

引用格式:黄敬尧,程煜,李雅恬.基于 DCM-PCA 和 GA-BP 的逆变器故障诊断[J].电力科学与技术学报,2024,39(1):260-271.

Citation: HUANG Jingyao, CHENG Yu, LI Yatian. Fault diagnosis of inverter based on DCM-PCA and GA-BP neural network[J]. Journal of Electric Power Science and Technology, 2024, 39(1): 260-271.

## 基于 DCM-PCA 和 GA-BP 的逆变器故障诊断

黄敬尧,程煜,李雅恬

(三峡大学电气与新能源学院,湖北宜昌 443000)

**摘要:**针对光伏并网三相电压型逆变器开关管的开路故障,提出深度级联模型(deep cascade mode, DCM)-主成分分析(principal component analysis, PCA)与遗传算法(genetic algorithm, GA)优化的 BP 神经网络结合的故障诊断方法。首先对逆变器的开路故障进行分析和仿真,确定三相电流作为故障信号,选择 22 类故障状态作为诊断对象,通过以稀疏表示分类(sparse representation based classifier, SRC)为基本操作单元的深度级联模型提取故障特征,DCM 根据层次学习特性将故障特征分层,再由 SRC 部分得到不同故障的编码系数,并采用 t 分布-随机近邻嵌入(t-distributed stochastic neighbor embedding, t-SNE)方法验证了 DCM 具有较好的特征提取能力,通过 PCA 降低故障特征的冗余度、保留有价值的主成分提高网络映射能力,最后将故障特征向量作为 GA-BP 神经网络的输入信号实现对故障的诊断识别。通过仿真实验得到该方法的故障诊断准确率为 95.64%,与 DCM-PCA-BP、FFT-GA-BP 和 FFT-BP 相比准确率分别提高 8.71%、20.64%、51.70%,表明该方法有更好的故障特征提取能力和故障诊断效果。

**关键词:**逆变器;故障诊断;神经网络;深度级联模型;故障特征

**DOI:** 10.19781/j.issn.1673-9140.2024.01.027 **中图分类号:** TM464 **文章编号:** 1673-9140(2024)01-0260-12

### Fault diagnosis of inverter based on DCM-PCA and GA-BP neural network

HUANG Jingyao, CHENG Yu, LI Yatian

(College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443000, China)

**Abstract:** Aiming at the open-circuit fault of the photovoltaic grid-connected three-phase voltage-type inverter, a fault diagnosis method combining deep cascade mode-principal component analysis (DCM-PCA) and genetic algorithm-optimized BP (GA-BP) neural network is proposed. Firstly, the open-circuit fault of the inverter is analyzed and simulated, the three-phase current is determined as the fault signal, and 22 types of fault states are selected as the diagnosis objects, and the fault features are extracted through the deep cascade model with sparse representation classification as the basic operation unit, the DCM fault features are stratified based on the characteristics of hierarchical learning. The t-SNE method is used to verify that DCM has good feature extraction ability. PCA is used to reduce the redundancy of fault features, retain valuable principal components to improve the network mapping ability. Finally, the fault feature vector is used as the input of the GA-BP neural network to identify the fault and output the diagnosis result. The fault diagnosis accuracy of this method is 95.64% through simulation and experiments, compared with the DCM-PCA-BP, FFT-GA-BP and FFT-BP, the accuracy is increased by 8.71%, 20.64% and 51.70% respectively, indicating that the proposed method has better fault feature extraction capability and better fault diagnosis performance.

**Key words:** inverter; fault diagnosis; neural network; deep cascade mode; fault characteristics

随着科学技术的发展,电力电子器件越来越受到重视。逆变器被广泛应用于光电、风电、电动汽

车、飞机等重要的工业领域。在光伏发电系统中,并网逆变器作为其中的一个重要组成部分,关注其

收稿日期:2022-11-25;修回日期:2023-05-10

基金项目:湖北省自然科学基金(2019CFB331)

通信作者:程煜(1998—),女,硕士研究生,主要从事电力电子的故障诊断方面的研究;E-mail: 1670914197@qq.com

工作的可靠性十分必要。在电机调速系统中,有82.5%的故障由开关管故障引起。在光伏电站运行的常见故障中,逆变器故障占比60%。而在电力电子设备的常见故障中,开关管故障占比约38%<sup>[1]</sup>。电力电子变换器的故障可能会影响整个系统的正常运行,从而造成经济损失。及时发现并识别故障能够有效避免不利影响。并网逆变器故障会严重影响光伏并网系统的安全稳定运行。功率管的短路故障具有速度快、瞬时影响大等特点。通常在发生短路故障时,硬件保护会进行动作封锁以保护系统。而开路故障的故障时间较长、瞬时影响较小,但故障会引起波形畸变。若不及时发现,会影响系统的电能质量和效率等<sup>[1-2]</sup>。因此,及时发现功率管的开路故障并进行故障定位对光伏系统的安全稳定运行是非常必要的。

逆变器的故障诊断方法可以分为基于模型的方法、基于信号的方法和基于知识的方法。基于模型的方法很难建立精确的故障模型,而基于知识的方法包括专家系统法和神经网络法等。专家系统法需要有足够的专家知识,而神经网络等智能分类算法能够基于数据建立映射关系并进行非线性拟合,具有简单易行、应用广泛、适用性强等优点<sup>[1]</sup>。在具体方法方面,文献[3]提取出三相四桥臂逆变器输出三相电压的直流分量、前10次谐波分量、中性线上的电流直流分量以及开关频率处的谐波分量作为故障特征,通过误差反传的神经网络(back propagation neural networks, BPNN)对满载、空载和2/3负载3种情况进行开关管的故障诊断。该方法通过网络输出结果逼近目标值表明具有很好的诊断能力,但未对结果进行数据化和可视化处理。文献[4]通过BP神经网络结合逻辑判断对变频器的开关管故障进行诊断,但对位于相同桥臂的同一类型开关管故障神经网络无法有效判别,采集电压电流数据结合逻辑判断实现所有类别的故障诊断,但采集电压数据需要额外传感器,且逻辑判断较复杂。文献[5]以三电平逆变器的相电压为研究对象,通过快速傅立叶变换(fast Fourier transformation, FFT)提取故障特征,验证了BP神经网络进行故障诊断的可行性,但仅针对双管故障进行了诊断。文献[4-5]均未对神经网络进行优化处理,且FFT和小波分析等传统数据处理方法分别存在特征缺失和小波基函数选取较为困难的问题<sup>[1]</sup>。文献[6]针对整流器的开关管故障采用优化的径向基函数神经网络(radical basis function, RBF)与概率神

经网络(probabilistic neural network, PNN)相结合的诊断方法,诊断正确率为91.6%,相较单一的神经网络提高了诊断准确率,但分级诊断增加了网络的复杂性。文献[7]针对掘进机减速器的故障,采用遗传算法(genetic algorithm, GA)优化BP神经网络将故障诊断准确率提高了21.13%。文献[8]提出一种深度级联模型用于人脸图片识别,针对扩展的Yale B数据库小样本,其识别准确率超过98%,验证了其针对小规模数据样本具有很好的学习能力和识别效果,如今深度学习发展迅速但在逆变器的故障诊断中应用仍不广泛。文献[9]提取三相电流的均值和方差作为故障特征,通过支持向量机(support vector machine, SVM)实现对三相逆变器IGBT的开路故障诊断。文献[10]针对多电平换流器的开路故障诊断,提取电流数据特征结合混合支持向量机实现故障识别。文献[11-12]针对逆变器的开路故障,通过卷积神经网络对故障特征进行深度学习并进行故障识别,但所需故障样本数量巨大。

针对电压型并网逆变器的双管故障,本文采用深度级联模型(deep cascade mode, DCM)实现故障信号的特征提取。通过DCM中的稀疏表示分类(sparse representation based classifier, SRC)处理信号,得到编码向量后经最大池化处理得到特征向量。接着通过主成分分析(principal component analysis, PCA)降低DCM提取的故障特征维度,保留有价值的主成分,以提高网络映射能力。针对BP神经网络易陷入局部极小值的问题,采用遗传算法进行优化。最后,结合DCM-PCA与GA-BP网络实现开关管的开路故障诊断。与文献[3-4]相比,该方法对BP网络进行了优化,对结果进行了数据化和可视化处理,验证了GA-BP相较BP网络有更好的诊断效果,提高了故障诊断准确率。与文献[5]相比,该方法采用DCM提取故障特征,相较FFT特征提取方法其特征分布效果更好且能够提高神经网络的准确率。该研究首次将文献[8]中应用于人脸识别的DCM应用于开关管的故障诊断,并验证了其可行性与有效性。

## 1 逆变器的开路故障分析

三相电压型并网逆变器的拓扑结构如图1所示,  $U_{dc}$  为直流侧的输入电压,  $V_1 \sim V_6$  为逆变器的功率管IGBT,  $V_1$ 、 $V_3$ 、 $V_5$ 和 $V_4$ 、 $V_6$ 、 $V_2$ 分别组成逆变器的上半桥和下半桥,  $VD_1 \sim VD_6$  为各个功率管的反并联二极管,每一相桥臂上的2个功率管交替导通

工作,  $L$  为交流侧的滤波电感,  $e_a$ 、 $e_b$ 、 $e_c$  为交流侧电网相电压。

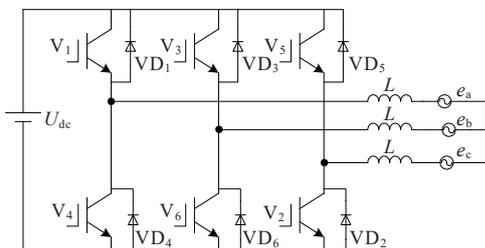


图1 三相电压型桥式逆变器拓扑

Figure 1 The topology of three-phase voltage type bridge inverter

在三相电压型逆变器中, IGBT 开关管的开路故障一般由脉冲信号丢失以及热效应引起的器件破损、接线断开导致。当开关管发生短路故障时, 系统硬件保护动作使其发展为开路故障<sup>[13]</sup>。同时, 由于反并联二极管的存在, 当开关管发生开路故障时系统仍可保持一小段时间的正常运行, 但任其发展会对系统其他器件产生损害, 也会影响系统的电能质量<sup>[14]</sup>。考虑到三管及以上的故障情况发生概率较小<sup>[15]</sup>, 所以只对单管及双管的开路故障进行分析。

在 MATLAB 中搭建并网逆变器的仿真模型, 采用电流控制和 SVPWM 调制使得系统以单位功率因数向电网输入恒定功率的电能<sup>[16]</sup>。考虑到仿真参数的真实性和有效性, 结合工程实际和实验条件设置交流侧电动势为 220 V, 电流为 40 A, 则额定功率为 26 kW, 假设电压有  $\pm 15\%$  的波动, 则交流侧线电压幅值为 456.79~618.01 V, 对应的直流电压  $U_{dc}$  最小应为 618.01 V, 考虑裕度将直流侧电压  $U_{dc}$  设为 700 V, 控制模块中的开关频率设置为 20 kHz, 则有:

$$L \leq \frac{3E_m^2 \sin^2 \varphi + 3E_m \sin \varphi \sqrt{E_m^2 \sin^2 \varphi + M^2 U_{dc}^2 - E_m^2}}{3E_m I_m \sin \varphi \cdot 2\pi f} \quad (1)$$

式中,  $E_m$  为交流相电压峰值;  $I_m$  为电流峰值;  $\varphi$  为功率因素角;  $U_{dc}$  为直流侧电压;  $f$  为电网频率 50 Hz;  $M = \sqrt{3}/3$  为 SVPWM 调制的电压最大利用率。求得  $L \leq 5.3$  mH, 故取电感值为 5 mH。考虑安全裕度选择型号为 APT46GA90JD40 的 IGBT, 其耐压值为 900 V, 最大导通电流为 87 A; 选择型号为 195G75 的电感, 其最大额定电流为 75 A。系统仿真参数如表 1 所示。

由于三相桥臂对称性, 以 A 相桥臂为例结合故障情况下的仿真波形对逆变器的开路故障进行分析。如图 2 所示, 将 A 相电流分为正、负 2 个方向, 在正常情况下, 当  $I_A > 0$  时, 电流由两部分组成:  $V_1$  导通、 $V_4$  关断时,  $I_A$  通过  $V_1$  正向流通;  $V_1$  关断、 $V_4$  导通时, 电流  $I_A$  通过  $V_4$  的反并联二极管  $VD_4$  流向电网实现正向续流。同理, 当  $I_A < 0$  时, 电流亦由 2 个路径构成:  $V_1$  导通  $V_4$  关断时,  $I_A$  通过二极管  $VD_1$  实现反向续流;  $V_1$  关断  $V_4$  导通时, 电流  $I_A$  则通过  $V_4$  反向流通。

表 1 并网逆变器系统的仿真参数

Table 1 Simulation parameters of grid-connected inverter systems

仿真参数	单位	数值
直流侧电压	V	700
交流侧电压	V	380
额定功率	kW	26
滤波电感	H	5e-3
电网频率	Hz	50
控制器开关频率	kHz	20
IGBT 型号		APT46GA90JD40
电感型号		195G75

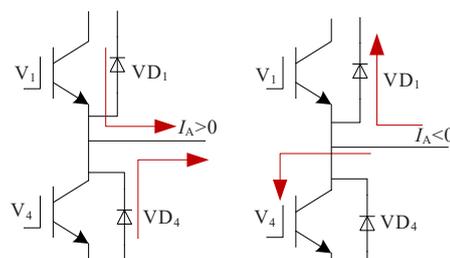


图2 A相桥臂电流分析

Figure 2 A-phase bridge current analysis

当上半桥开关管  $V_1$  发生开路故障,  $I_A > 0$  时, A 相电流失去其主要的正向流通过径, 而  $I_A < 0$  时仍可通过二极管实现续流; 同理当开关管  $V_4$  发生开路故障,  $I_A > 0$  时, A 相电流通过  $VD_4$  正向续流, 而  $I_A < 0$  时则失去其主要反向流通过径。设置故障发生时刻为 0.08 s, 仿真得到的三相电流故障波形如图 3(a) 所示, IGBT<sub>1</sub> 开路时 A 相电流失去正半波并造成电流畸变, 与理论分析一致。当同相桥上的开关管开路时, 由上述分析可知, 该相电流会失去正、反向流通过径, 在波形上表现为失去正、负半波, 经仿真验证如图 3(b) 所示, 且同时也会引起另外两相的波形畸变; 而当异相桥上的 2 个开关管同时发生故障时, 除了故障相波形发生变化, 第三相的电流波形也发生了缺失, 如图 3(c) 所示, 三相电流均发生一定畸变。

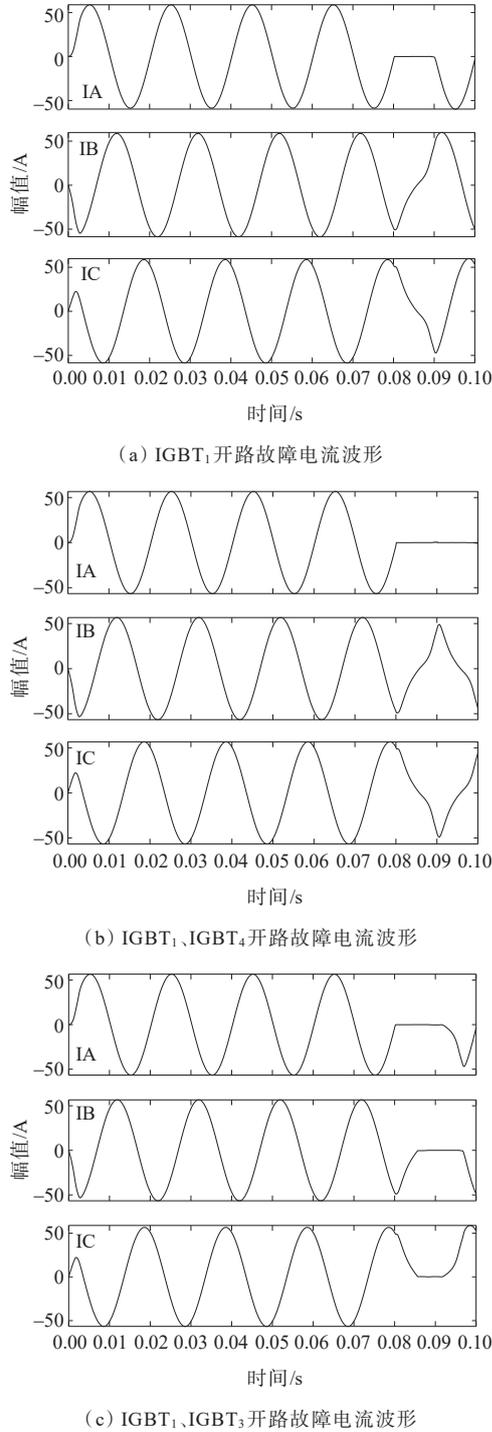


图3 开路故障电流波形仿真波形

Figure 3 Simulation waveform of open-circuit fault current waveform

通过上述分析可知,不同故障会引起三相电流的变化,故将三相电流作为故障信号并提取其中的故障特征以实现故障诊断。

## 2 深度级联模型和PCA算法

### 2.1 基于DCM的特征提取

深度级联模型(deep cascade model,DCM)是将

深度学习的深度概念与传统表示模型的编码框架稀疏表示分类(sparse representation based classifier, SRC)结合,利用深度学习中的层次学习、多层连接和非线性特征转换的优秀特性,以SRC作为DCM的主要操作单元,实现信号特征的提取<sup>[8]</sup>。

SRC是稀疏表示分类模型,也可用作稀疏编码(sparse coding),通过求解稀疏编码得到稀疏系数矩阵,在总类数据集中通过编码系数表示原始信号。利用深度学习中的层次学习将故障信号分为3层,第1层是原始信号,第2层将原始信号平分为4个区域,第3层在第2层的基础上平分为16个区域,定义 $X$ 为训练样本, $y$ 为测试样本, $H_y^l$ 则为第1层的第 $i$ 个子区域,当 $l=1$ 时 $i=1$ , $l=2$ 时 $i=1,2,3,4$ , $l=3$ 时 $i=1,2,\dots,16$ ,稀疏编码的表达式为

$$\min_{w_y^l} \|H_y^l - H_X^l w_y^l\|_2^2 + \lambda \|w_y^l\|_1 \quad (2)$$

式中, $\lambda$ 为正则化系数; $w$ 为编码系数; $\|\cdot\|_1$ 为L1范数; $\|\cdot\|_2$ 为L2范数。

交替方向乘子法(alternating direction method of multipliers)可以在多个变量之间进行交替优化迭代,通过ADMM算法对上述系数表示问题进行求解,结合增广拉格朗日乘数法得到式(2)的增广拉格朗日函数表达式为

$$L_u(w_y^l, z_y^l, \Lambda_y^l) = \min_{w_y^l, z_y^l, \Lambda_y^l} \|H_y^l - H_X^l w_y^l\|_2^2 + \lambda \|z_y^l\|_1 + \langle \Lambda_y^l, w_y^l - z_y^l \rangle + \frac{u}{2} \|w_y^l - z_y^l\|_2^2 \quad (3)$$

其中, $u$ 为常数, $\Lambda$ 为拉格朗日乘子, $\langle P, Q \rangle = \text{tr}(P^T Q)$ 。

设变量 $z_y^l = w_y^l$ ,进行ADMM迭代。

设 $z_y^l = z_y^{l(k)}$ , $\Lambda_y^l = \Lambda_y^{l(k)}$ ,更新 $w_y^l$ 得:

$$w_y^{l(k+1)} = \arg \min_{w_y^l} L_u(w_y^l, z_y^l, \Lambda_y^l) \quad (4)$$

设 $w_y^l = w_y^{l(k+1)}$ , $\Lambda_y^l = \Lambda_y^{l(k)}$ ,更新 $z_y^l$ 得:

$$z_y^{l(k+1)} = \arg \min_{z_y^l} L_u(w_y^l, z_y^l, \Lambda_y^l) \quad (5)$$

设 $w_y^l = w_y^{l(k+1)}$ , $z_y^l = z_y^{l(k+1)}$ ,更新 $\Lambda_y^l$ 得:

$$\Lambda_y^{l(k+1)} = \Lambda_y^{l(k)} + u(w_y^{l(k+1)} - z_y^{l(k+1)}) \quad (6)$$

基于式(3)、(4)可以表示为

$$w_y^{l(k+1)} = \arg \min_{w_y^l} (\|H_y^l - H_X^l w_y^l\|_2^2 + \langle \Lambda_y^l, w_y^l - z_y^l \rangle + \frac{u}{2} \|w_y^l - z_y^l\|_2^2) \quad (7)$$

通过求解上述过程得到编码系数,再生成softmax向量,为了降低第2层和第3层的维数,防止过拟合,采用最大池化函数对softmax向量进行处理,

将提取到的3层特征结合得到最终的特征,其结构如图4所示。

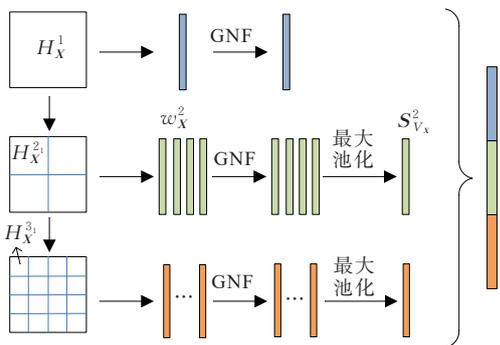


图4 DCM中softmax向量生成过程

Figure 4 Softmax vector generation process in DCM

通过 softmax 函数得到 softmax 向量:

$$S_v = \left[ \frac{e^{-r_1}}{\sum_{c=1}^C e^{-r_c}}, \frac{e^{-r_2}}{\sum_{c=1}^C e^{-r_c}}, \dots, \frac{e^{-r_c}}{\sum_{c=1}^C e^{-r_c}} \right]^T \quad (8)$$

式中,  $C$  为故障总类别;  $r_c$  为各类别的表示误差。

如图4所示,在第1层中得到1个 softmax 向量  $S_{V_x}^1$  用以代替原始数据  $H_X^1$ , 而第2层有4个区域即有4个  $S_{V_x}^2$ , 第3层有16个  $S_{V_x}^3$ , 对第2、3层多个 softmax 向量采用最大池化函数(max-pooling function)处理, 求取每个矩阵窗口中的最大值最终得到  $S_{V_x}^2$  和  $S_{V_x}^3$ 。

## 2.2 基于PCA算法的特征处理

主成分分析(principal component analysis, PCA)是一种常用的多元统计分析方法,通过降低维度把多指标数据转化为能够反映事物特征的少量指标数据,从而从多元事物中解析出主要影响因素。PCA能够在不丢失大量有用信息的情况下降低输入空间的维数,一个维度较低的输入空间能够有效减少训练神经网络所需的时间,通过只保留有价值的主成分以提高映射能力<sup>[17]</sup>。

PCA算法流程具体如下:

- 1) 首先计算  $n$  组  $m$  维的数据样本集  $X$  的协方差矩阵  $C_{ov}$ ;
- 2) 计算协方差矩阵的特征值及对应的特征向量;
- 3) 将特征值按从大到小的顺序排列,选择其中最大的  $k$  个特征值以及对应的特征向量组成新的特征向量矩阵  $P$ ;
- 4) 将数据样本集  $X$  投影到新矩阵  $P$  上得到降

维的数据集,则降维后的数据集为

$$T_{(m \times k)} = X_{(m \times n)} \cdot P_{(n \times k)} \quad (9)$$

## 3 基于遗传算法优化的BP神经网络

BP神经网络是一种模仿人脑神经元的多层神经元模型,通过多次信号正向传播以及误差反向传播的迭代过程形成的神经网络模型,能够很好地处理非线性信息<sup>[15]</sup>。

如图5所示,三层BP神经网络由输入层、隐含层和输出层组成,  $X$  和  $y$  分别为输入层的输入信号和输出层的输出信号,  $\omega$  和  $b$  代表权值和阈值,  $f^1, f^2$  分别是隐含层和输出层的激活函数。每层都由神经元构成,将不同层之间神经元的连接定义为权值,定义阈值判断神经元的输出。在正向传播过程中网络的权值不变,若实际输出与期望输出不符,则通过误差从输出层反向传递到输入层逐步修正权值,该过程为误差信号的反向传播,2个过程不断迭代,直到误差或迭代次数达到设定值时停止。

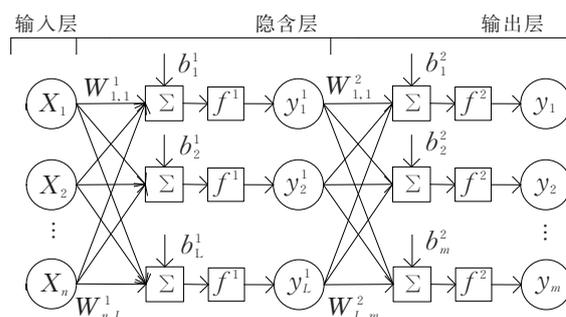


图5 三层BP神经网络结构

Figure 5 Three-layer BP neural network structure

网络的传输过程中信号的正向传播如下:

$$y_m = f^2 \left( \sum_{i=1}^l \omega_{i,m}^2 y_i^1 + b_m^2 \right) \quad (10)$$

设期望输出为  $Y_i$ , 则误差函数为

$$L = \frac{1}{2} \sum_{i=1}^m (Y_i - y_i)^2 \quad (11)$$

通过梯度下降法更新权值和阈值,实现网络的传输过程中误差信号的反向传播如下:

$$\omega_{i,j}^2 = \omega_{i,j}^2 - \eta \frac{\partial L}{\partial \omega_{i,j}^2} = \omega_{i,j}^2 - \eta \frac{\partial L}{\partial y_j} \frac{\partial y_j}{\partial \omega_{i,j}^2} \quad (12)$$

$$b_j^2 = b_j^2 - \eta \frac{\partial L}{\partial b_j^2} = b_j^2 - \eta \frac{\partial L}{\partial y_j} \frac{\partial y_j}{\partial b_j^2} \quad (13)$$

BP神经网络采用的梯度下降法,存在易陷入局部极小值、收敛速度慢等问题。为了解决这些问题,本文采用遗传算法对BP网络进行优化。遗传算法是一种不依赖梯度信息的迭代算法,模拟自然界中的优胜劣汰法则,通过对个体的遗传操作选择

出符合要求的最优个体<sup>[18-20]</sup>。GA 具有良好的并行性、鲁棒性以及全局最优性,其遗传操作包括选择、交叉和变异,能够对 BP 神经网络的初始权值和阈值进行优化,降低 BP 神经网络陷于局部极小值的风险,提高 BP 神经网络的稳定性<sup>[21]</sup>。

遗传算法不直接处理数据,而是对数据进行编码,通过适应度函数进行个体的选择,利用遗传算子即选择算子、交叉算子、变异算子来变换种群个体信息,经过多次迭代后从最新种群中确定最优解。针对 BP 神经网络的权值和阈值在训练中具有随机性的不足,选择 GA 优化 BP 神经网络的权值和阈值。结合 DCM-PCA 和 GA 优化 BP 神经网络的故障诊断流程如图 6 所示。

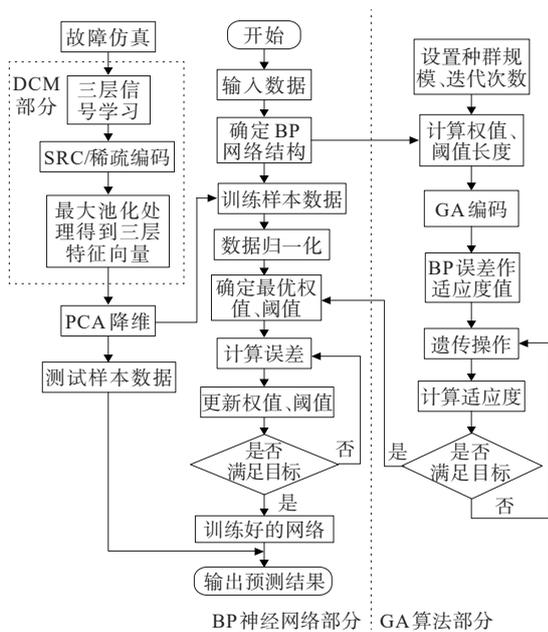


图 6 结合 DCM-PCA 和遗传算法优化 BP 神经网络的诊断流程

Figure 6 The diagnosis flow of genetic algorithm to optimize BP neural network combining DCM-PCA

其中遗传算法优化 BP 神经网络的主要步骤如下。

- 1) 将实验数据分为训练数据和测试数据,确定神经网络的输入输出层数,并对数据进行归一化处理。
- 2) 根据网络结构确定权值和阈值的长度,即种群个体长度,设置 GA 算法中的种群规模和迭代次数等参数,对初始种群进行遗传编码。
- 3) 将训练数据的误差作为个体适应度,通过遗传操作:选择、交叉和变异得到新的个体,并判断个体适应度是否满足目标要求。
- 4) 若不满足则跳回步骤 3),若满足则将最优个体解码并作为神经网络的权值和阈值。
- 5) 计算网络的全局误差,更新网络的权值和阈值,重复这一过程直到满足目标需求则输出预测结果。

### 4 仿真验证与分析

如图 7 所示为 2018a MATLAB/Simulink 下搭建电流控制、SVPWM 调制的三相电压型并网逆变器的仿真模型。在光伏并网系统中输出会受到光照强度的影响,考虑到环境的影响并依据通用的逆变器规格<sup>[5]</sup>,通过调节并网逆变器的直流侧电压和并网电流模拟在不同电压和额定功率下工作的情况。通过控制脉冲信号模拟开关管的通断,在 650 V/13 kW,650 V/26 kW,650 V/39 kW,700 V/7 kW,700 V/13 kW,700 V/20 kW,700 V/26 kW,700 V/33 kW,750 V/16 kW,800 V/20 kW,850 V/23 kW,900 V/26 kW 这些不同工况下采集开关管开路故障时的三相电流数据,共采集 264 组数据。

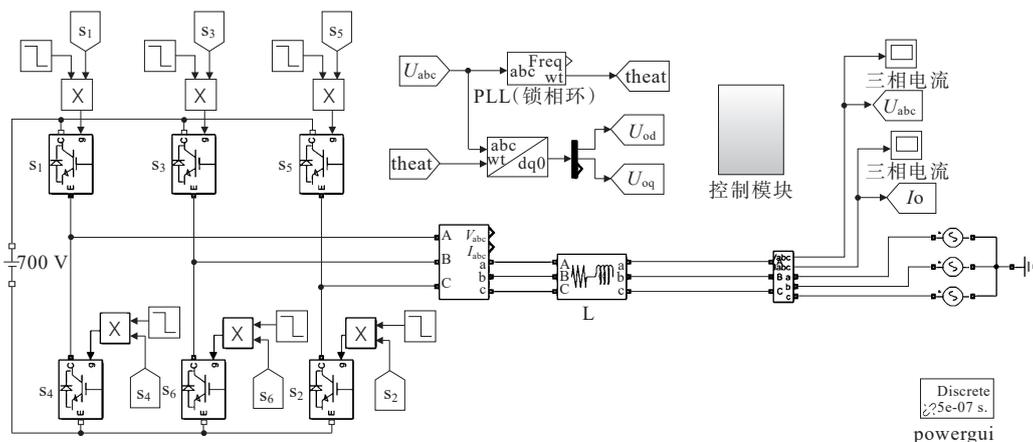


图 7 并网逆变器系统仿真模型

Figure 7 Simulation model of grid-connected inverter system

根据并网逆变器的拓扑结构可以建立三相坐标系下的数学模型,但其中参数是时变的三相交流变量,为了便于设计逆变器的控制器,通过Park变换得到 $d-q$ 坐标系下的数学模型。采用电网侧电流

搭建系统的电流内环控制模块,电流调节器采用PI调节,通过电流控制和SVPWM调制实现系统以单位功率因数向电网输入恒定功率的电能,电流内环控制仿真模块如图8所示。

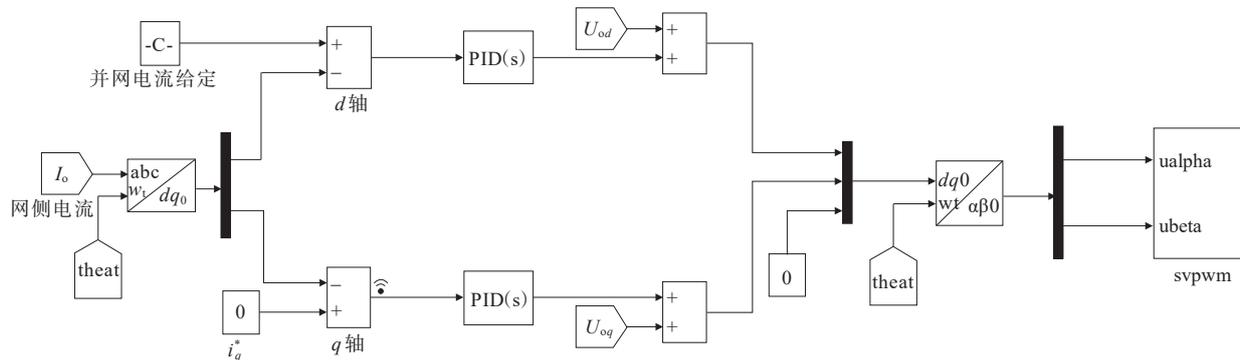


图8 电流内环控制模块

Figure 8 Current closed-loop control module

将特征提取和故障诊断方法应用于开关管故障诊断的步骤如下。

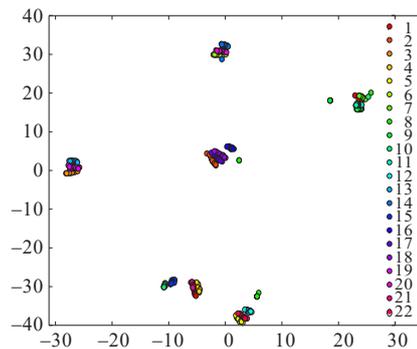
1) 首先利用深度学习中的层次学习进行特征的学习提取,将采集到的264组数据作为DCM的输入并将故障信号分为3层,第1层是原始信号,第2层将原始信号平分4个区域,第3层平分为16个区域;通过SRC对每一层的各个区域进行编码得到softmax向量;最后进行最大池化处理并合并3层特征向量,最终输出66维的故障特征。

2) 将上述输出的高维信号作为PCA的输入进行降维。

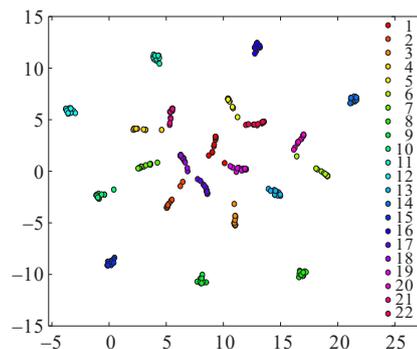
3) 得到的降维信号作为GA-BP神经网络的输入,根据前述网络的优化诊断步骤进行故障的学习和诊断,最终输出不同故障类型的编码实现故障的识别诊断。

通过DCM处理得到了维数为66的故障特征向量,为了验证特征提取的性能,最常见的方法之一是将特征向量的维数降为二维,并生成二维特征分布图<sup>[22]</sup>。本文采用t-SNE方法反映特征提取效果,与采用FFT提取的三相电流特征进行对比,DCM对故障特征的提取结果如图9所示。由图9所示的特征分布可以看出,FFT提取的部分故障类别混合在一起、不同故障特征极为接近,而DCM提取的故障特征表现出了较好的聚类效果、不同故障特征是明显分离的。

DCM提取的特征向量维度较高。为了有效减少神经网络的训练时间,并在不丢失有用信息的前提下降低网络输入特征的维度,本文采用PCA降



(a) FFT提取特征分布



(b) DCM提取特征分布

图9 特征提取结果t-SNE分布

Figure 9 The t-SNE distribution map of feature extraction results

维。通过保留有价值的主成分以提高映射能力。对DCM提取的故障特征样本进行主成分分析求解,计算得到样本的特征值及相应的累计贡献率。一般为保证主成分模型的精确度,选择累计贡献率大于85%的前 $k$ 个特征值即可<sup>[23]</sup>。通过PCA降维

得到的特征值及累计贡献率如表 2 所示,选择累计贡献率为 88% 的前 17 个特征值,通过 PCA 算法使得 DCM 提取的 66 维故障特征降为 17 维,极大地减小了故障特征的冗余度。

表 2 特征值及累计贡献率

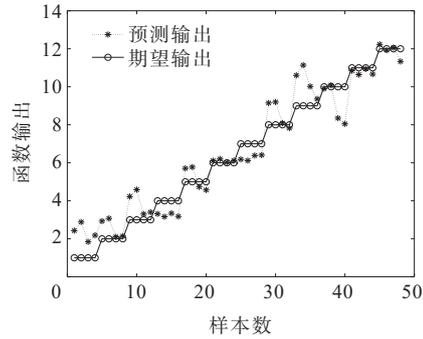
Table 2 Eigenvalues and cumulative contribution rate

序号	特征值(E-04)	累计贡献率/%
1	6.20	7.00
2	5.96	15.00
3	5.52	21.00
4	5.07	27.00
5	4.83	33.00
6	4.69	39.00
7	4.52	44.00
8	4.37	49.00
9	4.32	54.00
10	4.26	60.00
11	4.14	65.00
12	4.08	69.00
13	3.84	74.00
14	3.18	78.00
15	3.11	82.00
16	3.02	85.00
17	2.70	88.00

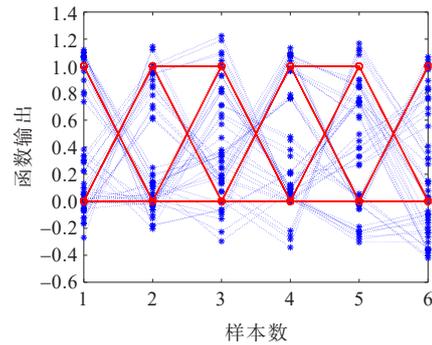
网络结构在一定程度上会影响映射能力。本文以同相同半桥和异相异半桥上的双管开路故障为诊断对象,通过 BP 神经网络进行故障识别。将神经网络的输出分别设置为单标签输出和多标签输出,其网络预测结果如图 10 所示,2 种网络结构的输出对比结果如表 3 所示。

通过仿真验证可知,与一个神经元作为输出的网络结构相比,采用 0、1(1 表示故障)编码的 6 个神经元输出提高了诊断准确率、减小了误差,能够有效提高网络映射能力和准确率。经过实验选择的三层 BP 网络结构:输入层数目即故障特征样本维度为 17,隐含层数目为 12,输出层数目为 6,22 类故障状态及相应输出编码如表 4 所示。GA-BP 神经网络训练曲线如图 11 所示。

网络的参数设置如表 5 所示,DCM 部分:对输入数据  $H_1^L, H_2^L$  进行正则化,正则化系数  $\lambda$  和常系数  $u$  为经验参数<sup>[8]</sup>,不同系数下网络诊断效果会有所不同,分别设置  $\lambda$  为 0、0.1、 $10^{-3}$  和  $10^{-4}$ 。当  $\lambda$  减小时,网络训练准确率有所提高;当其低于  $10^{-3}$  时,网络准确率基本不变。故设置正则化系数  $\lambda$  为 0.001,



(a) BP 神经网络单标签预测输出



(b) BP 神经网络 6 位编码预测输出

图 10 不同输出标签下 BPNN 的预测结果

Figure 10 Prediction results of BPNN under different output labels

表 3 不同网络结构的预测效果对比

Table 3 Comparison of prediction effects of different network structures

输出层结构	准确率/%	误差范围	平均绝对误差
单标签	14.58	[-2, 2.5]	0.689 5
6 位编码	41.32	[-0.6, 0.8]	0.165 7

$u$  过大和过小时均会使得准确率降低,在 0.1 附近时准确率稳定,故设置  $u$  为 0.1;遗传算法的种群规模通常在 40~200,交叉概率和变异概率的合理取值范围分别为 0.3~0.9 和 0.05~0.3<sup>[24]</sup>。为减小网络的计算量设置初始种群规模为 40,结合文献[25]设置交叉概率为 0.4、变异概率为 0.2。由图 11(a)所示的平均适应度进化曲线可知,当迭代次数接近 50 时,平均适应度曲线趋于稳定,故设置 GA 的最大迭代次数为 50,设置 BP 网络的训练目标最小误差为 0.001。由图 11(b)的训练误差曲线可知,当迭代次数为 100 时曲线十分稳定,故设置最大迭代数为 100,并且当迭代次数接近 50 时,达到了目标误差,这与适应度曲线的结果一致。

表4 开关管故障类别及编码

Table 4 Switch tube failure categories and code

故障状态	故障开关管	状态类别	输出编码
正常状态	无	1	000000
单管故障	V <sub>1</sub>	2	000001
	V <sub>2</sub>	3	000010
	V <sub>3</sub>	4	000100
	V <sub>4</sub>	5	001000
	V <sub>5</sub>	6	010000
	V <sub>6</sub>	7	100000
同相故障	V <sub>1</sub> 、V <sub>4</sub>	8	001001
	V <sub>3</sub> 、V <sub>6</sub>	9	100100
	V <sub>5</sub> 、V <sub>2</sub>	10	010010
	V <sub>1</sub> 、V <sub>3</sub>	11	000101
双管故障	V <sub>1</sub> 、V <sub>5</sub>	12	010001
	V <sub>3</sub> 、V <sub>5</sub>	13	010100
	V <sub>4</sub> 、V <sub>6</sub>	14	101000
	V <sub>4</sub> 、V <sub>2</sub>	15	001010
	V <sub>6</sub> 、V <sub>2</sub>	16	100010
	V <sub>1</sub> 、V <sub>6</sub>	17	100001
	V <sub>1</sub> 、V <sub>2</sub>	18	000011
	V <sub>4</sub> 、V <sub>3</sub>	19	001100
异相异半桥故障	V <sub>4</sub> 、V <sub>5</sub>	20	011000
	V <sub>3</sub> 、V <sub>2</sub>	21	000110
	V <sub>6</sub> 、V <sub>5</sub>	22	110000

表5 网络参数设置

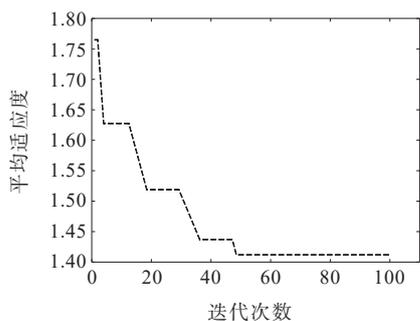
Table 5 Network parameter settings

模型	参数量	参数值
DCM	正则化系数	0.001
	常系数 $u$	0.1
BP网络	训练次数	100
	学习速率	0.07
	训练目标误差	0.001
GA	迭代次数	50
	交叉概率	0.4
	变异概率	0.2

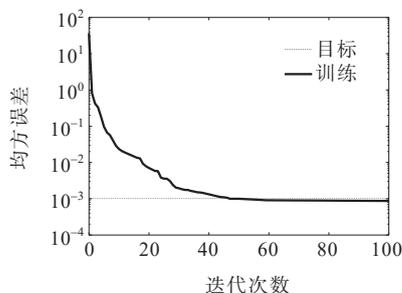
当样本数据过少时,神经网络容易出现欠拟合,无法达到较小的目标误差。然而,在工程实际中,系统通常运行在正常状态,故障为少数非常态,不易收集大量故障数据。因此,希望在小样本情况下网络也能有很好的故障诊断效果。为此,本文对22类故障采集了264组数据。基于GA优化的BP神经网络将36维的故障特征作为输入,其中176组数据用于训练网络,剩余的88组数据用于测试。训练网络得到的误差曲线如图12(a)所示。其中,验证曲线用于检验网络的拟合能力。当训练误差连续6次无法降低时,即停止训练。在第50次迭代时,验证误差达到最优,迭代到第56次时停止训练以防止过拟合。设置准确度误差为0.1,测试样本准确率为95.64%。预测输出结果如图12(b)所示,图12(c)展示了预测与期望之间的误差,图例分别对应表4中的22类故障状态。仿真结果表明,该方法具有较高的故障诊断率,具有很好的故障诊断效果。因此,在工程实际中,该方法有一定的可行性。

文献[3-5]中通过FFT提取故障特征,验证了BP神经网络进行故障诊断的可行性。然而,传统数据处理方法如FFT存在特征缺失等问题,同时BP神经网络容易陷入局部极小值。为了解决这些问题,本文采用GA来有效优化BP网络的权值和阈值。

为验证基于DCM-PCA和GA-BP的故障诊断方法对开关管的故障识别能力,并有效提高故障诊断率,本文与FFT进行对比,以验证DCM-PCA对故障特征提取效果的优化以及对诊断准确率的提高,同时与BP网络对比,以验证GA优化对故障诊断效果的影响。



(a) 平均适应度进化曲线



(b) 网络训练结果曲线

图11 GA-BP神经网络训练曲线

Figure 11 Training curve of GA-BP neural network

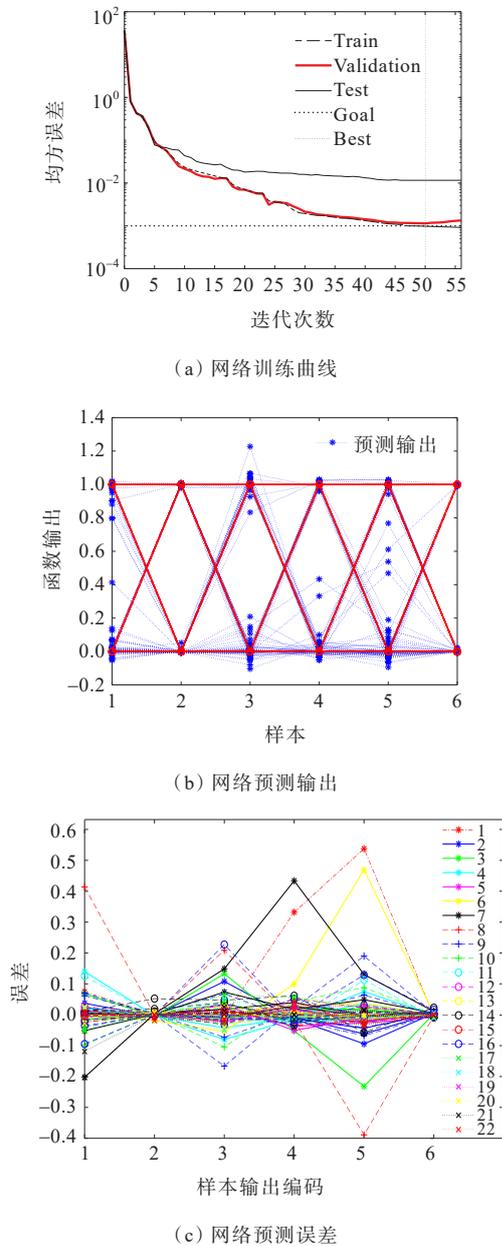


图 12 GA-BP 神经网络测试结果

Figure 12 Test results of GA-BP neural network

本文分别通过 DCM-PCA 和 FFT 提取故障特征。其中,FFT 提取三相电流的直流幅值、相位和基波幅值、相位作为故障特征。然后,采用 BP 神经网络和基于 GA 优化的 BP 神经网络进行故障识别。实验结果如表 6 所示,FFT 结合 GA-BP 的方法故障诊断准确率为 75%,相较于 FFT 结合 BP 的诊断准确率提高了 31.06%。这表明在小样本数据下,BP 网络不能达到很好的识别效果,而 GA 对 BP 网络的优化可以有效提高其泛化能力。

另一方面,DCM-PCA 提取故障特征与 GA-BP 网络结合的方法使故障诊断率达到 95.64%,相较于 FFT-GA-BP 的准确率提升了 20.64%。这表明

DCM 具有更好的特征提取效果,而 DCM-PCA-GA-BP 的平均绝对误差(MAE)是 4 种方法中最小的。图 13 展示了 4 种方法预测样本的平均误差对比结果,结果表明基于 DCM-PCA 和 GA-BP 的方法能够达到很好的故障诊断效果。

表 6 实验对比结果

Table 6 Experimental comparison results

分类算法	准确率/%	MAE
FFT-BP	43.94	0.153 3
FFT-GA-BP	75.00	0.085 3
DCM-PCA-BP	86.93	0.052 0
DCM-PCA-GA-BP	95.64	0.023 6

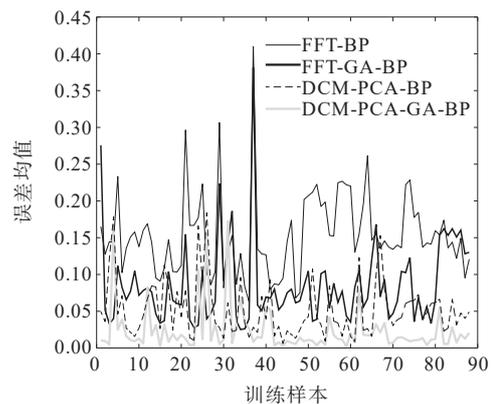


图 13 不同方法的误差对比

Figure 13 Error comparison of different methods

22 种故障可以分为单管故障、同相双管故障、异相同半桥双管故障和异相异半桥双管故障 4 类,对 4 类故障分别进行诊断分析,得到的故障诊断结果如表 7 所示。可知,各类故障的平均绝对误差均小于 22 类故障识别的平均绝对误差,当故障类别减小时网络的诊断效果会提高,而该方法在增加故障类别后依然显示出很好的故障诊断效果。

表 7 4 类故障的网络诊断结果

Table 7 Network diagnosis results for 4 types of faults

故障类型	准确率/%	MAE
单管故障	97.14	0.006 5
同相双管	99.44	0.002 9
异相同桥	100.00	0.002 8
异相异桥	98.61	0.003 3

## 4 结语

本文针对电压型光伏逆变器的开关管故障,提出了一种 DCM-PCA 与 GA 优化的 BP 神经网络结

合的诊断方法。相比传统的特征提取模型如FFT,本文方法采用DCM对输入信号进行分层处理和故障特征提取。DCM的层次学习和多层连接特性提高了特征提取能力和网络的泛化能力。同时,通过GA优化了神经网络的权值和阈值,提高了网络的诊断精度。结合PCA降维处理降低了网络的复杂程度,提高了神经网络的映射能力。具体结论如下。

1) 该方法采用三相电流信号作为故障信号,无需增加额外传感器。

2) 首次将DCM应用于逆变器的开路故障特征提取。DCM通过分层处理对信号特征进行学习,通过结合softmax函数和最大池化的SRC编码部分提取故障特征。t-SNE分布表明DCM提取的故障特征具有很好的聚类效果,对比实验表明其特征提取效果明显优于FFT。DCM-PCA-BP与FFT-BP相比以及DCM-PCA-GA-BP与FFT-GA-BP相比准确率分别提高了42.99%和20.64%,表明DCM有更好的特征提取能力,提高了网络的泛化能力。

3) DCM结合PCA在不丢失有用信息的前提下降低网络输入特征的维度,降低了冗余度的同时保留有价值的主成分,降低了网络的复杂度。

4) 采用GA优化BP神经网络避免网络陷入局部最优。FFT-GA-BP与FFT-BP相比以及DCM-PCA-GA-BP与DCM-PCA-BP相比故障诊断准确率分别提高了31.06%和8.71%,表明GA对网络的优化能够有效提高诊断精度。

#### 参考文献:

- [1] 马铭遥,凌峰,孙雅蓉,等.三相电压型逆变器智能化故障诊断方法综述[J].中国电机工程学报,2020,40(23):7683-7699.  
MA Mingyao, LING Feng, SUN Yarong, et al. Review of intelligent fault diagnosis methods for three-phase voltage-mode inverters[J]. Proceedings of the CSEE, 2020,40(23):7683-7699.
- [2] 周嘉琪,毕利.基于GAN的光伏逆变器数据异常检测技术[J].电力系保护与控制,2022,50(1):133-140.  
ZHOU Jiaqi, BI Li. Abnormal detection technology of photovoltaic inverter data based on GAN[J]. Power System Protection and Control, 2022,50(1):133-140.
- [3] 赵晖,徐浩然,梅志刚,等.基于人工神经网络的逆变器开路故障诊断[J].电力电子技术,2021,55(2):45-49.  
ZHAO Hui, XU Haoran, MEI Zhigang, et al. Fault diagnostic system for inverter open-circuit faults based on neural network[J]. Power Electronics Technology, 2021,55(2):45-49.
- [4] 张法,陈月莹,王志,等.基于BP神经网络的静止变频器故障诊断方法[J].自动化与仪表,2020,35(10):67-72.  
ZHANG Fa, CHEN Yueying, WANG Zhi, et al. Fault diagnosis method of static frequency converter based on BP neural network[J]. Automation and Instrumentation, 2020,35(10):67-72.
- [5] 王丽华,方旭东,韩素敏,等.基于BP神经网络的三电平逆变器开路故障诊断研究[J].机床与液压,2020,48(9):187-191.  
WANG Lihua, FANG Xudong, HAN Sumin, et al. Research on open circuit fault diagnosis of three-level inverter based on BP neural network[J]. Machine Tool and Hydraulics, 2020,48(9):187-191.
- [6] 黄敬尧,李雅恬,程煜.基于PSO-RBF和PCA-PSO-PNN的六脉冲整流器故障诊断研究[J].国外电子测量技术,2022,41(5):165-172.  
HUANG Jingyao, LI Yatian, CHENG Yu. Research on fault diagnosis of six-pulse rectifier based on PSO-RBF and PCA-PSO-PNN[J]. Foreign Electronic Measurement Technology, 2022,41(5):165-172.
- [7] 申利燕,孔红.基于GA-BP神经网络的掘进机减速器故障检测方法[J].煤炭技术,2022,41(5):219-221.  
SHEN Liyan, KONG Hong. Fault detection method of roadheader reducer based on GA-BP neural network[J]. Coal Technology, 2022,41(5):219-221.
- [8] ZHANG L, LIU J, ZHANG B, et al. Deep cascade model-based face recognition: When deep-layered learning meets small data[J]. IEEE Transactions on Image Processing, 2019,29:1016-1029.
- [9] BANDYOPADHYAY I, PURKAIT P, KOLEY C. Performance of a classifier based on time-domain features for incipient fault detection in inverter drives[J]. IEEE Transactions on Industrial Informatics, 2018,15(1):3-14.
- [10] LI C, LIU Z, ZHANG Y, et al. Diagnosis and location of the open-circuit fault in modular multilevel converters: An improved machine learning method[J]. Neurocomputing, 2019,331:58-66.
- [11] 商蕾,武美君,高海波,等.基于三通道2D-CNN的逆变器功率管开路故障诊断方法[J].船海工程,2020,49(1):78-82.  
SHANG Lei, WU Meijun, GAO Haibo, et al. A diagnostic technique for open-switch fault of inverters based on three-channel 2D-CNN[J]. Ship and Ocean Engineering, 2020,49(1):78-82.
- [12] 李英峰,张涛,张衡,等.太阳能光伏光热高效综合利用技术[J].发电技术,2022,43(3):373-391.  
LI Yingfeng, ZHANG Tao, ZHANG Heng, et al. Efficient and comprehensive photovoltaic/photothermal utilization technologies for solar energy[J]. Power Generation

- Technology, 2022, 43(3):373-391.
- [13] 韩素敏,周孟,郑书晴. 基于BP神经网络的三相电压源型逆变器开路故障诊断[J]. 河南理工大学学报(自然科学版), 2021, 40(6):126-131+188.  
HAN Sumin, ZHOU Meng, ZHENG Shuqing. Open circuit fault diagnosis of three-phase voltage source inverter based on BP neural network[J]. Journal of Henan University of Technology(Natural Science Edition), 2021, 40(6):126-131+188.
- [14] 杨秀,焦楷丹,孙改平,等. 考虑负荷多无功电场景的城市配电网无功优化配置[J]. 电力建设, 2022, 43(8):42-52.  
YANG Xiu, JIAO Kaidan, SUN Gaiping, et al. Reactive power optimization of urban distribution network considering multiple reactive power scenarios of loads [J]. Electric Power Construction, 2022, 43(8):42-52.
- [15] 许水清,黄文展,何恰刚,等. 基于自适应滑模观测器的中点钳位型三电平并网逆变器开路故障诊断[J]. 电工技术学报, 2023, 38(4):1010-1022.  
XU Shuiqing, HUANG Wenzhan, HE Yigang, et al. Open-circuit fault diagnosis method of neutral point clamped three-level grid-connected inverter based on adaptive sliding mode observer[J]. Transactions of China Electrotechnical Society, 2023, 38(4):1010-1022.
- [16] 洪芦诚,徐佳裕,唐润悦,等. 三相LCL型逆变器序阻抗简化建模方法及并网稳定性分析[J]. 电力系统自动化, 2023, 47(7):150-157.  
HONG Lucheng, XU Jiayu, TANG Runyue, et al. Simplified modeling method of sequence impedance and grid-connected stability analysis for three-phase LCL inverter[J]. Automation of Electric Power Systems, 2023, 47(7):150-157.
- [17] 宋威,施伟锋,卓金宝,等. 多电平逆变器开关管故障诊断方法综述[J]. 微电机, 2019, 52(10):110-117.  
SONG Wei, SHI Weifeng, ZHUO Jinbao, et al. Review of fault diagnosis methods for switching tubes of multilevel inverters[J]. Micromotor, 2019, 52(10):110-117.
- [18] 刘文宇,刘璐,刘馨然,等. 基于改进BP神经网络的低压配电台区智能电能表误差状态评估模型[J]. 电测与仪表, 2022, 59(11):176-181.  
LIU Wenyu, LIU Lu, LIU Xinran, et al. An error estimation method of smart electricity meter in low voltage distribution area based on improved BP neural network[J]. Electrical Measurement & Instrumentation, 2022, 59(11):176-181.
- [19] 李岩,袁弘宇,于佳乔,等. 遗传算法在优化问题中的应用综述[J]. 山东工业技术, 2019(12):242-243+180.  
LI Yan, YUAN Hongyu, YU Jiaqiao, etc. Review of the application of genetic algorithm in optimization problems[J]. Shandong Industrial Technology, 2019(12): 242-243+180.
- [20] 郭露方,张宝丹,吴广大,等. 一种考虑低压侧直供潜力的输配电网规划方法研究[J]. 智慧电力, 2022, 50(5):40-47+93.  
GUO Lufang, ZHANG Baodan, WU Guangda, et al. Planning of power transmission and distribution network considering direct supply potential of low voltage side[J]. Smart Power, 2022, 50(5):40-47+93.
- [21] 朱显辉,于越,师楠,等. BP神经网络的分层优化研究及其在风电功率预测中的应用[J]. 高压电器, 2022, 58(2):158-163.  
ZHU Xianhui, YU Yue, SHI Nan, et al. Research on hierarchical optimization of BP Neural network and its application in wind power prediction[J]. High Voltage Apparatus, 2022, 58(2):158-163.
- [22] SHI T, HE Y, WANG T, et al. Open switch fault diagnosis method for PWM voltage source rectifier based on deep learning approach[J]. IEEE Access, 2019, 7:66595-66608.
- [23] 尹文龙,陈辉,管聪,等. 基于PCA-PNN的柴油机故障识别方法研究[J]. 武汉理工大学学报:交通科学与工程版, 2021, 45(2):270-275.  
YIN Wenlong, CHEN Hui, GUAN Cong, et al. Research on fault identification method of diesel engine based on PCA-PNN[J]. Journal of Wuhan University of Technology: Traffic Science and Engineering, 2021, 45(2): 270-275.
- [24] 毛李恒,邓清,刘柔妮,等. 针对多星多任务仿真调度的关键路径遗传算法[J]. 系统仿真学报, 2021, 33(1):205-214.  
MAO Liheng, DENG Qing, LIU Runi, et al. CPM-GA for multi-satellite and multi-task simulation scheduling[J]. Journal of System Simulation, 2021, 33(1):205-214.
- [25] 王金锋,杨宇琦,温栋,等. 基于GA-BP和RBF的风力发电时间序列混沌预测组合模型[J]. 电网与清洁能源, 2022, 38(11):117-125.  
WANG Jinfeng, YANG Yuqi, WEN Dong, et al. A combined model of chaos prediction of wind power generation time series based on GA-BP and RBF[J]. Power System and Clean Energy, 2022, 38(11):117-125.
- [26] 杨桢,马钰超,李丽,等. 基于HHT和GA-BP的电压暂降源定位方法[J]. 中国电力, 2022, 55(3):97-104.  
YANG Zhen, MA Yuchao, LI Li, et al. Voltage sag source location method based on HHT and GA-BP[J]. China Electric Power, 2022, 55(3):97-104.