过对比分析可以发现,当断路故障信号和正常信号采用 db3、db7 和 db10 小波进行小波分解时,第 6 层模极大值有明显差异,可以对这两种信号进行有效区分。

经过对传感器正常信号和 5 种故障信号进行小波变换模极大值特征提取,可以得到正常信号和不同故障信号基于小波分解层数和小波类型两个不同维度的模极大值特征矩阵  $f_1$ :

$$f_1 = \begin{bmatrix} D_{11} & D_{12} & \cdots & D_{1(10)} \\ D_{21} & D_{22} & \cdots & D_{2(10)} \\ \vdots & \vdots & & \vdots \\ D_{61} & D_{62} & \cdots & D_{6(10)} \end{bmatrix} \quad (7)$$

### 3) 高频小波能量特征分析

除了时域数据中包含信号的特征信息之外,各频带的能量中也包含着信号的特征信息。通过计算对应层数细节系数的平方和,可以得到不同分解层数的小波能量。高频小波能量计算如下:

$$Ed_j = \|d_j\|^2 \quad (j=1,2,\dots,N) \quad (8)$$

对传感器信号进行 6 层小波分解,得到细节系数  $d_1 \sim d_6$ 。根据式(8)计算高频小波能量,得到  $Ed_1 \sim Ed_6$ 。图 6 为传感器正常信号和周期故障信号的高频小波能量对比。

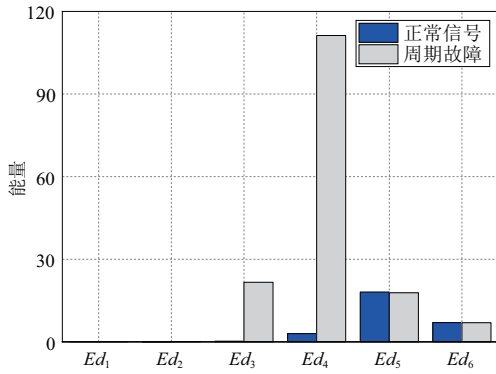


图6 正常信号和周期故障信号高频小波能量对比

分析图6可以发现,不同故障信号的高频小波能量变化各不相同,且相对于正常信号的高频小波能量都有较为明显的差异,用高频小波能量来表征不同故障的特征可以有效区分传感器正常信号和不同故障信号。

4) 高频小波能量特征序列

和小波变换模极大值特征提取一样,采用 db1~db10 小波,分别对传感器正常信号和5种故障信号进行高频小波能量特征提取,可以得到不同信号基于小波分解层数和小波类型这两个不同维度的高频小波能量特征矩阵  $f_2$ :

$$f_2 = \begin{bmatrix} Ed_{11} & Ed_{12} & \cdots & Ed_{1(10)} \\ Ed_{21} & Ed_{22} & \cdots & Ed_{2(10)} \\ \vdots & \vdots & & \vdots \\ Ed_{61} & Ed_{62} & \cdots & Ed_{6(10)} \end{bmatrix} \quad (9)$$

模极大值特征矩阵  $f_1$  和高频小波能量特征矩阵  $f_2$  共同组成传感器信号的特征矩阵  $F$ 。

## 2 LSTM 神经网络预测模型

### 2.1 LSTM 神经网络

长短期记忆(LSTM)神经网络是在RNN中加入自循环结构体和门控单元后得到的一种改进神经网络,解决了RNN的梯度消失、梯度爆炸和对序列的长期依赖问题<sup>[10]</sup>。图7为LSTM循环神经元结构。

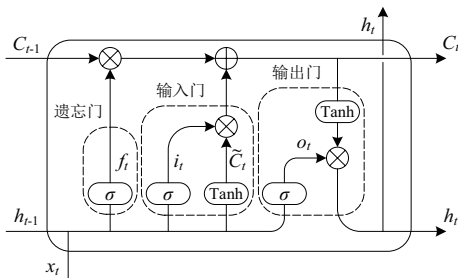


图7 LSTM 循环神经元结构

### 2.2 神经网络结构与参数设置

经过不断测试,选择具有最佳预测效果的LSTM神经网络结构。最终设计的LSTM神经网络预测模型共有6个层,包括1个输入层,4个隐含层和1个输出层。其中,4个隐含层中前2个为LSTM层,分别包含16个神经元和

32个神经元,后两个为全连接层,分别包含8个神经元和6个神经元,输出层采用Softmax层。

LSTM神经网络的主要参数包括模型运行的每次迭代训练的批量大小(batch\_size)、最大迭代次数(max\_epochs)、学习率(learning\_rate)和输入类别数(num\_classes)。具体参数设置如表1所示。

表1 LSTM神经网络参数设置

主要参数	批量大小	最大迭代次数	初始学习率	输入类别数
设定值	512	500	0.001	6

### 2.3 预测模型训练与测试

LSTM神经网络的结构以及参数设置完成后,就可以训练和测试针对不同压力工况的预测模型。训练的损失函数为交叉熵,用来度量预测值和期望值的误差。交叉熵的表达式如下所示。

$$L_{oss} = \sum_j y_j \cdot \ln(P(j|x)) \quad (10)$$

式中: $y_j$ 为第j类故障类别的标签; $P(j|x)$ 表示样本x被预测为标签 $y_j$ 的概率; $k$ 为标签个数。

预测模型训练时采用的方法是自适应矩估计(adaptive moment estimation, Adam)算法。预测模型的输入为12×10的特征矩阵F,输出为传感器信号对应的类别标签。

预测模型的训练与测试分别采集了10种不同压力工况下的传感器输出数据。压力工况类型如表2所示。

表2 压力工况类型

工况个数	工况类型
1	大气压阶跃到197.8 kPa
2	197 kPa 负阶跃到大气压
3	大气压阶跃到308.7 kPa
4	307.5 kPa 负阶跃到大气压
5	大气压阶跃到400.8 kPa
6	400 kPa 负阶跃到大气压
7	大气压阶跃到489.3 kPa
8	488.5 kPa 负阶跃到大气压
9	大气压阶跃到598.5 kPa
10	597.6 kPa 负阶跃到大气压

用测试集对预测模型进行测试,得到的分类结果和混淆矩阵如图8和图9所示。




图8 测试集分类结果




图9 测试集混淆矩阵

由图8和图9可以看出,6 000个测试样本中,有52个样本分类错误,分类错误的故障均为断路故障,分类准确率为99.13%。其中,压力工况1和压力工况2预测准确率均为100%;压力工况3和压力工况4各有2个断路故障被误分类为正常信号,预测准确率为99.67%;压力工况5和压力工况6各有3个断路故障被误分类为正常信号,预测准确率为99.5%;压力工况7和压力工况8各有7个断路故障被误分类为正常信号,4个断路故障被误分类为偏差故障,预测准确率为98.17%;压力工况9和压力工况10各有10个断路故障被误分类为正常信号,预测准确率为98.33%。

### 3 LSTM神经网络预测方法试验验证

#### 3.1 试验验证系统设计

试验验证系统的框架如图10所示。




图10 试验验证系统框架

传感器的故障注入操作是在数据采集模块采集的传感器正常输出数据上进行的,各种故障注入的具体操作过程如下。

- ①周期故障:某一时刻后在传感器正常输出信号中加入某一随机频率和幅值的周期信号。
- ②干扰故障:某一时刻后在传感器正常输出信号中加入某一随机幅值的脉冲信号,可以为单个脉冲信号,也可以为周期性脉冲信号。
- ③偏差故障:某一时刻后在传感器正常输出信号中加入某一随机常值信号。
- ④短路故障:某一时刻后在传感器正常输出信号中加入乘以增益-1后的传感器正常输出信号,使传感器信号置0。
- ⑤断路故障:某一时刻后将传感器信号维持在当前时刻的恒定值。

根据以上故障注入操作的思路,设计传感器故障注入模块,与传感器数据采集模块和传感器故障诊断模块共同组成LSTM神经网络预测方法的试验验证系统。传感器数据采集模块的硬件组成如图11所示。




图11 传感器数据采集模块硬件部分

具体的试验验证过程如下。

1)在随机压力工况下,通过数据采集模块采集压力传感器的输出数据,经过NI数据采集处理器和LabVIEW程序预处理后,通过故障注入模块注入随机故障,或者不注入故障,直接输出传感器正常信号,得到传感器随机信号数据,将随机信号数据经过特征提取后得到特征矩阵,最后将特征矩阵输入预测模型,进行分类。

2)重复步骤1)中的传感器故障诊断过程,将得到的预测结果与真实结果进行对比,验证LSTM神经网络预测方法针对随机压力工况下发生随机故障的预测效果。

#### 3.2 试验验证结果分析

用针对不同压力工况的LSTM神经网络预测模型来

预测随机压力工况下的随机故障,共进行了120次随机试验,得到的结果如图12所示。




图12 试验分类结果

由图12可以看出,在120次随机试验中,只有2个试

验分类结果与期望分类结果不符合。表3是不同信号出现次数、预测成功次数和准确率。

表3 试验验证结果

信号类型	信号出现次数	预测成功次数	准确率/%
周期故障	27	27	100
干扰故障	17	17	100
偏差故障	26	26	100
短路故障	13	13	100
断路故障	26	24	92.31
正常信号	11	11	100

从表3中可以看出,在120次随机试验中,只有2次断路故障预测错误,预测准确率为98.33%。试验验证结果说明,LSTM神经网络预测方法在传感器故障诊断中的应用效果很好。

## 4 结语

本文针对传感器信号进行小波分析的过程中,不同信号需要选择不同小波基函数的问题,结合小波分析和神经网络技术,提出一种直接对传感器输出信号进行分析的故障诊断方法。通过多维度特征提取方法,提取传感器信号的特征矩阵用于故障诊断。相比于传统的特征向量,提取的特征矩阵对不同信号的区分度更高,且得到的特征矩阵具有序列特性,能够充分发挥LSTM神经网络对序列数据预测准确率高的优点。最后对故障诊断方法进行试验验证,得到的分类准确率很高,充分证明了多维度特征提取方法和LSTM神经网络预测方法应用在传感器故障诊断中的效果很好。

(上接第195页)

## 4 结语

碳化硅MOSFET作为新型宽禁带功率半导体器件,在电力系统领域的应用前景广阔。本文针对碳化硅MOSFET存在的栅氧化层长期可靠性问题,研究了一种基于BPNN的碳化硅MOSFET栅极老化监测方法。首先结合设计搭建的硬件实验平台,采集多个健康器件和老化器件各自在变温度范围、变漏源极测量电流和变栅源极测量电压条件下的 $V_{TH}$ 和 $V_{SD}$ 数据。然后利用BPNN建立碳化硅MOSFET的栅极老化状态评估模型,将测量条件参数和对应的状态参量作为模型的输入,将器件的健康状态等级作为模型的输出,提取健康器件与老化器件样本数据间的特征差异,建立器件的外特性信息与健康状态之间的非线性对应关系。最后基于MATLAB对算法进行了验证,得到本文所研究方法的平均检测正确率在90%以上,取得了良好的评估效果。

### 参考文献:

- [1] 盛况,任娜,徐弘毅. 碳化硅功率器件技术综述与展望[J]. 中国电机工程学报,2020,40(6):1741-1753.
- [2] 钱照明,张军明,盛况. 电力电子器件及其应用的现状和发展[J]. 中国电机工程学报,2014,34(29):5149-5161.

### 参考文献:

- [1] 潘阳. 涡轴发动机控制系统传感器故障诊断与容错控制[D]. 南京:南京航空航天大学,2016.
- [2] SHARMA A B, GOLUBCHIK L, GOVINDAN R. Sensor faults[J]. ACM Transactions on Sensor Networks,2010,6(3):1-39.
- [3] KELIRIS C, POLYCARPOU M M, PARISINI T. Distributed fault diagnosis for process and sensor faults in a class of interconnected input-output nonlinear discrete-time systems[J]. International Journal of Control,2015,88(8):1472-1489.
- [4] 赵文博,叶志锋,王继强. 基于卡尔曼滤波波器组的航空发动机传感器故障诊断[J]. 机械制造与自动化,2013,42(3):14-17,53.
- [5] 彭红星,陈祥光,徐巍. PCA特征抽取与SVM多类分类在传感器故障诊断中的应用[J]. 数据采集与处理,2010,25(1):111-116.
- [6] 白杰,张正,王伟,等. 基于小波神经网络的航空发动机传感器故障诊断[J]. 机床与液压,2020,48(3):180-186.
- [7] 徐海祥,黄羽韬,余文翌. 基于无源观测器的小波神经网络故障诊断方法[J]. 华中科技大学学报(自然科学版),2020,48(4):91-96.
- [8] MALLAT S G. A theory for multiresolution signal decomposition: the wavelet representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,1989,11(7):674-693.
- [9] MALLAT S G. Multifrequency channel decompositions of images and wavelet models [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing,1989,37(12):2091-2110.
- [10] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to forget: continual prediction with LSTM [J]. Neural Computation,2000,12(10):2451-2471.

收稿日期:2022-12-20

- [3] 张开新. 高压大功率SiC固态功率控制器的仿真与设计[D]. 哈尔滨:哈尔滨工业大学,2019.
- [4] 宋海洋. 高温动态栅应力下SiC基VDMOS器件退化机理研究[D]. 南京:东南大学,2018.
- [5] SANTINI T, MORAND S, FOULADIRAD M, et al. Accelerated degradation data of SiC MOSFET for lifetime and Remaining Useful Life assessment [J]. Microelectronics Reliability,2014,54(9/10):1718-1723.
- [6] MATSUMURA M, KOBAYASHI K, MORI Y, et al. Two-component model for long-term prediction of threshold voltage shifts in SiC MOSFET under negative bias stress [J]. Japanese Journal of Applied Physics,2015,54(4S):04DP12.
- [7] YANG F, UGUR E, AKIN B. Evaluation of aging's effect on temperature-sensitive electrical parameters in SiC mosfets[J]. IEEE Transactions on Power Electronics,2020,35(6):6315-6331.
- [8] 李卫硕,孙剑,陈伟. 基于BP神经网络机器人实时避障算法[J]. 仪器仪表学报,2019,40(11):204-211.
- [9] 孟鹤立,邓二平,应晓亮,等. 基于体效应的SiC MOSFET器件栅极老化监测方法研究[J]. 中国电机工程学报,2021,41(3):1084-1093.
- [10] LOSEE P, BOLOTNIKOV A, YU L, et al. 1.2 kV class SiC MOSFETs with improved performance over wide operating temperature[C]//2014 IEEE 26th International Symposium on Power Semiconductor Devices & IC's. Waikoloa, HI, USA: IEEE,2014:297-300.

收稿日期:2021-12-23