

基于 EEMD 模糊熵和 PSO-KELM 的 NPC 三电平逆变器故障诊断

马子旻¹, 张朝龙^{1, 2}, 何怡刚²

(1. 安庆师范大学 电子工程与智能制造学院, 安徽 安庆 246052;

2. 武汉大学 电气与自动化学院, 武汉 430072)

摘要: 功率开关器件是逆变器的核心部件, 但其易发生开路故障, 故对其进行故障诊断方法研究很有必要; 针对中点钳位型 (NPC) 三电平逆变器功率开关器件的开路故障, 提出一种基于总体经验模态分解 (EEMD) 模糊熵和粒子群算法 (PSO) 优化的核函数极限学习机 (KELM) 的故障诊断方法; 首先采样功率开关器件的桥臂输出端的三相电压作为故障信号以区分各种故障类型, 然后利用 EEMD 模糊熵提取故障特征向量, 最后将其划分为训练集和测试集送入 PSO-KELM 中, 识别故障类型并输出诊断结果; 经 Matlab 平台仿真实验得到该方法的故障诊断率超过 98%, 通过与其他方法的对比实验分析, 该方法的有效性与优势得到验证。

关键词: NPC 三电平逆变器; 故障诊断; EEMD; 模糊熵; PSO-KELM

Fault Diagnosis of NPC Three-Level Inverter Based on EEMD Fuzzy Entropy and PSO-KELM

MA Ziyang¹, ZHANG Chaolong^{1, 2}, HE Yigang²

(1. School of Electronic and Intelligent Manufacturing, Anqing Normal University, Anqing 246052, China;

2. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

Abstract: Power switching device is the core component of inverter, but it is prone to open circuit fault, so it is necessary to study the fault diagnosis method. Aiming to the open-circuit fault of power electronic devices in neutral-point clamped (NPC) three-level inverter, a fault diagnosis approach based on ensemble empirical mode decomposition (EEMD) with fuzzy entropy and Kernel extreme learning machine (KELM) with particle swarm optimization (PSO) is proposed. Firstly, the bridge three-phase voltage of power switch devices are sampled as the characteristic signals to classify different fault types. Afterwards, the feature parameters of the fault diagnosis is extracted by EEMD with fuzzy entropy. Finally, the feature parameters in various fault situations is taken as training samples and testing samples, the PSO-KELM algorithm is utilized to identify different kinds of faults and output the consequences of fault diagnosis. Through MATLAB simulation experimental platform, the capability of the proposed method is more than 98%. Through comparing with other method, the effectiveness and superiority of the proposed method is proved.

Keywords: NPC (neutral point clamped) three-level inverter; fault diagnosis; EEMD (ensemble empirical mode decomposition); fuzzy entropy; PSO-KELM (particle swarm optimization—kernel extreme learning machine)

0 引言

NPC 三电平逆变器的输出电压高且容量大, 产生的电流谐波含量少, 工作效率高, 因此近些年来广泛应用于新能源发电及电能贮备系统中。NPC 三电平逆变器的电路拓扑结构较普通逆变器更为复杂, 其功率开关器件频繁地闭合关断, 易发生开路故障, 会引起系统中电力电子器件的

过饱和问题, 产生的过高电流会损坏设备, 存在着极大的安全隐患。为了避免故障对系统的正常运行造成影响, 选择合适的故障诊断方法对于提升系统的稳定性, 保证系统可靠性方面至关重要。

传统的逆变器开路故障诊断策略通常单一的依靠信号处理的方法, 主要体现在通过获取开关管开路故障时刻的电压或者电流信号来提取相关信息。三相电流与克拉克变

收稿日期: 2021-09-15; 修回日期: 2021-11-01。

基金项目: 国家自然科学基金资助项目(51637004); 国家重点研发计划“重大科学仪器设备开发”项目(2016YFF0102200); 国家自然科学基金项目(51607004); 安徽高校协同创新项目(GXXT-2019-002); 安徽高校自然科学研究重点项目(KJ2020A0509)。

作者简介: 马子旻(1996-), 男, 安徽安庆人, 硕士研究生, 主要从事逆变器故障诊断及容错控制技术方向的研究。

通讯作者: 张朝龙(1982-), 男, 安徽明光人, 硕士生导师, 教授, 主要从事模拟电路和混杂系统的故障诊断和预测方向的研究。

何怡刚(1966-), 男, 湖南邵阳人, 博士生导师, 教授, 主要从事电力电子技术等相关方向的研究。

引用格式: 马子旻, 张朝龙, 何怡刚. 基于 EEMD 模糊熵和 PSO-KELM 的 NPC 三电平逆变器故障诊断[J]. 计算机测量与控制, 2022, 30(4): 50-55, 108.

换相结合, 得出电流的运行轨迹, 从而判断故障发生的位置^[1-2]。通过提前设定电压残差的相关阈值, 来检测并判断 IGBT 的故障部位, 实现快速定位^[2-3]。但上述所提及的传统方法易受到外界干扰信号的波及, 且对采集信号的纯度要求较高, 依赖性强, 所以故障准确率较低。

现有的逆变器开路故障诊断策略更多是基于信号提取和机器学习方法相结合, 当故障发生时, 对系统的故障信号进行识别分类及定位。傅里叶变换可以有效地提取出逆变器电压信号的频域和时域特征, 但是只能在单一范围内取得成效, 故无法全面提取故障信息。小波分析和概率神经网络 (PNN, probabilistic neural network) 相结合, 稳定性高, 但输入端的测量信号未进行去噪处理, 故诊断速率一般。主成分分析 (PCA, principal component analysis) 加上支持向量机 (SVM, support vector machine)^[4-5], 针对混杂系统取得了良好效果, 但不同故障状态下的模型参数难以抉择。经验模态分解 (EMD, empirical mode decomposition)^[6-7] 将原本复杂的故障信号分解成若干段本征模态分量 (IMF, intrinsic mode function) 作为故障特征值进行分析, 化繁为简, 但 EMD 在递归式分解的过程中存在模态混叠从而可能导致误诊^[8-9]。

但是目前针对逆变器开关管器件开路故障的研究进展依然不够全面可靠, 故本文提出一种基于 EEMD 模糊熵和 PSO-KELM 的故障诊断方法^[10-11], EEMD 在 EMD 基础上加以改进, 具有很强的抗模态混叠能力。模糊熵则对电压信号的波动畸变具有很强的敏感性, 将二者结合可以及时检测出逆变器系统的电压突变。KELM 是由极限学习机 (ELM, extreme learning machine) 优化改进而来^[8-9], 在保留 ELM 学习速率快和泛化性强的基础上, 核函数的加入再加上粒子群优化使得 KELM 的稳定性大幅提高, 在信号处理过程中分类性能较好。

鉴于现有的研究工作与进展, 本文在 Matlab/Simulink 平台搭建 NPC 三电平逆变器仿真模型, 采样电压信号, 利用 EEMD 先将原始信号处理成若干段稳定的 IMF 模态分量和一个余项, 经相关系数法准则去除掉作用小的分量, 然后计算剩余 IMF 分量的有效模糊熵值, 形成能表征不同类型开路故障时刻的特征向量, 通过优化过的 PSO-KELM 进行分类, 最终可达到较高的故障诊断准确率。

1 诊断方法理论介绍

1.1 模糊熵的特征提取

模糊熵使用隶属度函数和均值算法作为度量判据, 将故障特征向量作为样本信息, 模糊相似度量后进行有效分类, 可解决其他类型熵划分故障特征在时间序列尺度上过于单一的问题, 且较为稳定。模糊熵利用指数函数 (模糊函数边界的梯度是为 n , 宽度是为 r) 来计算向量之间的相似性, 对于一段若干个序列点排列成的时间序列, 模糊熵的计算公式如下:

先对时间序列处理得到 m 维向量, 即是:

$$x_m^i = \{x(i), x(i+1), \dots, x(i+m-1) - x_0(i)\}$$

$$x_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} x(i+j) \quad (1)$$

式中, $i=1, 2, \dots, N-m+1$; x_i^m 表示的是时间序列去除均值 $x_0(i)$ 之后的结果。

随机定义两向量之间的间隔为两者所对应元素绝对值的最大差值, 即是:

$$d_{i,j}^m = d[x_i^m, x_j^m] = \max\{|x(i+k) - u_0(i)| - |x(j+k) - u_0(i)|\} - |x(j+k) - u_0(j)| \quad (i, j = 1, 2, \dots, N-m, i \neq j) \quad (2)$$

式中, $d_{i,j}^m$ 表示向量 x_i^m 和向量 x_j^m 之间的距离。

由模糊函数可以定义向量 x_i^m 和向量 x_j^m 的相似度:

$$D_{i,j}^m = \mu(d_{i,j}^m, n, r) = e^{-d_{i,j}^m/r}$$

定义模糊函数是为:

$$\psi^{m+1}(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-M-1} \sum_{j \neq i, j=1}^{N-M} d_{i,j}^m \right) \quad (3)$$

模糊熵函数在 $m+1$ 维上的形式如下:

$$\psi^{m+1}(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-M-1} \sum_{j \neq i, j=1}^{N-M} d_{i,j}^{m+1} \right) \quad (4)$$

式中, r 表示函数的相似容限。

由以上这些步骤可以得到模糊熵值是为:

$$FuzzyEn(m, n, r) = \lim_{N \rightarrow \infty} [\ln \psi^m(n, r) - \ln \psi^{m+1}(n, r)] \quad (5)$$

在 N 为具体的有限数字时, 得到模糊熵的数学表达式如下:

$$FuzzyEn(m, n, r, N) = \ln \psi^m(n, r) - \ln \psi^{m+1}(n, r) \quad (6)$$

1.2 EEMD 方法

EEMD 是利用高斯白噪声独特的时频域特性, 将其与原始信号相结合, 经过多次分解得到所有的本征模态分量后对其取均值, 因为高斯白噪声能够保证每个模态分量在时域中的有序性, 使得不同的时间尺度信号匹配到适宜的参考尺度上, 从而在一定程度上消除模态混叠, 算法具体过程如下:

确定信号 $x(t)$ 并添加标准差为常数, 均值为零的高斯白噪声 $n_i(t)$, 则公式如下:

$$x(t) = x_i(t) + n_i(t) \quad (7)$$

信号 $x_i(t)$ 进行 EMD 分解得到若干个 IMF 分量 $c_j(t)$ 与一个剩下的残留分量 $r_i(t)$ 。

重复一二两步共 H 次, 进行总体平均以消除高斯白噪声的影响, 得到 EEMD 分解的第 j 个 IMF 分量:

$$c_j(t) = \frac{1}{H} \sum_{i=1}^H c_{ij}(t) \quad (8)$$

因为在上述迭代计算的过程中, 分解产生的一些误差客观上将会影响到最终求得 IMF 分量的准确性, 不是所有的 IMF 分量都可以代表原始信号的相关特征, 所以有必要去除掉无效的 IMF 份量。可以通过计算相关系数来确定:

$$p_{w_c} = \frac{Cov(x, c_i)}{\sqrt{D(x)} \sqrt{D(c_i)}} = \frac{E((x - Ex)(c_i - Ec_i))}{\sqrt{D(x)} \sqrt{D(c_i)}} \quad (9)$$

式中, 原始信号 x 与 IMF 分量 c_i 的协方差为 $Cov(x, c_i)$,

原始信号 x 的方差为 $D(x)$ 。 P_{wi} 的取值范围是为 $[-1, 1]$, $[0, 1]$ 表示的是正相关, $[-1, 0]$ 则表示负相关。相关系数的绝对值大小反映了分解得到的本征模态分量和原始信号的线性相关度, 绝对值越大, 相关度越高, 有效性则越强。

使用 EEMD 分解得到特征提取后的模糊熵 IMF 分量, 并适当剔除一些无关分量, 即为 EEMD 多尺度模糊熵。

1.3 基于 PSO-KELM 的故障识别

通过 EEMD 模糊熵有效提取故障信息后, 要根据故障的不同类型来进行划分, 本文采用核函数极限学习机进行故障识别。ELM 属于单隐层前馈神经网络 (SHFNN, single hidden feedforward neural networks), 其优势在于不需要人为调整隐藏层的偏置和权重, 可以随机生成, 但其结构则相对较为简单, 故引入核函数来提高性能。

ELM 的输出函数如下:

$$f_{ELM}(x) = h(x)\beta = h(x)H^T(\frac{1}{C} + HH^T)^{-1}Y \quad (10)$$

式中, $h(x)$ 是对应输入样本 x 的隐藏层输出, 是隐藏层和输出层之间的输出权重向量, H 是隐藏层输出矩阵。

定义 KELM 的核矩阵为:

$$\Omega_{KELM} = HH^T; \Omega_{KELM} = h(x_i)h(x_j) = K_{KELM}(x_i, x_j) \quad (11)$$

由上面二式可得到 KELM 的输出函数为:

$$f_{KELM}(x) = \begin{bmatrix} K_{KELM}(x, x_1) \\ \vdots \\ K_{KELM}(x, x_n) \end{bmatrix} (\frac{1}{C} + \Omega_{KELM})^{-1} \quad (12)$$

1.4 PSO 优化 KELM 步骤分析

粒子群算法是研究人员观察鸟类觅食过程中相关群体以及个体运动规律的所归纳总结出的优化算法。从微观粒子运动的角度出发, 针对解空间的可行域中每个粒子以及对周围粒子的搜索能力, 动态调整其具体的空间位置和运动速度, 粒子的适应度函数依赖于局部极值 P 和整体极值 G 的变化, 并在优化迭代时不断更新, 具体的计算公式如下:

$$\begin{aligned} V_{id} &= \omega V_{id} + C_1 random(0, 1)(P_{gd} - X_{id}) + \\ &C_2 random(P_{gd} - X_{id}) \\ X_{id} &= X_{id} + V_{id} \end{aligned} \quad (13)$$

式中, ω 为惯性因子, 其数值的变化可以改变局部寻优与全局寻优的结果。 C_1 和 C_2 则分别表示个体学习因子的加速常数和社会学习因子的加速常数, $random(0, 1)$ 则表示取 $0 \sim 1$ 之间的随机数。

在使用粒子群算法优化核函数极限学习机的过程中, 将 PSO 的优化参数与 KELM 的隐层偏差与输入权值相结合, 使用 KELM 学习样本的期望输出和实际输出的均方差误差作为 PSO 的适应值, 不断地优化迭代, 动态更新每个粒子的位置和速度, 当算法逐步运行到最大临界值, 此时种群的最大个体数即是最优个体, 以此往复训练, 最后即得到粒子的真实输出。由以上分析, 可得出 PSO 优化

KELM 步骤的算法流程如图 1 所示。

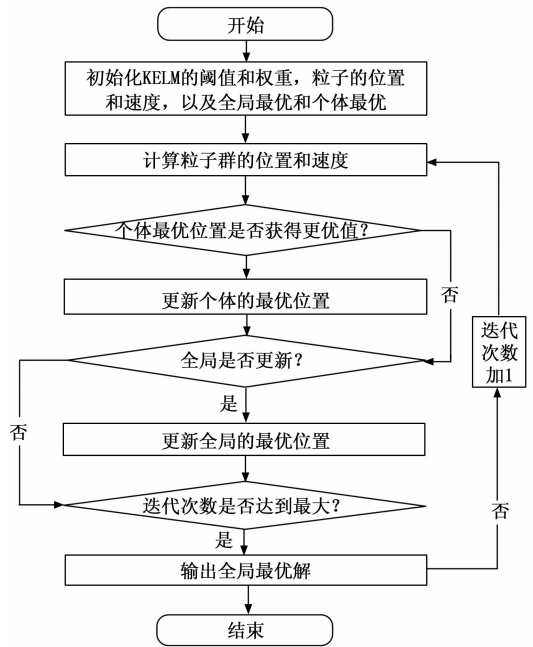


图 1 PSO 优化 KELM 过程

先初始化 PSO 的基本参数, 然后通过比较粒子的特征选择阈值和权重, 从而得到粒子选择的特征个数和特征输入, 再结合 KELM 参数值建立故障诊断模型, 对粒子的个体适应度确定后, 更新局部极值 P 和整体极值 G , 进而更新每个粒子的位置与速度, 重复以上步骤直到实现最大迭代次数, 输出 KELM 分类器和分类结果。

2 仿真实验分析

基于 EEMD 模糊熵和 PSO-KELM 的诊断流程如下:

- 1) 在 MATLAB/SIMULINK 平台上搭建 NPC 三电平逆变器仿真模型, 设置各种开路故障状况;
- 2) 采样逆变器输出端各类故障状态下的三相电压信号, 并对其作归一化处理;
- 3) 将采样好的电压信号, 通过 EEMD 进行本征模态分解, 得到若干个固有的模态分量, 再通过观察图像和相关系数法选取有效的 IMF 分量, 求取其相关的模糊熵, 即是 EEMD 模糊熵;
- 4) 将求解得到的所有 EEMD 模糊熵作为特征向量矩阵集划分为训练特征向量矩阵集和测试特征向量矩阵集;
- 5) 建立 KELM 模型, 并用 PSO 对其优化;
- 6) 将待测的训练特征向量矩阵集和测试特征向量矩阵集输入到优化好的 PSO-KELM 分类器中, 进行故障识别, 确定开关管以及相关器件的工作状态与故障情形;
- 7) 故障诊断后输出结果, 诊断率良好, 表明该诊断方法切实可行。

2.1 电路模型及其故障情形分析

NPC 三电平逆变器的拓扑结构如下:

主电路结构由 a, b, c 三相桥臂组成, 每相桥臂上包含 2 个钳位二极管, 4 个功率开关器件与续流二极管组成的电力电子设备, 每一相电路由中性点相连, 并在负载中性点 (N 点) 处交汇, 呈三相三线制, 总共包含 12 个以 IGBT 开

关管为主体的电力电子器件, 桥端的输出电压通常有正电压, 0 以及负电压。钳位二极管作为中点用于连接直流侧电容器与电源开关, LCL 滤波器则用于滤波从逆变器中输出的三相电压用于为系统供电。门信号作为驱动电源开关状态的方式, 电源打开时门信号为 1, 当电源关闭时门信号则为 0, 本文采用传统的 PWM 调制策略来控制门级信号, 从而决定逆变器的开关模式。

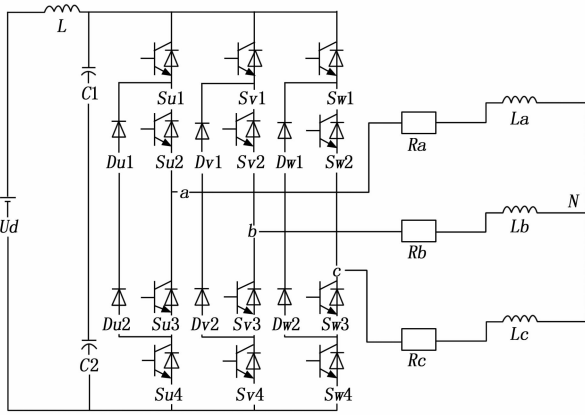


图 2 逆变器主电路拓扑

在运行过程中, 由于逆变器所处复杂的工作环境, 且频繁的开通与关断, 所以其中的开关管及相关器件发生故障在所难免, 故障可分为短路故障和开路故障, 由于电路自带保护电路, 所以短路故障往往影响不大, 而开路故障则因为相位开关器件所处位置的差异, 以及受损数目有所不同, 会造成逆变器整体输出的电压值紊乱从而影响系统的稳定运行。故障种类繁多复杂, 通常情况下, 3 个及其以上数目的开关器件同时发生故障的概率极低, 本文不作讨论, 因模型有 12 个 IGBT 开关管, 故单一发生故障的情形有 12 种, 同一相桥臂上两开关管同时发生故障的情形有 12 种, 交叉桥臂上两开关管同时发生故障的情形为 36 种, 上中下 3 个桥臂连同中性点之间构成 3 种故障情形, 将正常工作状况也视为一种特殊的故障情形, 总计 64 种故障情形, 因为 NPC 三电平逆变器在拓扑结构上符合严格的三相对称, 避免实验数据重复训练测试, 经灵敏度测试, 可得知实际故障有 22 种, 为了便于区分对其进行 5 位二进制编码, 如表 1 所示。通过采样各故障情形的三相电压值作为故障诊断的特征信号进行分析。

2.2 故障特征提取

采样时间设置为 1 s, 每类故障电压信号的单次采样点数为 1 000 个, 为了确保实验的客观有效性, 减少可能存在的实验误差, 对数据样本统一做归一化处理。对所有的故障电压信号样本采集完之后, 通过 EEMD 将其逐一分解成若干段本征模态分量, 因有 22 种故障情形, 故单列出 SU1 故障时刻的电压信号分解结果作为典型代表, 设置辅助的白噪声的标准差为原始标准差的 0.2 倍, 设定迭代次数 $M=100$, 图 3 为 SU1 开关管开路故障时刻电压信号 EEMD 的分解结果。

表 1 故障情形及 5 位二进制编码

序号	开关器件开路故障	编码
1	正常状况	00000
2	SU1 正向电压开路故障	00001
3	SV1 正向电压开路故障	00010
4	SW1 正向电压开路故障	00011
5	SU3 正向电压开路故障	00100
6	SV3 正向电压开路故障	00101
7	SW3 正向电压开路故障	00110
8	SU1 和 SV1 负向电压开路故障	00111
9	SU1 和 SW1 负向电压开路故障	01000
10	SV1 和 SW1 负向电压开路故障	01001
11	SU3 和 SV3 负向电压开路故障	01010
12	SU3 和 SW3 负向电压开路故障	01011
13	SV3 和 SW3 负向电压开路故障	01100
14	SU1 和 SV3 负向电压开路故障	01101
15	SU1 和 SW3 负向电压开路故障	01110
16	SV1 和 SU3 负向电压开路故障	01111
17	SV1 和 SW3 负向电压开路故障	10000
18	SW1 和 SU3 负向电压开路故障	10001
19	SW1 和 SV3 负向电压开路故障	10010
20	A 桥臂正向电压开路故障	10011
21	B 桥臂正向电压开路故障	10100
22	C 桥臂正向电压开路故障	10101




图 3 SU1 管故障电压分解情况

由 EEMD 分解图可见, EEMD 分解的电压故障信号逐次从高频到低频分解出 8 个 IMF 分量和一个余项, IMF1 到 IMF6 所包含的有效信息较之 IMF7 和 IMF8 要多, 且通过计算相关系数, 可以得知前面部分的 IMF 与原始信号相似度高, 因此选取前 6 个高频 IMF 分量更加能够达到准确表

征原始信号的目标，列出 SU1 管剔除无效分量后的 IMF 分布情况，同理可得出其他 21 种情况的有效 IMF。

表 2 SU1 管故障时刻电压信号有效 IMF 分布

IMF1	1.079	0.627	0.352	0.293	0.273	0.191	0.206	0.121
IMF2	0.705	0.906	0.707	0.593	0.485	0.344	0.283	0.253
IMF3	0.354	0.599	0.768	0.789	0.777	0.641	0.614	0.553
IMF4	0.092	0.169	0.226	0.279	0.332	0.381	0.427	0.459
IMF5	0.052	0.104	0.141	0.158	0.158	0.149	0.139	0.129
IMF6	0.028	0.056	0.083	0.107	0.128	0.143	0.155	0.165

根据多尺度模糊熵的计算步骤，选取前 6 个 IMF 分量，设置嵌入维数 m 为 4，相似容限 r 为 0.2 SD，模糊函数的梯度 n 选取为 3。由多尺度模糊熵的计算公式，对该模式分量可以得出其相关的 EEMD 模糊熵，构成的矩阵维度为 1×3 。由此推广，对 22 种故障情形分别叠加 100 次的高斯白噪声，将计算得到的模糊熵进行排列组合，最终得到 $22 \times 100 \times 1 \times 3$ 维度的矩阵作为故障特征向量，为了对各类故障进行合理的区分，将 EEMD 模糊熵提取得到的数据样本集做三维投影，箭头 EE 表示每一类故障的具体分布，如图 4 所示。

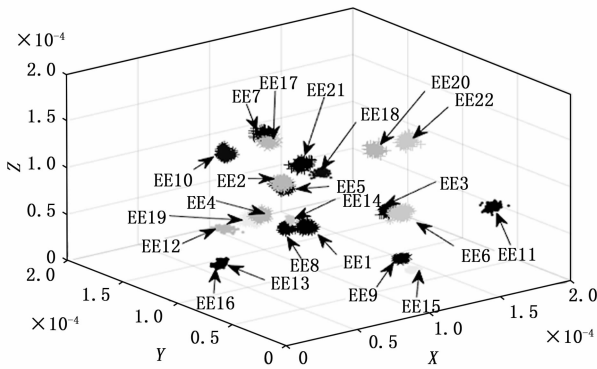


图 4 EEMD 模糊熵分布

由图 4 观察，不难发现各类故障所对应的 EEMD 模糊熵有着明显的区分度，存在较大差异，适用于后续分类器模型的训练和测试。

2.3 基于 PSO-KELM 的故障分类识别

经过模糊熵的计算后，将所有故障情形下的 EEMD 模糊熵的值作为特征向量矩阵集，故障类型有 22 种，故设置 22 个故障标签依次标记为 1~22，每种故障为 100 组 1×3 的数据，可得总数据集为 2 200。首先将数据集划分为训练特征向量矩阵集和测试特征向量矩阵集，随机选取每类故障的前 50 组数据依次叠加 22 次组成总计 1 100 组数据集作为训练特征向量矩阵集，同理划分剩余的数据集作为测试特征向量矩阵集使用。把训练特征向量矩阵集输入到 PSO-KELM 分类器中，对其进行训练，完成故障诊断模型的建立，将测试特征向量矩阵集输入到故障诊断模型中，测试相关的准确率，最后的分类结果作为评价分类器优劣的性能指标。

本文使用 PSO 对 KELM 进行参数优化和验证利用 PSO 可以提高对故障数据集的搜索能力和延展性。设置 PSO 的相关参数，个体学习因子加速常数 c_1 初始值为 1.5，社会学习因子加速常数 c_2 初始值为 1.7，迭代次数 $G=100$ ，终止代数 $pop=20$ 。令 KELM 分类器的隐层神经元节点的个数为 L ，选取 $L=20$ ，设置 KELM 的核函数类型为径向基核函数 (RBF kernel, radial basis function)，最为重要的两个实验参数分别是核函数参数 g 与正则项系数 c ，通过对 KELM 的多次训练，根据实验数据的对比，得出最优的核函数参数 g 为 $8.883\ 94e+06$ ，最优正则项系数 c 为 $93.490\ 4$ 。实验测试结果如图 5 所示，此时 PSO-KELM 的分类效果达到最佳，故障诊断的测试精度达到 98.454 5%，实验结果理想，表明该方法切实可行，分类效果较好。




图 5 PSO-KELM 模型诊断结果

为了避免 PSO-KELM 在实验过程中所实现的诊断率存在偶然性，故对此进行 10 次独立实验，并且统计如表 3 所示。

表 3 PSO 运行适应度曲线

序号	最优正则项系数 c	核函数参数 g	故障诊断率 %
1	248.923	$1e-06$	98.363 6
2	717.419	$4.288\ 93e+06$	98.272 7
3	499.465	$8.604\ 53e+06$	97.818 2
4	231.964	$9.195\ 22e+06$	97.090 9
5	39.628 3	$4.543\ 92e+06$	98
6	93.490 4	$8.883\ 94e+06$	98.454 5
7	54.000 4	$5.657\ 64e+06$	97.090 9
8	634.196	$2.420\ 18e+06$	98.181 8
9	567.104	$4.183\ 14e+06$	98.090 9
10	703.041	$8.479\ 26e+06$	98.181 8
平均值	—	—	97.954 53

总体来说，PSO 方法在减少了更多的训练时间前提下，且保证了 KELM 能够选择更少的训练特征向量矩阵集时，依然能够保证较高的故障诊断准确率。图 6 表明了 PSO 独立运行 10 次后统计得到的诊断率以及相对应的诊断率的平均值情况。




图 6 PSO-KELM 运行 10 次的结果

验证本文提出的基于 EEMD 模糊熵和 PSO-KELM 诊断方法的客观性与准确性, 在仿真实验中, 将进行过特征提取的 EEMD 模糊熵输入到随机森林 (RF, random forest), SVM 这两种分类器中, 再使用模糊熵提取故障特征向量, 输入到上述两种分类器和 PSO-KELM 中, 划分相同形式的训练集和测试集, 在完全一致的实验条件下进行对比分析, 不同的故障诊断方法的诊断结果如表 4 所示。

表 4 故障方法性能对比

编号	方法	诊断率/%
1	EEMD 模糊熵和 PSO-KELM	98.454 5
2	EEMD 模糊熵和 SVM	95.252 5
3	EEMD 模糊熵和随机森林	95.181 8
4	模糊熵和 PSO-KELM	92.646 4
5	模糊熵和 PSO-KELM	92.272 7
6	模糊熵和随机森林	89.2

与其他诊断方法的比较中不难得出, EEMD 模糊熵与 PSO-KELM 相结合的故障诊断率优于其他方法, 说明其提取的故障特征向量区分度更高, 分类器的实验效果更为准确, 可以客观全面的反映 NPC 三电平逆变器的开路故障状态。

3 结束语

本文提出一种基于 EEMD 模糊熵和 PSO-KELM 的针对 NPC 三电平逆变器单一器件开路以及多器件同时开路的故障诊断方法。通过采样 NPC 三电平逆变器的多路电压信号, 使用 EEMD 模糊熵进行故障特征提取, 归一化后得到实验数据集, 将其输入到 PSO-KELM 中。诊断结果表明, 算法的数据搜索性能强大, 延展性好, 易于实现, 训练测试得到最优的故障诊断率为 98.454 5%, 故障识别精度较好。在相同的实验条件下进行对比实验分析, 诊断能力均优于其他方法, 且适用于多类故障情形, 抗噪声能力强, 符合 NPC 三电平逆变器的在线诊断要求。

参考文献:

[1] 陈丹江, 叶银忠. 基于多神经网络的三电平逆变器器件开路故障诊断方法 [J]. 电工技术学报, 2013, 28 (6): 121-126.

[2] 马成才, 顾晓东. 基于神经网络组与故障分级的故障诊断 [J]. 系统工程与电子技术, 2009, 31 (1): 225-228.

[3] 韩世军, 朱菊, 毛吉贵, 等. 基于粒子群优化 SVM 的变压器故障诊断 [J]. 电测与仪表, 2014, 51 (11): 71-75, 90.

[4] 袁圃, 毛剑琳, 向凤红, 等. 改进的基于遗传优化 BP 神经网络电网故障诊断 [J]. 电力系统及其自动化学报, 2017, 29 (1): 118-122.

[5] 沈艳霞, 吴娟, 赵芝璞, 等. 三电平逆变器多故障模式识别方法 [J]. 系统仿真学报, 2017, 29 (7): 1447-1456

[6] 樊春玲, 赵慧超, 陈秀霆. 基于 EMD 多尺度能量熵的气液两相流型表征 [J]. 华东理工大学学报, 2014, 40 (1): 81-85.

[7] 姜媛媛, 程浩, 崔江, 等. VMD 小波能量的光伏逆变器软故障诊断 [J]. 电力系统及其自动化学报, 2018, 30 (11): 19-25.

[8] LI X, MAO W, WEI J. Extreme learning machine based transfer learning for data classification [J]. Neurocomputing, 2016, 174: 203-210.

[9] 何星, 王宏力, 陆敬辉, 等. 基于优选小波包和 ELM 的模拟电路故障诊断 [J]. 仪器仪表学报, 2013, 34 (11): 2614-2619.

[10] 陶洪峰, 周超超, 杨慧中. 基于 EMD-DTRVM 方法的三电平逆变器故障诊断 [J]. 控制工程, 2019, 26 (12): 2291-2298.

[11] 黄大荣, 陈长沙, 孙国玺, 等. 电力变压器故障的客观熵权识别及诊断方法 [J]. 电力系统及其自动化, 2017, 41 (12): 206-211.

[12] 朱大奇, 刘永安. 故障诊断的信息融合方法 [J]. 控制与决策, 2007, 22 (12): 1321-1328.

[13] 项文强, 张华, 王姮, 等. 基于 L-M 算法的 BP 网络在变压器故障诊断中的应用 [J]. 电力系统保护与控制, 2011, 39 (8): 100-111.

[14] 吴广宁, 袁海满, 高波, 等. 基于特征评估与核成分主元分析的电力变压器故障诊断 [J]. 高电压技术, 2017, 43 (8): 2533-2540.

[15] 高国强, 杨飞豹, 尹豪杰, 等. 基于代价敏感组合核相关向量机的电力变压器故障诊断 [J]. 电测与仪表, 2017, 54 (16): 7-13.

[16] 徐牧. 基于 SVM 的变压器故障诊断研究 [D]. 淮南: 安徽理工大学, 2017.

[17] 公茂法, 柳岩妮, 王来河, 等. 基于混沌优化粒子群 BP 神经网络的电力变压器故障诊断 [J]. 电测与仪表, 2016, 53 (15): 13-16, 32.

[18] 房立清, 吕岩, 张前图, 等. 基于半监督邻域自适应 LLT-SA 算法的故障诊断 [J]. 振动与冲击, 2017, 36 (13): 189-194.

[19] 汤清泉, 颜世超, 卢松升, 等. 三电平逆变器的功率管开路故障 [J]. 中国电机工程学报, 2008, 28 (21): 26-32.

[20] 刘永斌, 龙潜, 冯志华, 等. 一种非平稳, 非线性振动信号检测方法的研究 [J]. 振动与冲击, 2007, 26 (12): 131-134.

(下转第 108 页)