

基于 SMA-VMD 和优化神经网络的 逆变器开关故障诊断*

李冉¹ 邢砾云¹ 庞娜¹ 沈建强² 王策¹

(1. 北华大学电气与信息工程学院 吉林 132021; 2. 国网辽源供电公司 辽源 136200)

摘要: 为解决基于电流的中点箝位式三电平逆变器开路故障诊断易受负载变化影响的问题,本文从提升故障特征区分度入手,首先,基于 SMA 优化 VMD 的最佳模态数 K 及惩罚系数 α ,改善模态混叠现象,提高了故障特征的独立性。其次,基于小波包能量分布相对平稳,能有效克服负载影响的特点,将各 IMF 的两层小波包能量最大值作为故障特征量,在克服负载影响的同时,使时频特征信息更集中,进一步提高了故障特征区分度。最后,将上述故障特征应用于神经网络进行训练,并引入 SSA 对模型的权值和阈值进行优化,解决了模型局部最优问题,提升了故障辨识的准确性。通过 NPC 三电平逆变电路模拟 17 种开路故障的仿真实验,结果表明,该方法的诊断准确率达到 98.99%,适用于变负载工况下 NPC 三电平逆变器在线故障诊断。

关键词: NPC 三电平逆变器;开路故障诊断;VMD;小波包能量;神经网络

中图分类号: TN306 **文献标识码:** A **国家标准学科分类代码:** 470.40

Fault diagnosis based on SMA-VMD and optimization of neural networks for NPC three-level inverters

Li Ran¹ Xing Liyun¹ Pang Na¹ Shen Jianqiang² Wang Ce¹

(1. College of Electrical and Information Engineering, Beihua University, Jilin 132021, China;

2. State Grid Liaoyuan Power Supply Company, Liaoyuan 136200, China)

Abstract: In order to solve the problem that the current-based midpoint-clamped three-level inverter open-circuit fault diagnosis is easily affected by the load changes, this paper mainly improves the accuracy from the fault feature differentiation. Firstly, VMD improves the modal aliasing phenomenon, and its optimal modal number K and penalty coefficient α are optimized by SMA, which improves the independence of fault features. Second, due to the relatively smooth distribution of wavelet packet energy, which can effectively overcome the characteristics of load influence, the maximum value of the two-layer wavelet packet energy of each IMF is taken as the fault feature quantity, so that the time-frequency feature information is more centralized which further improves the fault feature differentiation without the influence of varying loads. Finally, the fault features are applied to the neural network for training, and the weights and thresholds of the model are optimized by SSA, which solves the problem of local optimum of the model and improves the accuracy of fault identification. Through the simulation experimental results of 17 open-circuit faults in the NPC three-level inverter circuit model, the diagnostic accuracy of this method reaches 98.99%, which is applicable to the online fault diagnosis of NPC three-level inverters under variable load conditions.

Keywords: NPC three-level inverter; open circuit fault diagnosis; VMD; wavelet packet energy; neural network

0 引言

在国家“碳达峰”与“碳中和”的战略指引下,光伏发电技术作为清洁能源的重要支柱,其相关技术的研究日益受到瞩目^[1-2]。中点箝位(neutral point clamped, NPC)三电平

逆变器作为光伏发电系统与电网之间的关键桥梁,对于电力系统的稳定与可靠运行具有至关重要的作用^[3]。由于其具备损耗低、效率高和可靠性强的显著优势,三电平逆变器在并网逆变器中得到了广泛应用^[4-5]。然而,其电路结构复杂,开关数量多,工作频率较高,易发生故障^[6]。因此,深入

收稿日期:2024-04-02

* 基金项目:吉林省科技发展计划项目(YDZJ202201ZYTS601)、吉林省教育科学“十四五”规划 2022 年度重点课题(ZD22091)、国家自然科学基金(42004153)、北华大学青年科技创新团队项目(202016003)资助

研究 NPC 三电平逆变器开关故障诊断方法,对于确保电网的安全稳定运行具有重要的实践意义和理论价值^[7-8]。

相较于其他诊断手段,基于信号分析的诊断方法通过深入分析逆变器电路输出的电压和电流信号来进行故障识别,其诊断结果的可靠性得以提升^[9-10]。而基于电压的诊断方法需要额外增加传感器,电流诊断方法虽无需增加额外的硬件,但非线性负载对诊断准确率影响较大^[11-13]。

为了解决负载变化对电流诊断准确性的影响,关键在于降低负载变化对于电流信号特征辨识的影响。可见,电流信号特征的有效提取与准确辨识尤为重要。

变分模态分解(variational mode decomposition,VMD)分解非线性非平稳电流信号时,有效地解决了模态混叠的问题^[14]。但是 VMD 参数的不恰当选取导致了特征冗余或者失真^[15]。小波分析技术能够精确地捕获信号的时频特性^[16-17],而基于小波能量分布的故障信号表示方法在负载发生变化时仍能保持其特征的稳定性,但小波变换对尺度的依赖性较强,往往导致不同故障类型的能量值接近^[18]。而由于小波包变换能自适应地选取小波基函数并且在信号中频带选取得更加细致,所以小波包能量提取特征就成为在负载变化下改善特征区分度有效方法。但有效的特征提取是准确辨识的基础,基于反向传播(back propagation,BP)神经网络辨识方法可准确辨识开关故障位置^[19],但是模型训练过程中会出现局部最优,收敛速度慢等问题。

综上所述,针对信号在变负载时特征区分度低、诊断准确率低的问题,在负载变化时对逆变器输出的三相电流信号进行 VMD 分解的基础上,进行多次高低频信号分解,并对本征模态分量(intrinsic mode function,IMF)提取小波包能量,选特征信息更集中的能量值作为故障特征。将神经网络应用于逆变器故障开关位置诊断中,最后通过仿真实验证明所提方法具有鲁棒性与有效性。

1 NPC 三电平逆变器电路拓扑与故障类型

本研究以 NPC 三电平逆变器开关开路故障诊断为对象进行研究,依据发生故障的开关位置,对所有故障类型进行了归类梳理,由于逆变器在拓扑结构上的对称性,三相且上下桥臂工作原理类似,将故障类型合并归纳为 17 个,以便在后续的特征提取及故障识别步骤有针对性的进行相应算法的选择与设计。

NPC 三电平逆变器的拓扑结构如图 1 所示。由图 1 可以看出,NPC 三电平逆变器结构复杂,由 12 个绝缘栅双极型晶体管(insulated gate bipolar transistor,IGBT),6 个钳位二极管,12 个反向并联的续流二极管和 2 个分压电容组成,直流侧电压 U_d 为 380 V,交流侧输出接电网。在运行过程中,IGBT 需要频繁地进行快速开通与关断,导致温度升高,引发故障。

通常,逆变器电路中不超过两个 IGBT 同时发生故障。因此,故障类型可分为单管故障和双管故障。单管故障有

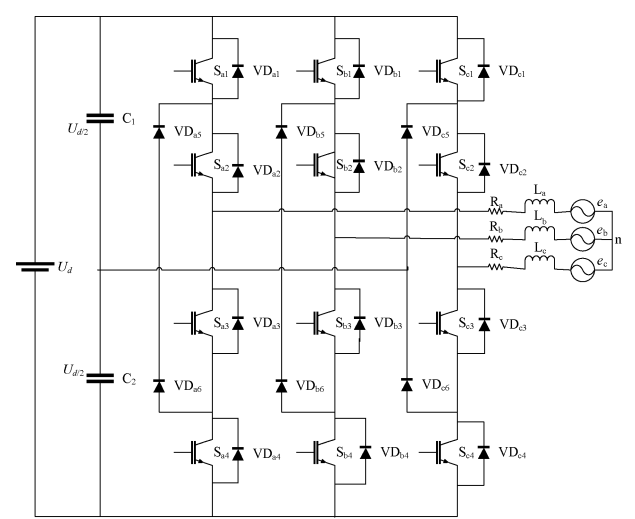


图 1 NPC 三电平逆变电路拓扑结构

12 种,由于电路三相对称,仅研究 A 相的 4 个 IGBT,即分为 4 种故障类型。对于双管故障,共有 $C_{12}^2 = 66$ 种故障。由于上下桥臂对称,且 Sa2 单管故障以及 Sa1 和 Sa2 双管故障有相同的输出电流拓扑结构,即同相同桥的双管 IGBT 故障暂不计入研究。A 相上同相不同半桥的双管 IGBT 同时故障 $C_2^1 C_1^1$,即 4 种故障类型,异相即 A 相和 B 相上同半桥的双管 IGBT 发生故障 $C_2^1 C_2^1$ 和不同半桥的双管 IGBT 故障 $C_2^1 C_2^1$,可分别分为 4 种故障类型。故仅研究单管 IGBT 的 4 种故障和双管 IGBT 的 12 种故障,并引入无故障工况进行研究,共计 17 种故障类型,其故障分类如表 1 所示。

表 1 故障类型

故障类型	故障大类	故障的 IGBT
F01	无故障	无故障
F02	单管 IGBT 发生故障	Sa1
F03		Sa2
F04		Sa3
F05		Sa4
F06	同相不同半桥的双管 IGBT 同时发生故障	Sa1Sa3
F07		Sa1Sa4
F08		Sa2Sa3
F09		Sa2Sa4
F10	异相同半桥的双管 IGBT 同时发生故障	Sa1Sb1
F11		Sa1Sb2
F12		Sa2Sb1
F13		Sa2Sb2
F14	异相不同半桥的双管 IGBT 故障	Sa1Sb3
F15		Sa1Sb4
F16		Sa2Sb3
F17		Sa2Sb4

通过 Matlab 的 Simulink 仿真模块建立 NPC 三电平逆变器电路仿真模型,无故障和部分开路故障情况下的三相电流 I_A 、 I_B 、 I_C ,波形如图 2 所示。

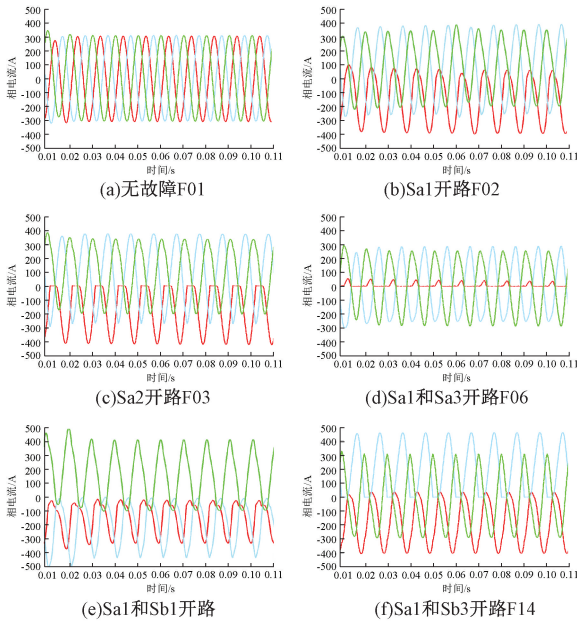


图 2 三相电流波形

通过比较图 2(a)与图 2 中的其他波形,三电平逆变器 IGBT 的开路故障会导致输出三相电流出现不同程度的畸变,而不同位置的 IGBT 出现故障时,输出电流的电平特性会有明显的不同,进而区分出这 17 种故障类型。

2 基于 VMD-小波包能量的故障特征提取

电流信号的电平属性揭示了不同故障模式的特征,这可以作为故障检测的重要依据。然而,由于电流信号呈现出非线性非平稳的特性,仅仅依赖电平逻辑是不足以进行多故障模式的高精度诊断。而 VMD 技术能够选取不同 K 值,来确定 IMF 的频率中心和带宽,实现信号频带的有效分离,揭示信号的奇异性,并捕捉故障信号中频域信息的微妙变化。IMF 确定了各个频带内响应信号的小波包能量分布,因此可以使用各 IMF 分解的频带小波包能量作为故障的特征信息。

2.1 VMD 分解信号

在进行 VMD 分解时,确定了每个 IMF 的实际带宽和最理想的中心频率,这有助于有效地将信号分解为多个 IMF。约束条件要求 IMF 之和等同于原始信号,那么相应的约束条件的表达式为:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_{k=1}^K u_k = f(t) \end{cases} \quad (1)$$

将约束条件转化为非约束性变分问题,利用 *Lagrange* 函数,使表达式为:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \quad (2)$$

式中: α 是惩罚因子, λ 为 *Lagrange* 系数。

即 IMF 和中心频率的表达式为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k}^K \hat{u}_i^n(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (4)$$

式中: $\hat{u}_k^{n+1}(\omega)$ 是更新后得到的 IMF, ω_k^{n+1} 是更新后的中心频率,傅里叶变换得到 $\hat{f}(\omega)$ 、 $\hat{u}_i^n(\omega)$ 、 $\hat{\lambda}^n(\omega)$ 、 $\hat{u}_k^n(\omega)$, n 为迭代次数。

为了提升 VMD 在复杂数据分解中的精确度,对模态数 K 和惩罚因子 α 进行合理设置。由于 K 对分解效果有显著影响, K 太小难以获取足够的故障信息,而 K 太大在增加工作量的同时又会导致过度分解,因此采用黏菌算法 (slime mould algorithm, SMA) 优化 VMD 的 K 值和惩罚系数 α 。

2.2 SMA 优化 VMD 的 K 值和惩罚因子 α

SMA 是一种基于黏菌觅食行为的优化算法,它在解决寻找最优解的问题时表现出快速收敛和精确找到最优值的特点^[20]。因此,本研究利用 SMA 优化 VMD 中的 K 和 α ,以提高 VMD 在复杂数据分解中的性能。

黏菌有 3 种行为:接近食物,包裹食物和获取食物。建立黏菌各种行为的数学模型,黏菌位置更新的公式为:

$$X(t+1) = \begin{cases} \text{rand} \cdot (U_B - L_B) + L_B, & \text{rand} < z \\ X_b(t) + v_b \cdot (W \cdot X_A(t) - X_B(t)), & \text{rand} < p \\ v_c \cdot X(t), & \text{rand} \geq p \end{cases} \quad (5)$$

式中: U_B 和 L_B 为搜索范围的上限和下限; rand 为 $[0,1]$ 中的随机值; z 是自定义参数; v_b 为 $[-a, a]$ 中的随机数; v_c 是在 $[-1,1]$ 之间振荡最终趋于 0 的参数; t 是此时的迭代次数; $X_b(t)$ 为目前的适应度最优个体的位置; $X(t)$ 是此时黏菌个体的位置; $X_A(t)$ 和 $X_B(t)$ 是两个随机个体位置; W 是黏菌的权重系数。

控制参数 p 的公式为:

$$p = \tanh |S(i) - DF| \quad (6)$$

式中: $i \in 1, 2, 3, \dots, n$, $S(i)$ 为第 i 个黏菌的适应度值; DF 是此时取得的最佳适应度值。

参数 v_b 的公式为:

$$a = \operatorname{arctanh}\left(1 - \left(\frac{n}{\max_n}\right)\right) \quad (7)$$

式中: \max_n 是最大迭代次数。

权重系数 W 的公式为:

$$W(\operatorname{SmellIndex}(i)) = \begin{cases} 1 + r \cdot \log\left(\frac{bF - S(i)}{bF - wF} + 1\right), & \text{condition} \\ 1 - r \cdot \log\left(\frac{bF - S(i)}{bF - wF} + 1\right), & \text{others} \end{cases} \quad (8)$$

$$\operatorname{SmellIndex} = \operatorname{sort}(S) \quad (9)$$

式中: condition 是种群中适应度的前一半个体; others 是剩下的个体; bF 是当前迭代过程里可以获取的最佳适应度值; wF 是当前迭代过程里获取的最差的适应度值; $\operatorname{SmellIndex}$ 是适应值序列。

由于样本熵 (sample entropy, SE) 通过非负数对时间序列的复杂特征进行度量的特性, VMD 分解的 IMF 的与原信号相似度越高, 样本熵值就越小, 表示其包含的故障信息越多。如图 3 所示为 SMA 优化 VMD 的 K 值和惩罚系数 α 的流程图。

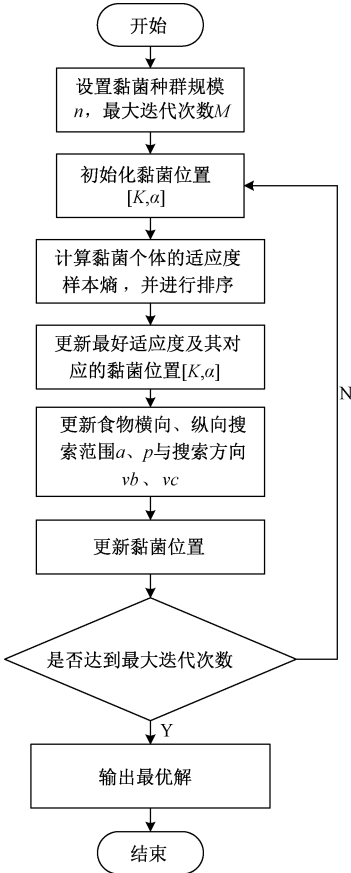


图 3 寻优流程图

SMA 算法进行参数寻优的步骤如下:

步骤 1) 初始化 SMA 参数。设定种群规模 n , 目标函数的维数 d , $[K, \alpha]$ 的优化范围以及最大迭代次数。

步骤 2) 计算每个黏菌位置 $[K, \alpha]$ 相应的 K 个适应度值, 选用样本熵作为适应度值。然后对适应度值进行排序, 选出最优和最差适应度值。

步骤 3) 更新黏菌位置。由式 (8) 所示, 计算权重 W , 据此更新当前最佳个体位置及适应度值, 随后更新 a 。

步骤 4) 判断是否已经达到最大迭代次数, 若是, 循环结束, 输出最优黏菌位置 $[K, \alpha]$ 和最优适应度值; 若否, 则返回步骤 2)。

2.3 小波包能量提取

小波包分解对信号进行多级频带细分的技术, 每次分解将当前频带划分为两个子频带。通过对频段信号进行重构, 获得的频带分量构成了原始信号的频域表示。通过观察频带分量的能量, 为后续的特征提取提供了有力的支持。

信号经过小波包 i 层分解, 得到 2^i 个频段信号。将第 i 层中 j 个频段信号分别记为: $\{S_3^0, S_3^1, S_3^2, L, S_i^j\}$, 总信号为这些频段信号之和:

$$S = \sum_{j=0}^n S_i^j \quad (10)$$

计算各频段信号的能量, 将第 i 层中 j 个频段信号的能量记为 E_i^j , 即:

$$E_i^j = \int |S_i^j(t)|^2 dt \quad (11)$$

则特征向量 H 可表示为: $H = [E_1^1, E_1^2, E_1^3, L, E_i^j]$ 。

为减少运算复杂性, 提高诊断速度, 可将能量最大值作为光伏逆变器的故障特征向量。

3 基于优化 BP 神经网络的故障辨识

将故障特征向量输入 BP 神经网络中, 以进行故障辨识。

BP 神经网络有良好的非线性拟合性能, 易于实现。然而, 它在故障诊断中的应用往往收敛缓慢, 全局搜索性能较差, 易陷入局部极小值。针对神经网络的不足, 结合麻雀搜索算法 (sparrow search algorithm, SSA) 选择优质个体、信息传递, 通过全局搜索和局部搜索等机制确保后期收敛的准确性和稳定性; 通过变异机制以自适应可变概率进行的个体变异, 帮助个体摆脱局部最优, 进一步寻找全局最优解, 如文献 [21]。其过程为:

步骤 1) 初始化麻雀种群位置和适应度。

步骤 2) 对种群进行排序, 得到目前麻雀的最佳个体位置和最佳适应度值。

步骤 3) 觅食, 设定最大迭代数 N , 种群大小 n , Q 为服从正态分布的随机数; L 是单位行向量; 安全值 ST , 警告值 R_2 , a 为 $[0, 1]$ 里的随机数。根据以下公式对发现者位置进行更新:

$$X_{ij}^{t+1} = \begin{cases} X_{ij}^t \cdot \exp\left(\frac{-i}{a \cdot N}\right), & R_2 < ST \\ X_{ij}^t + Q \cdot L, & R_2 > ST \end{cases} \quad (12)$$

步骤 4) 更新新个体位置, 公式如下:

$$X_{ij}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{worst}^t - X_{ij}^t}{i^2}\right), & i > \frac{n}{2} \\ X_P^{t+1} + |X_{ij}^t - X_P^{t+1}| \cdot A^+ \cdot L, & i \leq \frac{n}{2} \end{cases} \quad (13)$$

式中: X_{worst} 是适应度最低的麻雀的位置; A^+ 是只包含 1 与 -1 的行向量。

步骤 5)反捕食行为,更新麻雀的种群位置:

$$X_{ij}^{t+1} = \begin{cases} X_{best}^t + \beta \cdot |X_{ij}^t - X_{best}^t|, & f_i > f_{best} \\ X_{ij}^t + K \left(\frac{|X_{ij}^t - X_{worst}^t|}{f_i - f_{worst} + \epsilon} \right), & f_i = f_{best} \end{cases} \quad (14)$$

式中: K 是 $[-1,1]$ 中的随机数, f_i 为适应度值。 E 为接近 0 的常数。

步骤 6)更新最小适应度。适应度值是分类错误率,适应度值越小即训练越准确,精度越好。

步骤 7)判断是否达到最大迭代次数,若是,结束循环,输出最优权值和阈值,若否,执行步骤 2)~6)。

SSA 优化 BP 神经网络流程,如图 4 所示。

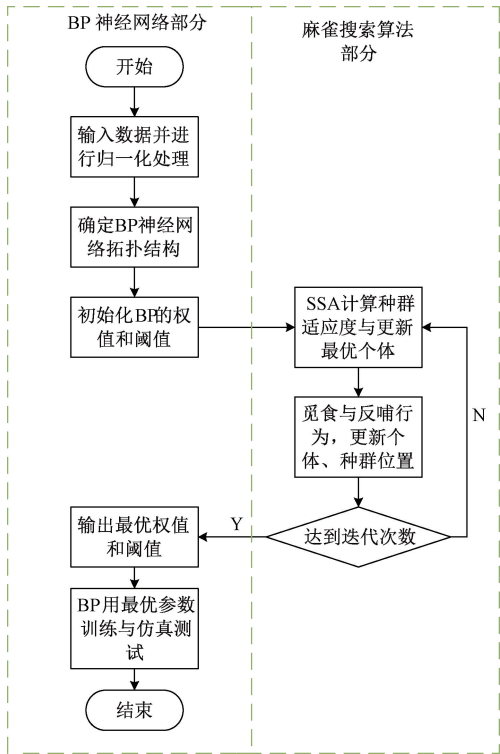


图 4 SSA 优化神经网络权值和阈值流程图

4 仿真结果与分析

为了验证本研究提出的 NPC 三电平逆变器开关开路故障诊断方法的可行性和准确性,依据图 1 的 NPC 三电平逆变器电路的拓扑结构,在 Simulink 环境中构建了相应的逆变器电路模型,如图 5 所示。在此模型基础上,通过设定不同位置 IGBT 脉冲信号的导通和截止状态,以模拟 17 种

不同位置的 IGBT 开路故障。获取交流侧三相电流数据 I_A 、 I_B 、 I_C ,其中采样时间为 0.1 s,其他参数分别设置如表 2 所示。




图 5 NPC 三电平逆变器电路模型

表 2 仿真参数

物理量	参数
电网电压/频率	380 V/50 Hz
逆变器直流侧参考电压	750 V
逆变器直流侧电容	100 μ F
网侧电感	0.2 mH
采样频率	10 kHz
负载电阻 R	0.2 Ω
种群数量	70
最大遗传代数	50
交叉概率	0.7
变异概率	0.01
控制步数	2
预测步数	10

4.1 样本信号及特征量的提取

通过开关闭合设置 12 个 IGBT 的 17 个故障类型,并在故障点交流侧采集三相电流信号 I_A 、 I_B 、 I_C ,每个样本采集 2 000 个数据,每种故障选取 200 组样本信号。

由于 VMD 参数的设定对分解结果具有显著影响,当参数设置过大导致信号过分解;而参数设置过小引发模态混叠等问题。为了找到最佳的参数组合,并提高 VMD 分解的精度,采用 SMA-VMD 自适应分解原始信号,设置 SMA 参数,即初始种群数量设为 30,迭代次数为 30 次,模态数 $K \in [4,10]$,惩罚因子 $\alpha \in [500,3\ 000]$,收敛曲线如图 6 所示,适应度为样本熵。除了本文的方法外,采用中遗传算法(genetic algorithm, GA)优化 VMD 参数^[22],设置如下:初始种群为 20,迭代次数为 100,交叉概率为 0.8,突变概率为 0.1。

如图 6 所示,GA 优化 VMD 参数时信号序列的样本熵在迭代过程中诊断错误率下降缓慢,且有波动,最终样本熵

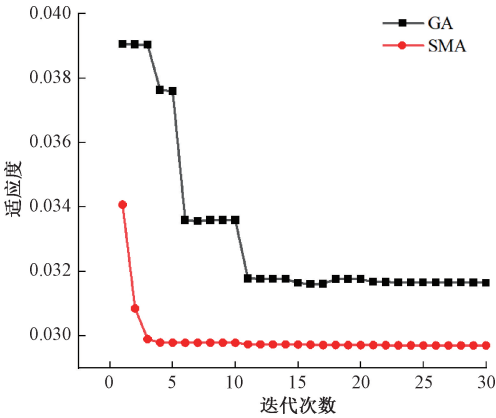


图 6 VMD 参数优化的迭代曲线

稳定在 0.034。相比之下,随着迭代次数的递增,SMA 优化 VMD 参数时信号序列的样本熵呈现显著下降趋势,并在第 12 次迭代后稳定在 0.029 的水平,在整个过程中保持平稳,无显著波动。这一提升不仅表现出黏菌能够在搜索空间中快速找到潜在的最优解区域,并通过自组织和自适应能力不断调整搜索策略,从而提高搜索效率,展示了 SMA 在优化过程中的高效性,也证明了 SMA 具有更出色的寻优能力。因此,对每个工况下参数 K 和 α 寻优,结果如表 3 所示。

表 3 17 种工况下对应的参数 K 和 α

故障类型	模态数 K	惩罚因子 α
F01	6	1 956
F02	6	1 831
F03	7	1 864
F04	6	1 782
F05	6	1 691
F06	7	1 756
F07	6	1 837
F08	6	1 824
F09	6	1 223
F10	6	1 542
F11	6	1 065
F12	6	1 737
F13	6	951
F14	6	1 256
F15	6	2 837
F16	6	2 311
F17	6	1 981

由表 3 可以看出除了 F03 和 F06 模态个数 $K=7$,其他工况的 K 都为 6,因此设定最佳 $K=6$,计算 17 种工况下

α 的平均值作为最佳惩罚因子 α 为 1 732。将优化的结果作为 VMD 分解的参数对仿真信号进行分解,利用优化后的参数对仿真信号进行分解,以 F02 的 A 相电流为例进行分析,如图 7 所示为默认参数下的频谱图和经过 SMA 优化参数后的 IMF 对应频谱图。

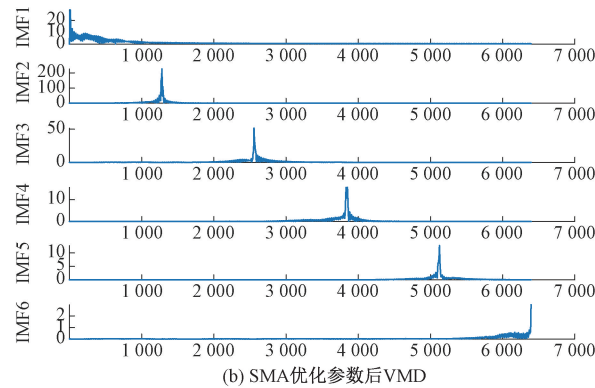



图 7 频谱图

如图 7 所示,SMA 优化 VMD 参数的频谱图中新增了 IMF6 分量。从幅值上看,这一分量能够有效地表征原信号的特征,而在使用 VMD 默认参数时,这一重要特征却被忽视了。此外,SMA 优化 VMD 参数的频谱图中,中心频率并未出现混叠现象,说明不同频率成分得到了有效的分离。每个 IMF 之间相互独立,没有冗余,特征向量相互正交。证明了 SMA 优化参数后能够更好地体现原信号的特征。

在多次试验过程中,不同小波包基函数的特征提取结果并无显著差异。因此选取小波包基函数 db3 进行 2 层分解,每个 IMF 得到 4 个能量值。具体的分解结果如表 4 所示。

由表 4 可知,以 IMF1 为例,D4 能量值最大且比其他能量值大很多,意味着它与原信号的相关性最高,相比之下其他 3 个能量包含故障信息极少,所以选择最大能量值作为故障特征量。因此,每个 IMF 的故障特征量从 4 个简化为了 1 个,从而使每个信号分解得到的 6 个 IMF 的 4×6 个

表 4 IMF 的小波包能量

IMF	D1	D2	D3	D4
IMF1	10.065 6	13.165 64	638.466 6	24517.91
IMF2	47.398 3	18 267.53	25 317.41	54.033 49
IMF3	14 669.3	43 312.26	2 676.050	653.951 9
IMF4	160 191	3 789.576	3 789.576	80.181 92
IMF5	13 236.7	121.735 2	8.565 865	3.441 003
IMF6	15 814.5	59.116 13	7.071 483	2.045 379

故障特征降低到了 6 个,显著减少了特征量的个数,降低数据冗余。图 8 是 VMD 和 VMD-小波包能量的 IMF1 的时频对比。





图 8 IMF1 的时频图对比

如图 8(a)所示,各个频率成分的界限并不清晰,这可能导致对故障特征的识别不够精确,所以引入了小波包能量对 IMF 进行进一步的分解。如图 8(b)所示,信号被更准确地分解为不同频率的子带,能量的分布也更为精细。可见 VMD-小波包能量更精确地表征故障特征,为后续的故障诊断提供了更为可靠的依据。

当负载增加时,逆变器需要提供更多的能量来维持负载的正常工作,交流侧输出三相电流会增加。由于逆变器采用了双闭环控制,保证了逆变器在负载变化时可以平稳过渡到新的状态,即本文只考虑负载变化对电流幅值的影响。如图 9 所示,由于负荷变化,三相电流幅值发生变化,进入暂态过程,产生虚警。

图 9 负载电阻 0.01 s 时为 0.02 Ω 并在 0.06 s 时增加至 0.2 Ω

由于小波包分析可以根据信号的特性和分析要求自适应地选择频带,因此可以更加精确地定位并抑制这些暂态

成分,使小波包能量分布在不同频率子带上的特征相对稳定。为验证负载变化对本方法的影响,对逆变器 F02 状态进行 3 种工况下的采样,将负载电阻 R 分别设置如为 0.02 Ω ,0.01 s 时 0.02 Ω 且在 0.06 s 时增加至 0.2 Ω ,0.2 Ω ,图 10 是 F02 时不同负载下的 IMF 对应的小波包能量。

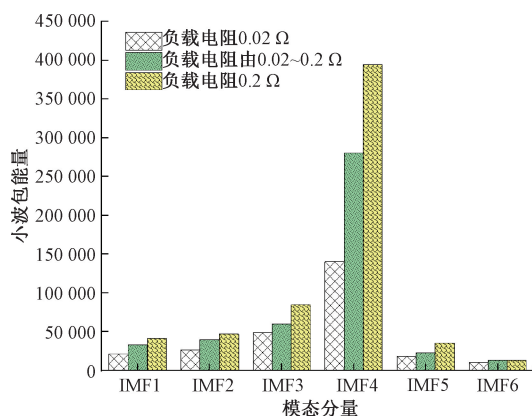


图 10 不同负载下 F02 分解的 IMF 的小波包能量

如图 10 所示,在逆变器 F02 状态时 VMD 分解电流得到 IMF1-6,将 IMF1-6 结合小波包 2 层分解,计算各频段的能量,选取其中最大值。可以看出,负载不同情况下各 IMF 的小波包能量分布相似,所以将小波包能量作为故障特征,可以减小负荷侧变化对输出电流特征的影响,从而表明本方法对负载变化有一定的鲁棒性。

为证明此方法提取的故障特征的区分度高,采用 T-分布随机邻域嵌入 (T-distributed neighbor embedding, T-SNE)对仅 VMD、默认参数下 VMD-小波包能量和 SMA 优化参数下 VMD-小波包能量方法提取的特征量进行可视化,如图 11 所示。图 11(b)和(c)中选择小波基函数 db3 进行 2 层分解。为了提高图的可读性,选取了 8 个故障类型进行分析,去除了实验对照组,最终选择了 F01、F02、F06、F07、F10、F11、F14 和 F15 进行研究和比较。

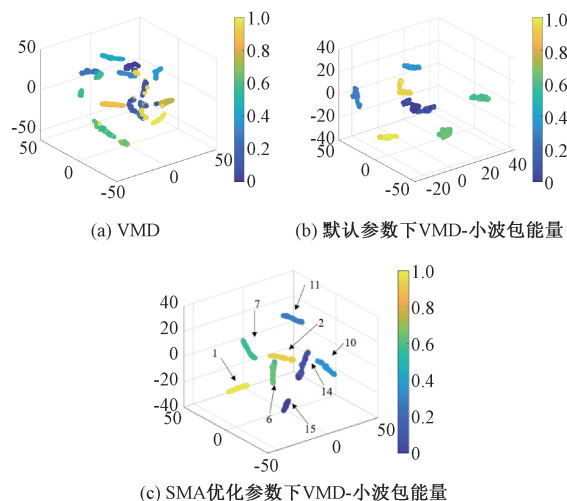


图 11 故障特征可视化结果

从图 11(a)中可以看出,仅 VMD 提取的特征出现了 F10 和 F11、F14 和 F15 部分混淆的情况,图 11(b)中默认参数下 VMD-小波包能量提取的特征点不同类别距离优于仅 VMD,但 F14 和 F15 仍有多处重叠。与前两种方法相比,图 11(c)中 SMA 优化参数下 VMD-小波包能量中不同类别样本之间距离较大,且没有明显的故障类别混淆现象,总体性能明显优于其他几种特征提取方法,因此 SMA 优化参数下 VMD-WPT 在提取特征方面具有更好的可判别性,为实现样本数据分类提供了基础。

4.2 优化 BP 神经网络的诊断性能分析

将前 2 种工况的数据(130 组样本)作为训练集,后 1 种工况(70 组样本)作为测试集。根据特征量确定 BP 神经网络输入层节点 $q=6$,输出层节点 $m=17$,隐含层节点 l 根据确定大致范围,经多次实验 l 选择 20,以小波包能量降维得到的能量值作为 6-15-17 结构的 SSA 优化的神经网络的输入进行故障识别。学习率 0.01,最大迭代次数为 1 000,训练目标误差,训练方法采用反向传播的 LM 算法。

$$l = \sqrt{(q+m)} + a \quad (15)$$

为验证所提 SSA 优化神经网络的优越性,将传统神经网络 BP 和 SSA 优化的神经网络法对 100 组训练样本进行训练,神经网络参数相同。SSA 优化的神经网络算法的参数种群数量为 30,迭代次数为 30。将 2 种方法的适应度值迭代曲线进行对比,如图 12 所示。





图 12 不同方法下适应度曲线


由图 12 可知,传统神经网络在 30 次迭代的过程中平均适应度的值始终没有到达最佳适应度,而 SSA 优化的神经网络在第 26 次迭代时出现了最佳目标值趋于平稳的情况,并且后续没有出现波动,总体迭代效果更好。SSA 在第 26 次迭代就达到了最佳目标值平稳,说明 SSA 在后期的搜索速度较快,减少了迭代次数与运行时间;并且 SSA 在初次迭代时选择的函数目标值与最终的最佳目标值相差很小,表明 SSA 算法能够快速确定迭代函数的最佳目标值并进行迭代,具有较高的精度。

使用测试集数据来评估神经网络故障分类的准确性,并将诊断结果以混淆矩阵的形式呈现,如图 13 所示。

由图 13 可知,对角线上表示正确诊断的样本数;非对



(a)神经网络



(b)SSA优化的神经网络

图 13 不同方法下混淆矩阵

角线上表示错误诊断的样本数;最右边的列表示诊断出属于每个故障类型的正确率和错误率。可以明显看出神经网络分类出现了 26 个误分类样本,而 SSA 优化的神经网络分类仅有 12 个误分类样本。相较于神经网络方法诊断准确率为 97.81%,SSA-BP 方法在此故障分类任务中展现出更高的准确率,达到了 98.99%。结果表明,经过 SSA 优化的神经网络在诊断精度方面展现出了显著的优势。

5 结 论

本研究针对 NPC 三电平逆变器开关开路故障基于电流信号的诊断在负载变化的影响下存在诊断准确率低的问题,提出了一种 VMD-小波包能量与 SSA 优化的神经网络结合的方法,并进行仿真实验验证,可以得到如下结论:引入 VMD 实现了对非稳态非线性信号的分析,并结合 SMA 对 VMD 参数进行了优化,增强了 IMF 的正交性,从而改善故障特征区分度低的问题。利用小波包能量的最大值作为故障特征量,使故障信息更集中,进一步提高了负载变化时的电流特征区分度。T-SNE 分布结果表明其特征提取效果明显优于 VMD 和默认参数下 VMD-小波包能量,是一种改善开关故障特征区分度的有效方法;针对神经网络易陷入局部最优的问题,利用 SSA 算法在初次迭代时即可确定初值在最终的最优值相近范围内的特点,在提升收敛精度的同时,可以优化神经网络权值阈值,从而避免了神经网络陷入局部最优;从适应度达到稳定的迭代次数上可见 SSA 优化的神经网络达到最佳适应度值更快速,准确率可达到 98.99%。综上所述,本文方法所提出的方法在变负

载条件下在提升开关故障特征区分度和诊断准确性上获得了较好的效果,但单一特征在区分同桥臂同半桥的 2 个 IGBT 故障与桥臂内侧单个 IGBT 故障输出电流特征区分度明显降低,在后续研究中可结合多特征融合作为进一步诊断方法的研究方向。

参考文献

- [1] 林伯强.“双碳”目标下储能产业发展新趋势[J]. 人民论坛,2024(3):78-83.
- [2] 李晖,刘栋,姚丹阳.面向碳达峰碳中和目标的我国电力系统发展研判[J]. 中国电机工程学报,2021,41(18):6245-6259.
- [3] HU H, FENG F, WANG T. Open-circuit fault diagnosis of NPC inverter IGBT based on independent component analysis and neural network[J]. Energy Reports, 2020, 6: 134-143.
- [4] 王晓标,肖华平,牛晨晖,等.高可靠三电平逆变器构造方法研究[J]. 中国电机工程学报,2023,43(10):3928-3938.
- [5] 唐圣学,王维威,马强,等.三电平逆变器 IGBT 器件接线故障在线诊断方法研究[J]. 仪器仪表学报,2020,41(11):19-30.
- [6] WU X, CHEN C Y, CHEN T F, et al. A fast and robust diagnostic method for multiple open-circuit faults of voltage-source inverters through line voltage magnitudes analysis[J]. IEEE transactions on power electronics, 2019, 35(5): 5205-5220.
- [7] PECINA S J A, CAMPOS-DELGAD D U, ESPINOZA-TREJO D R, et al. Fault diagnosis in grid-connected PV NPC inverters by a model-based and data processing combined approach [J]. Power Electronics, IET, 2019, 12(12):3254-3264.
- [8] CHEN M, HE Y. Multiple open-circuit fault diagnosis method in NPC rectifiers using fault injection strategy[J]. IEEE Transactions on Power Electronics, 2022, 37(7): 8554-8571.
- [9] 左景航,王友仁,王景霖,等.变工况下航空逆变器健康评估方法研究[J]. 电子测量技术,2022,45(6):30-35.
- [10] 彭丽维,张彼德,孔令瑜.级联 H 桥七电平逆变器故障的 SKSNN-LPP 特征提取方法[J]. 电子测量与仪器学报,2019,33(2):110-116.
- [11] 刘攀,王文江,陈轩.基于相电压积分的逆变器开路故障诊断策略[J]. 电子测量技术,2017,40(10):252-254.
- [12] LI Z, WHEELER P, WATSON A, et al. A fast

diagnosis method for both IGBT faults and current sensor faults in grid-tied three-phase inverters with two current sensors [J]. IEEE Transactions on Power Electronics, 2020, 35(5):5267-5278.

- [13] REYES-MALANCHE J A, VILLALOBOS-PINA F J, CABAL-YEPEZ E, et al. Open-circuit fault diagnosis in power inverters through currents analysis in time domain[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-12.
- [14] 姜媛媛,张书婷.基于改进的 VMD 和 CNN 神经网络的光伏逆变器软故障诊断方法研究[J]. 电测与仪表,2021,58(2):158-163.
- [15] 覃尚昊,胡迎春,周明,等.基于改进 VMD 与特征选择的路灯故障检测方法[J]. 电子测量技术,2023,46(9):92-99.
- [16] 万红,任晓红,范晋瑜,等.三电平逆变器开路故障诊断研究[J]. 工矿自动化,2020,46(4):66-74.
- [17] DHUMALE R B, LOKHANDE S D. Neural network fault diagnosis of voltage source inverter under variable load conditions at different frequencies [J]. Measurement, 2016, 91: 565-575.
- [18] 赵丹阳,董唯光,高峰阳.一种改进卷积神经网络的逆变器故障诊断[J]. 电源学报,2020,18(3):124-132.
- [19] 孙洁,孙超群.基于 LPWAN 和 MEA-BP 的港口起重机故障诊断[J]. 国外电子测量技术,2022,41(7):133-138.
- [20] 张福生,潘学文,路超.基于 SSA 优化 BP 神经网络的故障诊断系统研究[J]. 中国工程机械学报,2022,20(1):81-85,90.
- [21] 杨童亮,胡东,唐超,等.基于 SMA-VMD-GRU 模型的变压器油中溶解气体含量预测[J]. 电工技术学报,2023,38(1):117-130.
- [22] LI Y, TANG B, JIANG X, et al. Bearing fault feature extraction method based on GA-VMD and center frequency[J]. Mathematical Problems in Engineering, 2022, 2022: 1-19.

作者简介

邢砾云(通信作者),博士研究生,教授,主要研究方向为电力谐波检测与多信息融合处理,太赫兹无损检测技术。

E-mail: xingliyun116@foxmail.com

李冉,硕士研究生,主要研究方向为逆变器故障分析与人工算法设计。

E-mail: liran18856330662@163.com