

# 基于特征融合的提升机逆变器故障诊断

吴传龙<sup>1,2,3</sup>, 陈伟<sup>1,2,3</sup>, 刘晓文<sup>1,3</sup>, 史新国<sup>4</sup>, 刘柯<sup>4</sup>, 任晓红<sup>2</sup>

(1. 中国矿业大学 电气与动力工程学院, 江苏 徐州 221008;

2. 中国矿业大学 物联网(感知矿山)研究中心, 江苏 徐州 221008;

3. 中国矿业大学 江苏省煤矿电气与自动化工程实验室, 江苏 徐州 221008;

4. 淄博矿业集团有限责任公司 信息中心, 山东 淄博 255000)



扫码移动阅读

**摘要:** 矿井提升机逆变器故障诊断的难点在于提取表征故障的特征, 目前主要利用信号处理方法得到故障统计特征, 或通过神经网络提取故障深度特征。提升机逆变器在实际工作环境中, 受背景噪声和负载变化等因素影响, 运用单一的特征提取方法难以获得能有效表征故障的特征, 导致提升机逆变器故障诊断准确率。针对上述问题, 提出了一种基于统计特征与深度特征融合的提升机逆变器故障诊断方法。首先, 利用希尔伯特-黄变换(HHT)对逆变器输出电流信号进行优化集合经验模态分解(MEEMD), 提取故障统计特征, 同时利用压缩激励密集连接卷积网络(SE-DenseNet)提取输出电流信号的深度特征; 然后, 利用局部线性判别分析(LFDA)对 2 种特征的组合进行融合降维处理, 得到统计特征和深度特征的低维融合特征; 最后, 将低维融合特征输入极限学习机, 实现逆变器故障分类。针对提升机逆变器中单个 IGBT 开路故障进行实验, 结果表明, 该方法得到的低维融合特征比单一特征的故障表征能力更强, 有效提高了故障识别准确率。

**关键词:** 矿井提升机; 逆变器开路; 故障诊断; 特征融合; 特征降维; 希尔伯特-黄变换; 优化集合经验模态分解; 压缩激励密集连接卷积网络

中图分类号: TD633/534 文献标志码: A

## Feature fusion based fault diagnosis of hoist inverter

WU Chuanlong<sup>1,2,3</sup>, CHEN Wei<sup>1,2,3</sup>, LIU Xiaowen<sup>1,3</sup>, SHI Xinguo<sup>4</sup>, LIU Ke<sup>4</sup>, REN Xiaohong<sup>2</sup>

(1. School of Electrical and Power Engineering, China University of Mining and Technology,

Xuzhou 221008, China; 2. Internet of Things(Perception Mine) Research Center, China University of

Mining and Technology, Xuzhou 221008, China; 3. Jiangsu Province Laboratory of Mining Electric and Automation, China University of Mining and Technology, Xuzhou 221008, China;

4. Information Center, Zibo Mining Group Co., Ltd., Zibo 255000, China)

**Abstract:** The difficulty in fault diagnosis of mine hoist inverters lies in extracting the features that characterize faults. At present, signal processing methods are mainly used to obtain fault statistical features, or the fault depth features are extracted by neural networks. In the actual working environment, the hoist inverter is affected by factors such as background noise and load changes. Therefore, it is difficult to obtain features that can characterize the faults effectively by using a single feature extraction method, resulting in low fault diagnosis accuracy of the hoist inverter. In order to solve the above problems, a fault diagnosis method of hoist inverter based on the fusion of statistical features and depth

收稿日期: 2021-04-21; 修回日期: 2021-05-07; 责任编辑: 盛男。

基金项目: “十三五”国家重点研发计划资助项目(2017YFC0804400, 2017YFC0804401); 淄矿集团智慧矿山关键技术研发开放基金资助项目(2019LH08)。

作者简介: 吴传龙(1996—), 男, 安徽安庆人, 硕士研究生, 主要研究方向为故障诊断, E-mail: wuchaunlong1996@163.com。通信作者: 刘晓文(1964—), 女, 江苏张家港人, 教授, 博士, 主要研究方向为矿山物联网、电气自动化, E-mail: wb2060022@cumt.edu.cn。

引用格式: 吴传龙, 陈伟, 刘晓文, 等. 基于特征融合的提升机逆变器故障诊断[J]. 工矿自动化, 2021, 47(5): 46-51.

WU Chuanlong, CHEN Wei, LIU Xiaowen, et al. Feature fusion based fault diagnosis of hoist inverter[J]. Industry and Mine Automation, 2021, 47(5): 46-51.

features is proposed. Firstly, the Hilbert-Huang transform (HHT) is used to conduct modified ensemble empirical mode decomposition (MEEMD) of the inverter output current signal so as to obtain the fault statistical features. At the same time, the squeeze and excitation with densely connected convolutional network (SE-DenseNet) is used to extract the depth features of the output current signal. Secondly, the local fisher discriminant analysis (LFDA) is used to perform fusion and dimensionality reduction processing on the combination of the two features to obtain low-dimensional fusion features of statistical features and depth features. Finally, the low-dimensional fusion features are input to the extreme learning machine to obtain inverter fault classification. Experiments are conducted for a single IGBT open-circuit fault in the hoist inverter. The results show that the low-dimensional fusion features obtained by this method are more capable of fault characterization than single features, which improves the fault recognition accuracy effectively.

**Key words:** mine hoist; inverter open circuit; fault diagnosis; feature fusion; feature dimensionality reduction; Hilbert-Huang transform; modified ensemble empirical mode decomposition; squeeze and excitation with densely connected convolutional network

## 0 引言

矿井提升机作为提升人员和物品的大型设备,是联系井下与地面的桥梁。逆变器作为矿井提升机控制系统的关键部件,长期处于高负载运行条件下,容易发生开路故障<sup>[1]</sup>,导致输出电压畸变,影响提升机稳定运行。目前主要通过监测输出电压或电流来进行逆变器故障诊断<sup>[2-3]</sup>。Yu Yunjun等<sup>[4]</sup>利用小波变换提取逆变器输出电压信号特征,再通过支持向量机(Support Vector Machine, SVM)进行故障判别。K. H. Chao等<sup>[5]</sup>将线电流信号通过快速傅里叶变换转换为频谱,建立故障类型与频谱之间的关系。M. Baghli等<sup>[6]</sup>通过累计求和算法将统计矩与Kullback-Leibler散度相结合作为特征,采用主成分分析(Principal Component Analysis, PCA)进行故障分类。王新等<sup>[7]</sup>采用变分模态分解对电流信号进行尺度分解,构建本征模态分量(Intrinsic Mode Function, IMF)作为故障状态特征,通过SVM实现故障识别。Liu Jun等<sup>[8]</sup>对电流信号进行小波去噪,通过卷积网络提取特征,将全连接层输出结果用于故障分类。

逆变器故障诊断的难点在于提取表征故障的特征,目前主要利用信号处理方法得到故障统计特征,或通过神经网络提取故障深度特征。在提升机逆变器实际工作环境中,受背景噪声和负载变化等因素影响,运用单一的特征提取方法难以获得能有效表征故障的特征,导致故障诊断准确率低。本文提出一种基于特征融合的提升机逆变器故障诊断方法。首先,利用希尔伯特-黄变换(Hilbert-Huang Transform, HHT)提取统计特征,并通过压缩激励密集连接卷积网络(Squeeze and Excitation with

Densely Connected Convolutional Network, SE-DenseNet)提取深度特征;然后,将2种特征进行组合,利用局部线性判别分析(Local Fisher Discriminant Analysis, LFDA)对组合特征集进行融合降维;最后,将低维融合特征集输入极限学习机(Extreme Learning Machine, ELM)进行故障分类。

## 1 故障诊断流程

提升机逆变器是中点钳位型三电平逆变器<sup>[9]</sup>,由三相桥臂组成,每相有4个IGBT。本文针对单个IGBT开路故障展开研究,共12种故障类型<sup>[10]</sup>,通过采集逆变器输出三相电流信号进行故障诊断。

基于特征融合故障诊断方法包含特征提取、特征组合、融合降维和故障分类4个步骤,流程如图1所示。

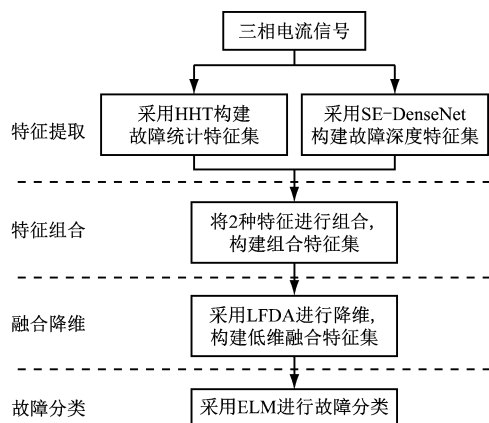


图1 基于特征融合的提升机逆变器故障诊断流程

Fig. 1 Fault diagnosis process of hoist inverter based on feature fusion

## 2 关键步骤

### 2.1 基于HHT的故障统计特征提取

HHT由2个步骤组成:①对电流信号进行经

验模态分解 (Empirical Mode Decomposition, EMD), 得到 IMF; ② 对 IMF 进行希尔伯特变换, 得到希尔伯特包络谱。计算 IMF 和希尔伯特包络谱的最大值、最小值、幅值、均值、标准差、能量、能量熵等并作为统计特征, 构建统计特征集。

由于 EMD 处理非平稳、非线性电流信号时容易出现模态混叠问题<sup>[11]</sup>, 本文使用优化集合经验模态分解 (Modified Ensemble Empirical Mode Decomposition, MEEMD) 代替 EMD。在原始信号中添加白噪声, 对信号进行模态分解, 将分解结果进行总体平均, 消除白噪声对信号分析的影响, 从而抑制模态混叠<sup>[12-13]</sup>。具体步骤如下:

(1) 将成对的白噪声信号  $b_e(t)$  和  $-b_e(t)$  ( $e = 1, 2, \dots, E, E$  为添加白噪声的对数;  $t$  为时间) 叠加到原始电流信号  $x(t)$  中, 得到包含白噪声的电流信号:

$$\begin{cases} x_e^+(t) = x(t) + a_e b_e(t) \\ x_e^-(t) = x(t) - a_e b_e(t) \end{cases} \quad (1)$$

式中  $a_e$  为添加的白噪声幅值。

(2) 对  $x_e^+(t)$  和  $x_e^-(t)$  分别进行 EMD, 得到  $x_e^+(t)$  和  $x_e^-(t)$  的第  $g$  ( $g = 1, 2, \dots, G, G$  为 IMF 总阶数) 阶 IMF  $I_{eg}^+(t)$  和  $I_{eg}^-(t)$ , 计算 IMF 平均值:

$$I'_g(t) = \frac{1}{2N} \sum_{e=1}^E [I_{eg}^+(t) + I_{eg}^-(t)] \quad (2)$$

(3) 计算  $I'_g(t)$  的排列熵, 若排列熵大于阈值, 则认为  $I'_g(t)$  出现异常, 所有异常  $I'_g(t)$  的总和为  $x'(t)$ 。原始电流信号去除  $x'(t)$  后可得正常电流信号:

$$\bar{x}(t) = x(t) - x'(t) \quad (3)$$

(4) 对  $\bar{x}(t)$  进行 EMD。

$$\bar{x}(t) = \sum_{g=1}^G I_g(t) + r(t) \quad (4)$$

式中:  $I_g(t)$  为  $\bar{x}(t)$  的第  $g$  阶 IMF;  $r(t)$  为  $\bar{x}(t)$  的残差。

### 2.2 基于 SE-DenseNet 的故障深度特征提取

DenseNet 是采用密集连接方式的卷积神经网络, 通过对卷积层输出的重复利用达到更准确的分类效果<sup>[14]</sup>。压缩激励 (Squeeze and Excitation, SE) 是典型的注意力机制, 通过修改通道的权重来实现对局部信息的关注<sup>[15-16]</sup>。本文将 SE 嵌入 DenseNet 中, 构建 SE-DenseNet, 结构如图 2 所示。

本文通过 SE-DenseNet 提取电流信号的深度特征, 构建深度特征集。电流信号经过卷积后得到特征图  $X_1 (M \times H \times C)$ ,  $M, H, C$  分别为特征图  $X_1$  的宽、高、通道数。SE 模块的作用是计算通道的权

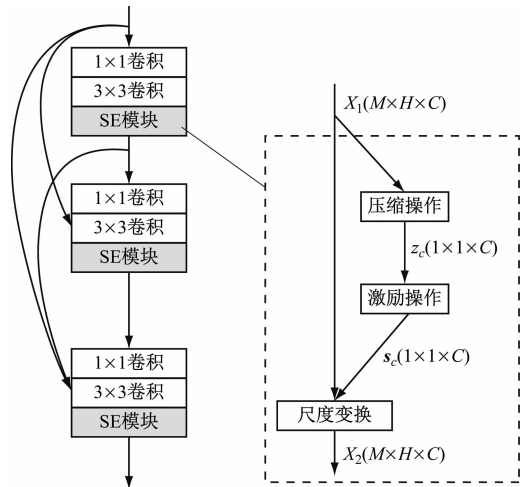


图 2 SE-DenseNet 结构

Fig. 2 SE-DenseNet structure

重矩阵, 具体步骤如下。

(1) 压缩操作。沿着宽、高方向进行求和, 将  $X_1 (M \times H \times C)$  压缩为  $z_c (1 \times 1 \times C)$ 。

$$z_c = F_{sq}(u_c(m, h)) = \frac{1}{MH} \sum_{m=1}^M \sum_{h=1}^H u_c(m, h) \quad (5)$$

式中:  $F_{sq}(\cdot)$  为压缩操作;  $u_c(m, h)$  为特征图  $X_1$  中第  $c$  ( $c = 1, 2, \dots, C$ ) 个通道 ( $m, h$ ) 处的像素点。

(2) 激励操作。对特征图的每一个通道计算权重, 得到通道权重矩阵  $s_c (1 \times 1 \times C)$ 。

$$s_c = F_{ex}(z_c) = \delta(W_1 f(W_2 z_c)) \quad (6)$$

式中:  $F_{ex}(\cdot)$  为激励操作;  $\delta(\cdot)$  为 Sigmoid 函数;  $f(\cdot)$  为 ReLU 激活函数;  $W_1$  为升维矩阵;  $W_2$  为降维矩阵。

(3) 尺度变换。将特征图  $X_1 (M \times H \times C)$  乘以通道权重矩阵  $s_c (1 \times 1 \times C)$ , 得到新的特征图  $X_2 (M \times H \times C)$ 。

$$X_2 = X_1 s_c \quad (7)$$

### 2.3 融合降维

将统计特征和深度特征进行组合, 构建组合特征集。由于组合特征集数据维度过大, 采用 LFDA 对组合特征集进行融合降维, 去除组合特征集中的冗余特征, 得到低维融合特征集。

LFDA 是一种半监督降维方法, 计算原理如下<sup>[17]</sup>。假设故障组合特征集  $\bar{\mathbf{X}} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ ,  $\mathbf{x}_i$  为第  $i$  ( $i = 1, 2, \dots, n, n$  为样本总数) 个样本,  $\mathbf{x}_i \in \mathbf{R}^d$ ,  $d$  为特征维度。计算  $\bar{\mathbf{X}}$  的类间散布矩阵  $\mathbf{S}^{(1)}$  和类内散布矩阵  $\mathbf{S}^{(2)}$ :

$$\mathbf{S}^{(1)} = \frac{1}{2} \sum_{i,j=1}^n \omega_{ij}^1 (\mathbf{x}_i - \mathbf{x}_j) (\mathbf{x}_i - \mathbf{x}_j)^T \quad (8)$$

$$\mathbf{S}^{(2)} = \frac{1}{2} \sum_{i,j=1}^n \omega_{ij}^2 (\mathbf{x}_i - \mathbf{x}_j) (\mathbf{x}_i - \mathbf{x}_j)^T \quad (9)$$

$$\omega_{ij}^l = \begin{cases} A_{ij} (1/n - 1/n_i) & y_i = y_j = l \\ 1/n & y_i \neq y_j \end{cases} \quad (10)$$

$$\omega_{ij}^2 = \begin{cases} A_{ij}/n_l & y_i = y_j = l \\ 0 & y_i \neq y_j \end{cases} \quad (11)$$

$$A_{ij} = \exp\left(-\frac{\|x_i - x_j\|^2}{\varepsilon^2}\right) \quad (12)$$

式中: $A_{ij}$ 为同类故障下 $\bar{\mathcal{X}}$ 中第 $i, j$ 个样本 $x_i$ 和 $x_j$ 之间的亲和度, $x_i$ 和 $x_j$ 越相近, $A_{ij}$ 越大; $n_l$ 为 $\bar{\mathcal{X}}$ 中第 $l(l=1, 2, \dots, p, p$ 为 $\bar{\mathcal{X}}$ 中故障类型总数)类故障的样本数; $y_i, y_j$ 为 $x_i, x_j$ 的故障类别标签; $\varepsilon$ 为常数。

在计算 $S^{(1)}$ 时,当 $x_i$ 和 $x_j$ 为相同故障类型, $\omega_{ij}^1$ 为负值,当 $x_i$ 和 $x_j$ 为不同故障类型, $\omega_{ij}^1$ 为正值,以此来实现不同故障类型的样本彼此分开。在计算 $S^{(2)}$ 时,当 $x_i$ 和 $x_j$ 为不同故障类型, $\omega_{ij}^2$ 为零,以此来实现相同故障类型的样本彼此靠近。

利用 LFDA 降维后得到低维融合特征集 $\bar{\mathcal{X}}'$ 。

$$\bar{\mathcal{X}}' = T_{\text{LFDA}} \bar{\mathcal{X}} \quad (13)$$

$$T_{\text{LFDA}} = \operatorname{argmax}[\operatorname{tr}((T^T S^{(2)} T)^{-1} T^T S^{(1)} T)] \quad (14)$$

式中: $T_{\text{LFDA}}$ 为 LFDA 的变换矩阵; $T$ 为变换矩阵。

### 3 实验验证

搭建逆变器电流信号采集实验平台,如图3所示。使用电阻和电感串联模拟负载变化,设置4种负载:0.5  $\Omega$ 和1.5 mH、0.5  $\Omega$ 和2 mH、1  $\Omega$ 和1.5 mH、1  $\Omega$ 和2 mH。逆变器正常状态加上12种单个IGBT开路故障共13种状态,每种状态下采集1 890个样本,共得到 $4 \times 13 \times 1\ 890$ 个样本,构建数据集Case1。相同条件下在Matlab仿真得到数据集Case2。



图3 逆变器电流信号采集实验平台

Fig. 3 Experiment platform of inverter current signal acquisition

为验证组合特征集的故障表征能力,在相同的数据集下,采用相同的分类器,选择不同的特征集来进行对比(ELM模型不提取故障特征直接诊断,HHT-ELM模型利用统计特征集进行诊断,SE-DenseNet-ELM模型利用深度特征集进行诊断,

FC-ELM模型利用组合特征集进行诊断),结果见表1。可看出FC-ELM模型的故障识别准确率最高;Case1数据集上的故障识别准确率大于Case2数据集,这是由于实验平台环境复杂,存在噪声影响。

表1 不同特征集下故障诊断结果

Table 1 Fault diagnosis results under different feature sets


模型	识别准确率/%	
	Case1	Case2
ELM	80.63	81.44
HHT-ELM	83.20	84.13
SE-DenseNet-ELM	84.50	85.27
FC-ELM	88.76	93.38

为验证 LFDA 的优越性,在相同的组合特征集下,采用相同的分类器,选择不同的降维方法来进行对比(FC-LFDA-ELM模型采用 LFDA 进行降维,FC-PCA-ELM模型采用 PCA 进行降维),结果见表2。可看出相比于FC-ELM模型,采用降维后的2种模型的故障识别准确率均得到提高,这是由于FC-ELM模型只是对2种特征进行组合,没有实现真正的融合;故障识别准确率随着低维融合特征集维度的增加先上升后下降,当低维融合特征集维度为50时,故障识别准确率最高;在相同低维融合特征集维度下,FC-LFDA-ELM模型准确率比FC-PCA-ELM模型高。在Case2数据集下通过增加网络层数来对比2种模型的稳定性,结果如图4所示。可看出FC-LFDA-ELM模型的故障识别准确率迅速增大后保持稳定,而FC-PCA-ELM模型的故障识别准确率会出现波动。在准确率和稳定性上,FC-LFDA-ELM模型比FC-PCA-ELM模型表现更好。

表2 不同降维方法下故障诊断结果

Table 2 Fault diagnosis results under different dimensionality reduction methods

低维融合特征集维度	Case1 识别准确率/%		Case2 识别准确率/%	
	FC-LFDA-ELM	FC-PCA-ELM	FC-LFDA-ELM	FC-PCA-ELM
20	86.50	85.50	92.45	91.25
30	90.93	87.53	93.56	92.86
40	94.50	88.50	96.72	93.52
50	99.18	95.98	99.61	98.45
60	95.70	92.56	96.95	93.75
70	93.27	85.77	95.53	90.56
80	88.82	83.72	90.23	85.23



(a) FC-LFDA-ELM (b) FC-PCA-ELM

图 4 不同降维方法下故障识别准确率

Fig. 4 Fault recognition accuracy under different dimensionality reduction methods

为进一步验证 LFDA 的降维能力,通过可视化方法展示统计特征集、深度特征集及分别经 LFDA 和 PCA 降维后的低维融合特征集,如图 5 所示。可看出在统计特征集和深度特征集中,相同故障类型的样本严重分散,不同故障类型的样本交叠在一起,交叠的样本容易出现故障分类错误;在经 LFDA 降维后的低维融合特征集中,相同故障类型的样本聚集,不同故障类型的样本分散,降低了故障分类难度;在经 PCA 降维后的低维融合特征集中,相同故障类型的样本聚集,但不同故障类型的样本存在交叠,不利于故障诊断。

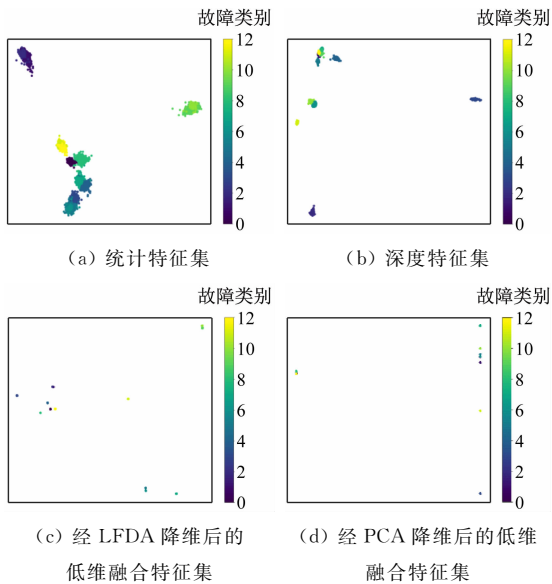


图 5 特征集样本分布

Fig. 5 Sample distribution of feature sets

### 4 结语

提出了一种基于特征融合的提升机逆变器故障诊断方法。将逆变器输出三相电流信号经过 HHT 得到的统计特征和通过 SE-DenseNet 获得的深度特征进行组合,再利用 LFDA 对组合特征进行融合降维,得到更容易分类的低维融合特征。实验结果表明,该方法得到的低维融合特征比单一特征的故障表征能力更强,有效提高了故障识别准确率。本文只针对提升机逆变器中单个 IGBT 开路故障进行

了研究,但实际条件下,提升机中逆变器和电动机相互耦合,容易出现复合故障,下一步将针对逆变器和电动机复合故障诊断进行研究。

### 参考文献 (References):

[1] 方祥. 基于三电平逆变器的矿井提升机矢量控制系统[D]. 淮南:安徽理工大学,2009.  
FANG Xiang. The vector control system applied to mine hoist based on three-level inverter[D]. Huainan: Anhui University of Science and Technology,2009.

[2] 张 Jianjian. 基于电流法和电压法的三相逆变器开路故障诊断方法研究[D]. 成都:电子科技大学,2019.  
ZHANG Jianjian. Research on open-switch fault diagnosis for three-phase voltage-source inverters based on currents and voltages [D]. Chengdu: University of Electronic Science and Technology of China,2019.

[3] 崔博文,任章. 基于傅里叶变换和神经网络的逆变器故障检测与诊断[J]. 电工技术学报,2006,21(7): 37-43.  
CUI Bowen,REN Zhang. Fault detection and isolation of inverter based on FFT and neural network[J]. Transactions of China Electrotechnical Society,2006, 21(7):37-43.

[4] YU Yunjun,PEI Shilei. Open-circuit fault diagnosis of neutral point clamped three-level inverter based on sparse representation[J]. IEEE Access,2018,12(99): 73499-73508.

[5] CHAO K H,KE C H. Fault diagnosis and tolerant control of three-level neutral-point clamped inverters in motor drives [J]. Energies, 2020, 13 (23): 6302-6327.

[6] BAGHLI M,DELPHA C,DIALLO D, et al. Three-level NPC inverter incipient fault detection and classification using output current statistical analysis [J]. Energies,2019,12(7):1372-1386.

[7] 王新,段文静,庞曦. 基于高分辨 VMD 和 SVM 的三电平变频器开路故障诊断[J]. 制造业自动化,2020, 42(11):38-43.  
WANG Xin,DUAN Wenjing,PANG Xi. Open circuit fault diagnosis of three-level inverter based on high resolution VMD and SVM [J]. Manufacturing Automation,2020,42(11):38-43.

[8] LIU Jun,WANG Junnian,YU Wenxin, et al. Open-circuit fault diagnosis of traction inverter based on improved convolutional neural network[J]. Journal of Physics Conference Series,2020,1633:12099-12109.

[9] 任晓红,万红,俞啸,等. 基于 Park 变换的三电平逆变器开路故障诊断[J]. 工矿自动化,2020,46(5): 82-86.

- REN Xiaohong, WAN Hong, YU Xiao, et al. Open-circuit fault diagnosis of three-level inverter based on Park transformation [J]. Industry and Mine Automation, 2020, 46(5): 82-86.
- [10] 王建亮. 全控双馈变频调速系统在矿井提升机中的应用[J]. 工矿自动化, 2009, 35(6): 97-99.
- WANG Jianliang. Application of double-fed frequency conversion speed-regulation system with full control in mine hoist [J]. Industry and Mine Automation, 2009, 35(6): 97-99.
- [11] 姜里运. 应用于矿井提升机的大功率三电平 SVPWM 逆变器变频调速系统研究 [D]. 沈阳: 东北大学, 2010.
- JIANG Liyun. Research on three-level SVPWM inverter frequency control system for mine hoist [D]. Shenyang: Northeastern University, 2010.
- [12] 郑近德, 程军圣, 杨宇. 改进的 EEMD 算法及其应用研究 [J]. 振动与冲击, 2013, 32(21): 21-26.
- ZHENG Jinde, CHENG Junsheng, YANG Yu. Modified EEMD algorithm and its applications [J]. Journal of Vibration and Shock, 2013, 32(21): 21-26.
- [13] 盖宏宇, 高军伟, 种兴静. 基于 MEEMD 和 GRNN 的轨道交通列车辅助逆变器故障诊断 [J]. 制造业自动化, 2019, 41(11): 11-14.
- GAI Hongyu, GAO Junwei, CHONG Xingjing. Fault diagnosis of train auxiliary inverter based on MEEMD and GRNN [J]. Manufacturing Automation, 2019, 41(11): 11-14.
- [14] 杨吕祥, 胡燕. 基于多层次注意力机制一维 DenseNet 音频事件检测 [J]. 计算机应用研究, 2020, 37(6): 1642-1646.
- YANG Lyuxiang, HU Yan. Sound event detection based on 1D DenseNet with multi-level attention [J]. Application Research of Computers, 2020, 37(6): 1642-1646.
- [15] HUANG Zheng, ZHAO Yiwen, LI Xin, et al. Application of innovative image processing methods and AdaBound-SE-DenseNet to optimize the diagnosis performance of meningiomas and gliomas [J]. Biomedical Signal Processing and Control, 2020, 59: 101-116.
- [16] ZHOU Qing, ZHOU Zhiyong, CHEN Chunmiao, et al. Grading of hepatocellular carcinoma using 3D SE-DenseNet in dynamic enhanced MR images [J]. Computers in Biology and Medicine, 2019, 107: 47-57.
- [17] ZHONG Kai, HAN Min, QIU Tie, et al. Fault diagnosis of complex processes using sparse kernel local fisher discriminant analysis [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(5): 1581-1591.