

基于快速傅里叶变换和改进 T-S 模糊神经网络集成模型的逆变器开路故障诊断方法研究

田广强¹, 乔珊珊¹, 侯 奥², 王福忠³

(1. 黄河交通学院智能工程学院, 河南 焦作 454950; 2. 河南送变电建设有限公司, 河南 郑州 450000;
3. 河南理工大学电气工程与自动化学院, 河南 焦作 454000)

摘 要: 针对受负载扰动和测量噪声影响, 逆变器开路时的故障边界间、故障与特征间存在交叠和模糊性问题, 在对逆变器功率管开路故障特征的分析基础上, 提出基于快速傅里叶变换和改进 T-S (Takagi-Sugeno) 模糊神经网络集成模型的逆变器开路故障诊断模型。首先, 依据快速傅里叶变换分析逆变器的三相输出电流波形, 提取功率管发生不同类型开路故障时的故障特征; 其次, 采用规则自分裂技术和模糊 C 均值设计 T-S 模糊神经网络的前件网络的隶属函数层; 然后, 依托自适应 Levenberg-Marquardt 算法对 T-S 网络参数进行训练; 最后, 利用训练后的 T-S 网络实现逆变器功率管的多种故障类型与位置的诊断。实验结果表明, 所提出模型的诊断准确率高达 96%, 能够显著改善逆变器功率管开路故障诊断时所存在的问题。

关 键 词: 逆变器; 开路故障诊断; 快速傅里叶变换; 改进 T-S 模糊神经网络; 自适应 LM 算法

DOI: 10.19781/j.issn.1673-9140.2023.06.008 中图分类号: TM464 文章编号: 1673-9140(2023)06-0076-11

Research on open-circuit fault diagnosis method for inverter transistor based on FFT and improved T-S FNN ensemble model

TIAN Guangqiang¹, QIAO Shanshan¹, HOU Ao², WANG Fuzhong³

(1. School of Intelligent Engineering, Huanghe Jiaotong University, Jiaozuo 454950, China; 2. Henan Power Transmission and Transformation Construction Co., Ltd., Zhengzhou 450000, China; 3. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454000, China)

Abstract: Aiming at overlap and fuzziness between fault boundaries, faults, and characteristics under load disturbances and measurement noise influence when the inverter is in an open-circuit state, an inverter open circuit fault diagnosis model built upon the fast Fourier transform (FFT) and improved Takagi-Sugeno (T-S) fuzzy neural network (FNN) integration model is proposed based on the analysis of the characteristics of the inverter power tube open circuit fault. Firstly, fault characteristics are extracted when different types of open-circuit faults occur in the power tubes according to the three-phase output current waveforms of the inverter analyzed by the FFT. Secondly, the membership function layer of the antecedent network of the T-S fuzzy neural network is designed by using the rule self-splitting technology and fuzzy C-means, and the parameters of the T-S network are trained by leveraging the adaptive Levenberg-Marquardt algorithm.

收稿日期: 2022-12-13; 修回日期: 2023-02-14

基金项目: 国家自然科学基金(U1804143); 河南省科技攻关(212102210146)

通讯作者: 田广强(1975—), 男, 硕士, 副教授, 主要从事人工智能应用技术研究; E-mail: tectian@zjtu.edu.cn.

The trained T-S network is used to realize the diagnosis of multiple fault types and positions of the inverter power tubes. The example results show that the diagnostic accuracy of the proposed model is up to 96%, which can significantly improve the problems existing in the open-circuit fault diagnosis of inverter power tubes.

Keywords: inverter; open-circuit fault diagnosis; fast Fourier transform (FFT); improved Takagi-Sugeno (T-S) fuzzy neural network; adaptive Levenberg-Marquardt (LM) learning algorithm

逆变器已经广泛应用于新能源发电的并网系统^[1-3]。在逆变系统中,半导体功率管发生的故障占38%,主要包括开路和短路2种故障。由于短路故障发生时,桥臂电路中串联的快速熔断器工作,将短路故障转化为开路故障^[1]。因此,开展逆变器半导体功率管开路故障诊断研究对提高逆变器系统的运行稳定性与可靠性具有十分重要的意义。

针对逆变器半导体功率管开路故障诊断研究,目前多采用基于解析模型分析法、基于信号分析法、基于知识分析法^[4-5]。解析模型分析法需要分析逆变系统并构建其精确数学模型,方法较为简单。但由于逆变系统受到负载扰动、电网扰动等影响,构建其精确数学模型比较困难,故该方法的应用存在局限性^[6]。

信号分析法采用的数学工具主要有小波分析法、频谱分析法、信息融合技术等方法^[7-8]。文献[7]利用小波变换与Concordia变换,通过采集逆变器输出的三相电流信息,得到三相逆变器故障特征信息。文献[9]将快速傅里叶变换与随机向量函数相结合,通过测量三相逆变器的输出电流,识别逆变器的故障类型和位置。文献[10]将傅里叶变换和主成分分析以及支持向量机相结合(FFT-RPCA-SVM),通过测量逆变器的输出电压,实现H桥多电平逆变器的故障诊断,其模型稀疏性高,但参数选择较为困难。由于传统信号分析方法缺乏学习功能,其自适应能力不强^[6]。

为解决信号分析法的自学习问题和逆变器开路故障诊断与定位问题,相关学者利用人工智能理论进行研究^[11]。文献[11]将小波包分析和核主成分分析以及概率神经网络相结合,通过测量逆变器输出的电压信号,实现了电磁法三电平逆变器故障诊断,其可靠性高,但运算量大,影响诊断速度。文献[12]将小波包分析和主成分分析以及极端学习机相结合,通过测量逆变器桥臂以及功率器件管上的电压信号,实现了三电平光伏逆变器开路故障诊

断与定位,其故障诊断与定位精度高,但存在对硬件依赖性高的问题。在基于知识分析方面,国内外学者将模糊推理、贝叶斯、神经网络、深度学习等应用于逆变器功率管的开路故障诊断及其定位中^[13]。文献[14]将自适应神经模糊推理方法应用于三电平逆变器功率管开路故障诊断中,利用逆变器的三相输出电流实现功率管的开路故障诊断,该方法学习与训练计算量较大,影响其实时性。文献[15]将小波包熵和主成分分析以及贝叶斯网络相结合,通过测量牵引逆变器的电流和电压,实现逆变器功率管开路故障诊断,该模型对于不确定因素的免疫能力强,但没有很好地解决故障模式模糊和故障边界不明显等逆变器功率管开路故障诊断问题。文献[16]通过对逆变器的电流信号分析,实现了电压源逆变器功率管的故障诊断,但采用神经网络,其诊断模型收敛速度慢、易陷入局部最小值。文献[17]提出了基于GAN的光伏逆变器运行异常检测和定位框架,该方法并没有完全解决生成对抗训练过程不稳定以及生成样本质量问题。

由于逆变器运行过程中受负载扰动和测量噪声等影响,不同故障的边界界限不明显,且故障与特征间存在的交叠和模糊性^[18],影响了逆变器开路故障在线诊断的精确性。对此,一方面考虑到快速傅里叶变换(fast Fourier transform, FFT)具有良好的噪声平滑处理性能;另一方面,T-S模糊神经网络(Takagi-Sugeno fuzzy neural network, T-S FNN)综合了非线性映射的神经网络和知识推理的模糊逻辑,能够处理各种模糊性问题^[19]。为此,本文基于快速傅里叶变换和改进T-S模糊神经网络提出一种逆变器功率管开路故障诊断模型,简称为FFT+改进T-SFNN多模型集成诊断模型。利用快速傅里叶变换求解功率管不同类型开路故障时的故障特征信息,然后采用改进T-S模糊神经网络识别发生具体故障位置、类型。实例仿真表明,该模型具有较高诊断准确率,能够显著改善上述问题。

1 逆变器功率管开路故障分类及其特征

本文以图1所示的三相逆变器为例,通过Matlab/Simulink建立逆变器功率管开路故障仿真模型,分析不同组合功率管发生开路时的故障特征^[13,19]。由于实际运行中3个功率开关管同时出现故障的概率较低^[20],为此本文主要分析逆变器单管开路故障、同相桥臂双管开路故障、同侧桥臂双管开路故障以及交叉桥臂双管开路故障。逆变器功率管开路故障分类及其特征如图2~5和表1所示。

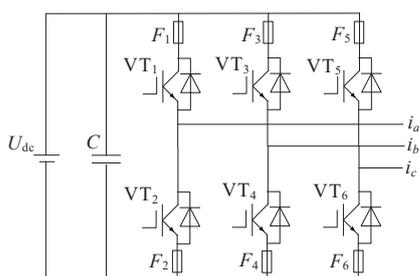


图1 三相逆变器的等效拓扑

Figure 1 Equivalent topology of three-phase inverter

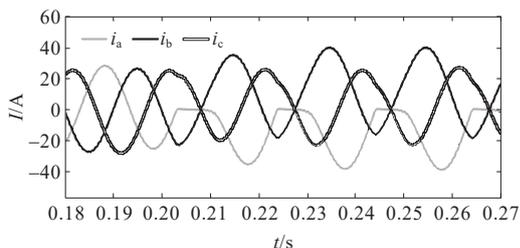


图2 VT₁发生开路故障时逆变器三相输出电流波形

Figure 2 The three-phase output current waveforms of the inverter when VT₁ have an open-circuit fault

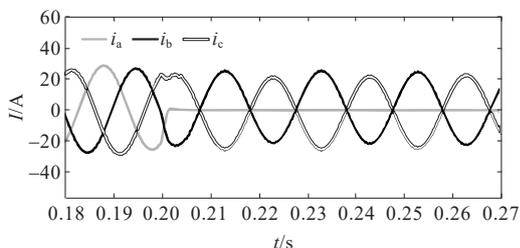


图3 VT₁与VT₂发生开路故障时逆变器三相输出电流波形

Figure 3 The three-phase output current waveforms of the inverter when VT₁ and VT₂ have an open-circuit fault

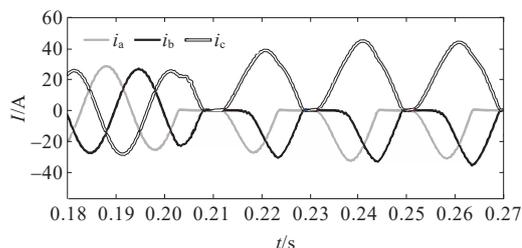


图4 VT₁与VT₃发生开路故障时逆变器三相输出电流波形

Figure 4 The three-phase output current waveforms of the inverter when VT₁ and VT₃ have an open-circuit fault

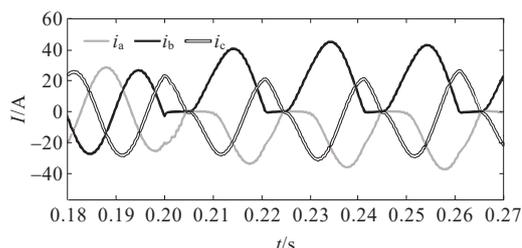


图5 VT₁与VT₄发生开路故障时逆变器三相输出电流波形

Figure 5 The three-phase output current waveforms of the inverter when VT₁ and VT₄ have an open-circuit fault

表1 逆变器功率管开路故障分类与特征

Table 1 Classifications and characteristics of open-circuit fault of inverter power tube

故障类型	故障数量	具体故障位置	故障特征
单管开路故障	6	VT ₁ 、VT ₂ 、VT ₃ 、VT ₄ 、VT ₅ 、VT ₆	A相波形缺少上半波、下半波幅值增大且波形出现畸变,B相、C相电流波形均发生不同程度畸变。
同相桥臂双管开路故障	3	VT ₁ VT ₂ 、VT ₃ VT ₄ 、VT ₅ VT ₆	A相电流会迅速趋于0; B、C两项电流迅速转变为对称状态。
同侧桥臂双管开路故障	6	VT ₁ VT ₃ 、VT ₁ VT ₅ 、VT ₃ VT ₅ 、VT ₂ VT ₄ 、VT ₂ VT ₆ 、VT ₄ VT ₆	A相、B相电流无上半波波形,C相电流几乎无下半波且上半周幅值增加,三相输出电流在一段时间输出均接近于0。
交叉桥臂双管开路故障	6	VT ₁ VT ₄ 、VT ₁ VT ₆ 、VT ₂ VT ₃ 、VT ₃ VT ₆ 、VT ₂ VT ₅ 、VT ₄ VT ₅	A相电流无上半波波形而下半波幅值增加,B相电流无下半波波形而上半周幅值增加,C相电流几乎无上半波,且三相输出电流在一段时间输出均接近于0。

由图 2~5 和表 1 可知,不同组合的功率管发生开路故障时,逆变器三相输出电流波形呈现明显差异,其故障特征也不同。因此可以通过逆变器输出的三相相电流提取故障特征信息,识别出功率管的开路故障。

2 逆变器功率管开路故障在线故障诊断模型

基于快速傅里叶变换和改进 T-S 模糊神经网络^[19,21]的逆变器功率管开路故障诊断模型如图 6 所示。该模型主要由快速傅里叶变换的功率管开路故障特征参数提取模块、输入特征参数预处理模块、改进 T-S 模糊神经网络模块等组成。其工作原理:首先,采集逆变器的三相输出电流信号,并利用快速傅里叶变换提取逆变器功率管发生不同开路故障时所表现的故障特征参数为模型的输入,然后对该故障特征参数进行预处理。为了保证 T-S 模糊神经网络故障诊断模型的诊断准确性和有效性,采用

规则自分裂技术和模糊 C 均值法设计前件网络的隶属函数层,利用自适应 LM 算法对 T-S 模糊神经网络进行训练,得到其较优的网络参数。最后,经 T-S 模糊神经网络运算识别出功率管的开放故障。

2.1 逆变器功率管开路故障特征参数提取

基于快速傅里叶变换,首先将逆变器输出的三相电流时域信号转换到频域,然后对频域电流信号的各次谐波进行分析处理,提取具有代表性的特征参数作为 T-S 模糊神经网络的输入信号。本文采用累计百分比幅值波动法,原理为通过分析不同组合的功率管发生开路故障前后电流信号的各次谐波幅值变化,通过累积百分比计算得到三相逆变器功率管开路故障的特征参数。累计百分比幅值波动法是根据不同故障下的同次谐波分量幅值的贡献率,提取故障特征参数,而不同组合的功率管发生开路故障时,逆变器三相输出电流波形以及电流信号中的各次谐波幅值存在明显区别,采用百分比幅值波动法进行逆变器功率管开路故障特征参数提取,具有良好的效果。

设 $X_{ij} \in A_{m \times n}$, 其中 X_{ij} 为第 i 类故障的第 j 次谐波分量, $A_{m \times n}$ 为故障分量矩阵, m 为故障类型数量, n 为谐波量级。由于逆变器功率管开路故障有 21 种,同时考虑正常状态,则 m 取 22。

首先计算同次谐波分量的幅值变化程度 ζ_j , 然后将 ζ_j 从大到小的顺序排列,计算各个 ζ_j 的幅值波动贡献率 R_j ,最后设置阈值并计算累积百分比幅值波动率 R'_j 。具体计算步骤如下。

1) 计算 ζ_j 。

$$\zeta_j = \frac{1}{m} \sqrt{\frac{\sum_{i=1}^m \left(y_{ij} - \frac{1}{m} \sum_{i=1}^m y_{ij} \right)^2}{\frac{1}{m-1} \sum_{i=1}^m \left(Y_{ij} - \frac{1}{m} \sum_{i=1}^m y_{ij} \right)^2}} \quad (1)$$

2) 将计算得到的 n 个 ζ 按照从大到小的顺序排列,即 $\zeta_1 > \zeta_2 > \zeta_3 > \dots > \zeta_n$ 。

3) 计算 R_j 。

$$R_j = \left(\frac{\zeta_j}{\sum_{j=1}^n \zeta_j} \right) \times 100\% \quad (2)$$

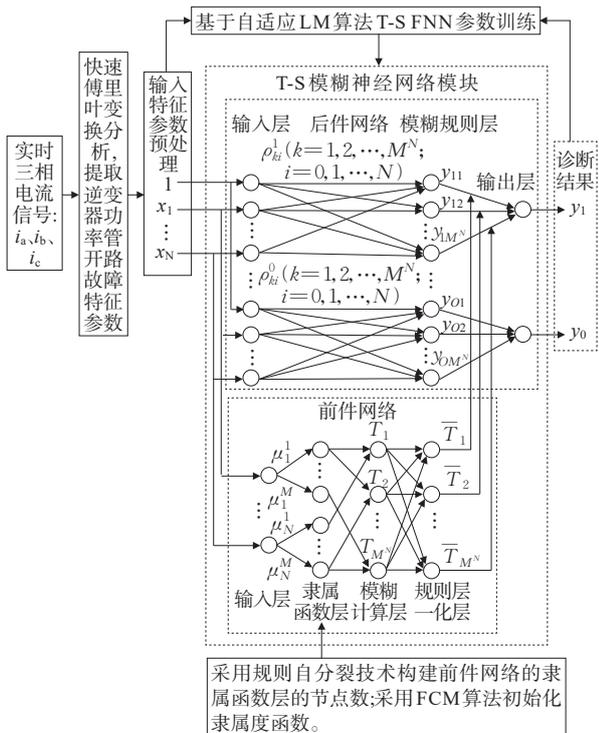


图 6 基于快速傅里叶变换和改进 T-S 模糊神经网络的逆变器功率管开路故障诊断模型

Figure 6 The FFT and improved T-S FNN based inverter power tube open-circuit fault diagnosis model

4) 计算 R'_j 。

$$R'_j = \sum_{j=1}^k R_j \geq 60\% \quad (3)$$

式中, R_j 为用户自行设定的阈值, 以获取符合要求的主要谐波分量, 阈值大小直接影响到提取的故障特征的精度率。通过仿真实验, 本文中阈值 R'_j 设定为 60%, 则满足式(3)的前 k 个 ζ 所代表的谐波量级为所提取的故障特征。

对图 1 所示的三相逆变器在不同类型开路故障下输出的电流进行快速傅里叶变换分析。设定参数: 起始时间为 0.05 s, 基频 50 Hz, 最大频率为 1 500 Hz。用 $F(k)$ 表示谐波次数 k 所对应的故障特征, 由于电流谐波次数越高, 其幅值越小, 对特征参数的影响越小。为了减少运算量, 本文中谐波次数 k 的取值为 0~29。因此, A、B、C 三相所对应的 X_{ij} 可记为 $F_A(k)$ 、 $F_B(k)$ 、 $F_C(k)$, 矩阵 A 共有 22×29 个元素。

分析发现, 当发生同相单管故障时, 如 VT_1 、 VT_2 发生故障时, 快速傅里叶变换后的谐波分量几乎相同。为解决该问题, 引入三相电流的直流相位信息 θ 作为故障特征参数之一, 以区分同相上、下功率管开路故障。综合分析, 得到三相逆变器功率管开路故障的特征参数与故障诊断模型输入参数的关系如表 2 所示。

表 2 逆变器功率管开路故障诊断模型的输入特征参数

Table 2 Input characteristic parameters of inverter power tube open-circuit fault diagnosis model

输入参 数序号	A 相特征 参数	输入参 数序号	B 相特征 参数	输入参 数序号	C 相特征 参数
X_1	$F_A(0)$	X_8	$F_B(0)$	X_{15}	$F_C(0)$
X_2	$F_A(1)$	X_9	$F_B(1)$	X_{16}	$F_C(1)$
X_3	$F_A(2)$	X_{10}	$F_B(2)$	X_{17}	$F_C(2)$
X_4	$F_A(3)$	X_{11}	$F_B(3)$	X_{18}	$F_C(3)$
X_5	$F_A(4)$	X_{12}	$F_B(4)$	X_{19}	$F_C(4)$
X_6	$F_A(18)$	X_{13}	$F_B(18)$	X_{20}	$F_C(18)$
X_7	$\theta_A(0)$	X_{14}	$\theta_B(0)$	X_{21}	$\theta_C(0)$

2.2 输入特征参数预处理

由于特征参数单位不同、数量级相差较大, 为了提高逆变器功率管开路故障诊断模型的计算精度, 需要对输入的功率管开路故障特征参数进行归

一化处理, 其公式为

$$X_n = \frac{x_n - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

式中, X_n 为归一化后的三相逆变器功率管开路故障的特征参数; x_n 为归一化前的功率管开路故障特征参数; x_{\max} 和 x_{\min} 为归一化前的功率管开路故障特征参数中的最大值和最小值。

2.3 T-S 模糊神经网络的前件网络构建

如图 2 所示, 前件网络由输入层、隶属度函数层、模糊计算层, 以及输出层等组成。

1) 输入层。

前件网络的输入层节点数应等于三相逆变器功率管开路故障特征参数的个数, 根据表 2 取 21 个, 即

$$\mathbf{X} = (x_1, x_2, \dots, x_N)^T, N=21 \quad (5)$$

2) 隶属度函数的构造。

前件网络的隶属函数可根据参数类型选择, 根据逆变器开路故障参数类型, 本文采用铃型隶属函数, 共有 $N \times M$ 个节点, 即

$$\mu_i^j = \exp\left[-\frac{(x_i - c_{ij})^2}{b_{ij}^2}\right] \quad (6)$$

式中, $i=1, 2, \dots, N$; $j=1, 2, \dots, M$; c_{ij} 、 b_{ij} 分别为前件网络第 i 个输入层对应的第 j 个隶属函数的中心和宽度。

为了减少确定隶属度函数层节点数时受人工主观因素的影响, 采用自分裂技术根据所需要的精度自适应地确定隶属度函数层节点数。其算法如下。

根据设定的阈值, 从初始的一个隶属函数以每次增加一个的形式分裂直到满足要求^[22]。假设所有的样本数据存在 M 个类聚, 维数为 N 。首先通过下式找到具有最大均方差的类聚:

$$g_1 = \arg \max_{1 \leq j \leq M} \bar{g}_j \quad (7)$$

式中, \bar{g}_j 为第 j 个类聚中心的均方差, 其值为第 j 个类聚中心中的所有输入变量的均方差和, 即

$$\bar{g}_j = \sum_{i=1}^N g_{ij} \quad (8)$$

式中, g_{ij} 为在第 j 个类聚中心的第 i 维输入变量的均方差, 其计算方式为

$$g_{ij} = \frac{1}{N_j} \sum_{x \in M_j} (x_{ij} - \bar{x}_{ij})^2 \quad (9)$$

式中, $x \in M_j$ 为三相逆变器功率管开路故障样本 x 属于第 j 个类聚中心; x_{ij} 为第 j 个类聚中心中的第 i 维数据; N_j 为第 j 个类聚中心的功率管开路故障样本总数。

若定义 $g_i \geq g_{th}$ 则将类聚数从一类增加至两类, 即 $M = M + 1$ 。其中 g_{th} 为一个定义的阈值, 设定的第 1 个类聚中心为所有输入训练样本的平均值。

假定原始类聚中心分别为 $P_j (j = 1, 2, \dots, M)$, 则新分裂生成的 2 个类聚中心分别为 $P_j + \beta$ 和 $P_j - \beta$ ($\beta > 0$, 且为一个较小的值), 本文 $\beta = 0.01$ 。

3) 前件网络模糊计算层和规则归一化层。

根据模糊规则确定模糊计算层, 每一节点都对应一条模糊规则, 共有 M^N 个节点, 用来计算每条规则的激活度, 即

$$T_k = \mu_1^{s_{1j}} \mu_2^{s_{2j}} \dots \mu_N^{s_{Nj}} \quad (10)$$

其中, $k = 1, 2, \dots, M^N, s_{1j} \in \{1, 2, \dots, M\}, s_{2j} \in \{1, 2, \dots, M\}, s_{Nj} \in \{1, 2, \dots, M\}$ 。该层有 M^N 个节点。

规则归一化层的节点数与模糊计算层的节点数相同, 是对输入参数规激活度的释放, 即

$$\hat{T}_k = \frac{T_k}{\sum_{i=1}^{M^N} T_i} \quad (j = 1, 2, \dots, M) \quad (11)$$

4) 基于模糊 C 均值算法 (FCM) 的前件网络隶属函数的初始化。

为了解决故障诊断网络因前件网络隶属函数参数初始值设定不当而引起的收敛速度慢和陷入局部最优问题, 增强网络自适应性, 本文采用 FCM 对式 (6) 所示隶属函数中的 c_{ij} 和 b_{ij} 进行初始化, 具体方法如下^[19]。

FCM 是将每个待分类的样本按照其特征类似程度划分为某类, 通过极小化数据样本与各类聚中心的欧氏距离和模糊隶属度的加权和, 不断迭代求解类聚中心直到符合设定的终止规则。

给定的数据集 $X = (x_1, x_2, \dots, x_{N'})^T$, 即将 N' 个数据样本分为 M 类。设 $P_j (j = 1, 2, \dots, M)$ 为第 j 类的聚类中心, $\mu_j(x_i)$ 为第 i 个样本对应第 j 类的隶属度函数。则 FCM 可表述为

$$\left\{ \begin{array}{l} \min \left\{ E_i = \sum_{j=1}^M \sum_{i=1}^{N'} [\mu_j(x_i)]^b \|x_i - P_j\|^2 \right\} \\ \sum_{j=1}^M \mu_j(x_i) = 1, \forall i = 1, 2, \dots, N' \end{array} \right. \quad (12)$$

式中, b 为加权指数, 且 $b = 2$ 。

对式 (12) 中的 $\mu_j(x_i)$ 和 P_j 求偏导, 并令其结果等于 0, 可得 E_i 达到极小值的必要条件为

$$P_j = \frac{\sum_{i=1}^{N'} [\mu_j(x_i)]^b x_i}{\sum_{i=1}^{N'} [\mu_j(x_i)]^b} \quad (13)$$

$$\mu_j(x_i) = 1 / \sum_{k=1}^M \frac{\|x_i - P_j\|^{2/(b-1)}}{\|x_i - P_k\|} \quad (14)$$

$$D_j = |P_j - \tilde{P}_j| / \gamma; j = 1, 2, \dots, M' \quad (15)$$

式 (13)~(15) 中, P_j 为最优类聚中心; D_j 为各类聚中心之间最近距离的绝对值; \tilde{P}_j 为最靠近 P_j 的聚类中心; γ 为重叠系数, 反映类别间相互重叠的程度, 较小的 γ 值对应于类别之间有较大的重叠特性, 即类别之间的模糊边界较宽, 模糊区域就大, 根据仿真训练, 本文中 γ 的取值为 $1 < \gamma < 2$ 。

通过迭代求解式 (13)~(15), 直到满足设定的终止规则, 得到最优类聚中心 P_j 和各类聚中心之间最近距离的绝对值 D_j 。最后将 P_j 和 D_j 作为前件网络隶属函数的初始中心 c_{ij} 和宽度 b_{ij} 值, 即得到 $M \times N$ 个模糊隶属函数的中心和宽度。

2.4 后件网络的构建

T-S 模糊神经网络诊断模型的输出如表 3 所示, 有 6 个输出节点, 分别表示逆变器的 6 个功率开关管的状态, 后件网络由 6 个子网络并联构成, 每个子网络的输出对应一个功率开关管的状态, 正常状态为“0”, 故障状态为“1”。

每个子网络的输入层节点数等于常数项与逆变器功率管开路故障特征输入参数的数量之和, 即为 $1 + 21 = 22$ 。

子网络的模糊规则层节点数与前件网络的规则归一化层的节点数相同, 每个节点分别与输入层各节点通过连接权 $\rho_{ki}^O (k = 1, 2, \dots, M^N; i = 0, 1, \dots, N)$ 连接, 即

$$y_{Ok} = \rho_{k0}^O + \rho_{k1}^O x_1 + \rho_{k2}^O x_2 + \dots + \rho_{kN}^O x_N \quad (16)$$

式中, O 为子络数, $O=1, \dots, 6$ 。

T-S模糊神经网络的输出结果为

$$y_o = \sum_{k=1}^{M^N} y_{Ok} \bar{T}_k \quad (17)$$

式中, y_o 为最终的诊断结果。

表3 T-S模糊神经网络诊断模型输出参数的定义

Table 3 Definition of T-S fuzzy neural network diagnosis model output parameters

输出变量定义	输出节点期望输出					
	y_1	y_2	y_3	y_4	y_5	y_6
正常	0	0	0	0	0	0
VT ₁ 故障	1	0	0	0	0	0
VT ₂ 故障	0	1	0	0	0	0
VT ₃ 故障	0	0	1	0	0	0
VT ₄ 故障	0	0	0	1	0	0
VT ₅ 故障	0	0	0	0	1	0
VT ₆ 故障	0	0	0	0	0	1

2.5 基于自适应LM算法的T-S模糊神经网络参数优化

LM算法具有局部收敛速度快以及求解误差小的优势,缺点是矩阵运算复杂^[22-24]。为提高网络收敛速度和减小计算量,本文采用自适应LM算法(adaptive levenberg-marquardt, ALM)对T-S模糊神经网络的参数 c_{ij} 、 b_{ij} 和 ρ_{ki}^O 进行训练^[25]。

ALM算法是将标准LM算法中的参数更新公式用式(18)代替:

$$\theta(t+1) = \theta(t) - (\Psi(t) + \eta(t)I)^{-1} \Omega(t) \quad (18)$$

式中, $\Psi(t)$ 为淮海森矩阵; $\Omega(t)$ 为梯度向量; $\eta(t)$ 为自适应学习率, I 为防止矩阵求逆出现奇异的单位阵。

该方法不需要进行Jacobian矩阵的乘法运算,而是直接计算淮海森矩阵 $\Psi(t)$ 和梯度向量 $\Omega(t)$,降低了计算复杂度和存储容量。另外自适应学习率 $\eta(t)$ 动态调整参数的更新速率,加快学习速度和提高泛化能力。

定义 $e(t) = [e_1(t), e_2(t), \dots, e_p(t)]^T$ 为误差向量, P 为样本总数。对于第 p 个样本, $e_p(t)$ 定义为期望输出与网络输出之间的差值,即

$$e_p(t) = y_{dp}(t) - y_{op}(t), p = 1, 2, \dots, P \quad (19)$$

$\eta(t)$ 的学习规则如下:

$$\eta(t) = \alpha \|e(t)\| + (1 - \alpha) \|\Omega(t)\| \quad (20)$$

式中, $\alpha(0 < \alpha < 1)$ 为预设的常量。

$\Psi(t)$ 和 $\Omega(t)$ 分别为所有样本子矩阵 $\varphi_p(t)$ 和子向量 $\omega_p(t)$ 的累加和,即

$$\omega_p(t) = \mathbf{j}_p^T(t) e_p(t), \Omega(t) = \sum_{p=1}^P \omega_p(t) \quad (21)$$

$$\varphi_p(t) = \mathbf{j}_p^T(t) \mathbf{j}_p(t), \Psi(t) = \sum_{p=1}^P \varphi_p(t) \quad (22)$$

式中, $\mathbf{j}_p(t)$ 为雅克比矩阵 J 的行向量。

$$\mathbf{j}_p(t) =$$

$$\left[\frac{\partial e_p}{\partial b_1}, \dots, \frac{\partial e_p}{\partial b_{NM}}, \frac{\partial e_p}{\partial c_1}, \dots, \frac{\partial e_p}{\partial c_{NM}}, \frac{\partial e_p}{\partial \rho_0}, \dots, \frac{\partial e_p}{\partial \rho_{M^N}} \right] \quad (23)$$

式中, c_{ij} 、 $b_{ij}(i = 1, 2, 3, \dots, N; j = 1, 2, 3, \dots, M)$ 分别为前件网络中隶属函数的中心值、宽度。对于第 i 个学习样本,雅克比矩阵行向量对应元素的值可表示为

$$\frac{\partial e_p(t)}{\partial b_{ij}(t)} = \frac{\partial e_p(t)}{\partial y_{op}(t)} \frac{\partial y_{op}(t)}{\partial \bar{T}_k(t)} \frac{\partial \bar{T}_k(t)}{\partial T_k(t)} \frac{\partial T_k(t)}{\partial \mu_{ij}(t)} \frac{\partial \mu_{ij}(t)}{\partial b_{ij}(t)} = -\bar{T}_j(t) \frac{\sum_{i \neq k}^{M^N} T_i(t)}{\left(\sum_{i=1}^{M^N} T_i(t) \right)^2} \sum_{i \neq k}^N \mu_i^{s_i}(t) \frac{\partial \mu_{ij}(t)}{\partial b_{ij}(t)} \quad (24)$$

$$\frac{\partial e_p(t)}{\partial c_{ij}(t)} = \frac{\partial e_p(t)}{\partial y_{op}(t)} \frac{\partial y_{op}(t)}{\partial \bar{T}_k(t)} \frac{\partial \bar{T}_k(t)}{\partial T_k(t)} \frac{\partial T_k(t)}{\partial \mu_{ij}(t)} \frac{\partial \mu_{ij}(t)}{\partial c_{ij}(t)}$$

$$\frac{\partial \mu_{ij}(t)}{\partial c_{ij}(t)} = -\bar{T}_j(t) \frac{\sum_{i \neq k}^{M^N} T_i(t)}{\left(\sum_{i=1}^{M^N} T_i(t) \right)^2} \prod_{i \neq k}^N \mu_i^{s_i}(t) \frac{\partial \mu_{ij}(t)}{\partial c_{ij}(t)} \quad (25)$$

$$\frac{\partial \mu_{ij}(t)}{\partial b_{ij}(t)} = -\frac{2(x_i(t) - c_{ij}(t))^2}{b_{ij}^3(t)} \cdot \exp\left[-(x_i(t) - c_{ij}(t))^2 / b_{ij}^2(t)\right] \quad (26)$$

$$\frac{\partial \mu_{ij}(t)}{\partial c_{ij}(t)} = -\frac{2(x_i(t) - c_{ij}(t))}{b_{ij}^2(t)} \cdot \exp\left[-(x_i(t) - c_{ij}(t))^2 / b_{ij}^2(t)\right] \quad (27)$$

$$\begin{cases} \frac{\partial E}{\partial \rho_{kN}^O} = \frac{\partial E}{\partial y_O} \frac{\partial y_O}{\partial y_{Ok}} \frac{\partial y_{Ok}}{\partial \rho_{kN}^O} = -\dot{T}_k x_i \\ \rho_{kN}^O(n) = \rho_{kN}^O(n-1) - \alpha \frac{\partial E}{\partial \rho_{kN}^O} = \\ \rho_{kN}^O(n-1) + \alpha \dot{T}_k x_i \end{cases} \quad (28)$$

本文构建的T-S FNN模型的稳定性:因规则自分裂技术和模糊C均值可生成一组模型的近似最优参数集,并且ALM方法在每次迭代计算过程中只需要计算雅可比矩阵行向量,降低了模型诊断的复杂性,计算速度较梯度法更快。

2.6 诊断模型流程

逆变器功率管开路故障在线诊断模型的步骤如下:

- 1) 获取训练样本数据,包括逆变器功率管的不同类型的开路故障及其对应的三相电流;
- 2) 采用快速傅里叶变换对逆变器的三相输出电流进行分析,得到逆变器功率管开路特征参数,并作为模型的输入;
- 3) 对逆变器功率管开路特征输入参数预处理;
- 4) 确定T-S模糊神经网络的基本结构;
- 5) 采用自分裂技术确定前件网络的隶属函数层的节点数;
- 6) 利用FCM初始化前件网络的隶属度函数参数: c_{ij} 、 b_{ij} ;
- 7) 采用ALM优化T-S网络参数 c_{ij} 、 b_{ij} 、 ρ_{hi}^0 ,计算T-S模糊神经网络的输出,根据误差大小反复迭代直到当输出误差满足要求,迭代结束。

3 实验分析

实验平台主要由逆变器、型号为DS1202的Dspace、电脑等设备组成。逆变器参数如表4所示。实验过程为,首先通过Dspace采集逆变器输出的三相电流,并送至电脑端;然后利用快速傅里叶变换提取故障特征参数,并输入至改进T-S模糊神经网络对逆变器的功率管开路故障进行诊断。

表4 逆变器参数

Table 4 Inverter parameter table

直流侧电压/ V	额定功 率/kW	额定频 率/Hz	开关频 率/kHz	额定功率因数
300~600	30	50	50	0.99

- 1) 样本数据。

以单功率管 VT_1 开路,同相桥臂功率管 VT_1 、 VT_2 开路,同侧桥臂功率管 VT_1 、 VT_3 开路,以及不同桥臂功率管 VT_1 、 VT_4 开路作为实验诊断类型。为了验证本文建立的改进T-S FNN逆变器开路故

障诊断模型的抗负载扰动噪声的影响和诊断精度,在实验平台上将逆变器的负载由10~12 kW之间进行调整,选取110组数据作为样本,其中4种故障类型及正常工作情况每类22组样本数据,17组作为训练样本数据,5组作为测试样本数据。

- 2) 实验仿真分析。

将训练样本数据、测试样本数据分别送入Bayes诊断模型、LM-BP诊断模型、T-S FNN诊断模型与改进T-S FNN诊断模型中,即可得到相同输入数据下4种诊断模型的输出结果。

逆变器功率管开路故障T-S FNN诊断模型、改进T-S FNN诊断模型的训练误差与迭代次数之间的关系如图7所示。图7中诊断模型输出 y_1 、 y_2 、 y_3 、 y_4 分别代表 VT_1 、 VT_2 、 VT_3 、 VT_4 的运行状态。由图7可知,在使用同样的数据样本下,T-S FNN诊断模型的训练误差曲线存在震荡现象,且需要迭代约100次才趋于稳定;而改进T-S FNN模型的训练误差曲线不存在震荡现象且误差值接近于0,在迭代约50次就趋于稳定。

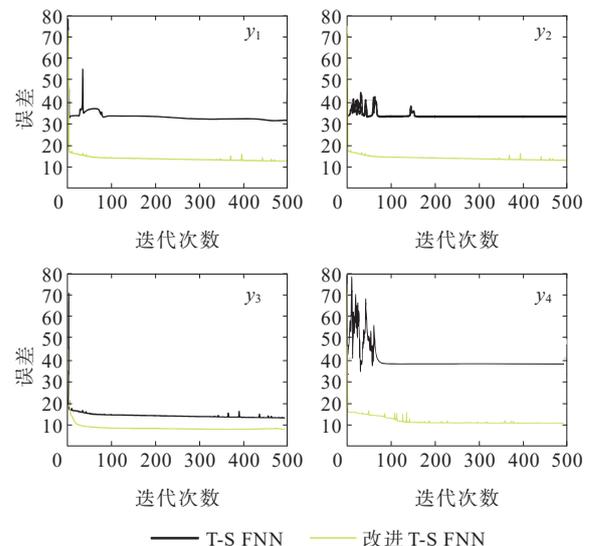


图7 逆变器功率管开路故障诊断模型训练误差

Figure 7 Training error of inverter power tube open-circuit fault diagnosis model

改进后的T-S FNN模型对于110组样本数据的输出误差如图8所示。由图8可知,改进T-S FNN模型输出 y_1 、 y_2 、 y_3 、 y_4 的误差均小于0.1。由此可知,与T-S FNN相比,本文所提出的改进T-S FNN模型,不仅收敛速度和响应速度快,而且诊断精度高。

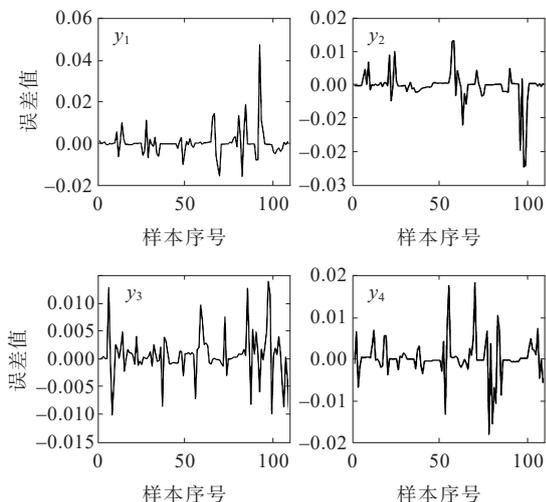


图8 基于改进T-S模糊神经网络的逆变器功率管开路故障诊断模型输出误差

Figure 8 Output error of inverter power tube open-circuit fault diagnosis model based on improved T-S FNN

Bayes 诊断模型、LM-BP 诊断模型、T-S FNN 诊断模型与改进 T-S FNN 诊断模型的诊断结果如表 5 所示,各算法故障诊断结果准确度的统计如图 9 所示。由表 5、图 9 可知,在 Bayes 模型故障诊断的结果中,25 组测试样本存在 5 次错判,准确率为 80%;在 LM-BP 模型故障诊断的结果中,25 组测试样本存在 2 次错判,准确率为 92%;在 T-S FNN 模型故障诊断的结果中,25 组测试样本存在 5 次错判,准确率为 80%;本文提出的改进 T-S FNN 诊断模型,25 组测试数据仅错判 1 次,准确率为 96%。

通过将改进 T-S FNN 诊断模型的故障诊断准确率分别与 Bayes、改进 Bayes、T-S FNN 的故障诊断准确率相比较,本文提出的基于快速傅里叶变换和改进 T-S FNN 集成模型的逆变器开路故障诊断方法的正确率高达 96%,明显高于 Bayes、LM-BP、T-S FNN 诊断模型。

表 5 逆变器功率管开路故障诊断结果

Table 5 Inverter power tube open-circuit fault diagnosis results

故障类型	测试样本数量	Bayes 正判次数	LM-BP 正判次数	T-S FNN 正判次数	改进 T-S FNN 正判次数
正常	5	5	5	5	5
VT ₁	5	4	4	4	4
VT ₁ 、VT ₂	5	4	5	3	5
VT ₁ 、VT ₃	5	3	4	4	5
VT ₁ 、VT ₄	5	4	5	4	5

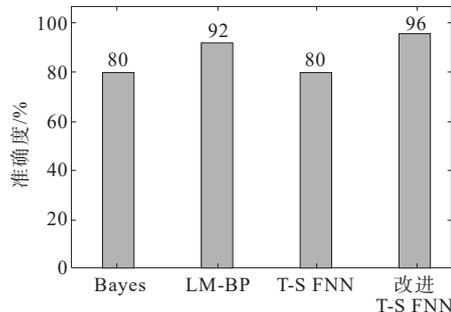


图9 各算法诊断结果准确度

Figure 9 Accuracy of diagnosis results of each algorithm

4 结语

本文提出一种基于快速傅里叶变换和改进 T-S 模糊神经网络集成模型的逆变器功率管开路故障诊断方法,主要工作总结如下。

1) 分析了功率管发生不同类型开路故障时,逆变器三相输出电流波形所包含的故障特征信息,通过电流中的故障特征信息能够识别发生开路故障的功率管;采用快速傅里叶变换、百分比幅值波动法对故障特征信号进行提取,保证提取特征的精确率;采用规则自分裂技术、模糊 C 均值法以及自适应 LM 算法构建 T-S 模糊神经网络,增强了诊断网络的自适应性,提高了故障诊断速度和精度。

2) 利用改进 T-S FNN, T-S FNN、Bayes、改进 Bayes 4 种诊断模型,分别进行了逆变器功率管开路故障诊断仿真实验与对比分析。实验分析表明,本文提出的基于快速傅里叶变换和改进 T-S FNN 集成模型的逆变器开路故障诊断方法的准确率高达 96%,明显高于 Bayes、改进 Bayes、T-S FNN 的准确率,并验证了该方法的有效性和实用性。

3) 提出的基于快速傅里叶变换和改进 T-S 模糊神经网络集成模型的逆变器功率管开路故障诊断方法,解决了负载扰动和测量噪声影响、逆变器开路时的故障边界间、故障与特征间存在交叠和模糊性问题,提高了逆变器开路故障在线诊断的精确性。

参考文献:

[1] 王晓鹏,姚帅亮,姚芳,等. 逆变器功率管开路故障诊断方法综述[J],电源学报,2023,21(3): 156-169.

- Review of open-circuit fault diagnosis methods for inverter power transistors[J]. *Journal of Power Supply*, 2023,21(3):156-169.
- [2] 曹芸凯,赵涛,朱爱华,等. 计及电网和线路阻抗的并联逆变器谐振抑制方法[J]. *电力科学与技术学报*,2022,37(2):188-196.
CAO Yunkai, ZHAO Tao, ZHU Aihua, et al. Resonance suppression method for parallel inverters considering the grid and line impedance[J]. *Journal of Electric Power Science and Technology*,2022,37(2):188-196.
- [3] 刘素梅,毕天姝,薛安成. 深度不对称故障下逆变电源控制策略研究[J]. *电力科学与技术学报*,2012,27(3):34-40.
LIU Sumei, BI Tianshu, XUE Ancheng. Study on the control strategy of inverter-interfaced renewable generators under severe asymmetrical faults[J]. *Journal of Electric Power Science and Technology*,2012,27(8):34-40.
- [4] GAO Z W, CECATI CARLO, DING S X. A Survey of fault diagnosis and fault-tolerant techniques-part I: fault diagnosis with model-based and signal-based approaches [J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(6):3757-3767.
- [5] GAO Z W, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques-part II: fault diagnosis with knowledge-based and hybrid/active approaches[J]. *IEEE Transactions on Industrial Electronics*,2015,62(6):3768-3774.
- [6] 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]. *Micromotors*,2019,52(10):110-117.
- [7] 崔江,王强,龚春英. 结合小波与 Concordia 变换的逆变器功率管故障诊断技术研究[J]. *中国电机工程学报*, 2015,35(12):3110-3116.
CUI Jiang, WANG Qiang, GONG Chunying. Inverter power switch fault diagnosis technique research based on wavelet and concordia transform[J]. *Proceedings of the CSEE*,2015,35(12):3110-3116.
- [8] 闵月梅,王宏华,韩伟. 基于信息融合的光伏并网逆变器故障诊断[J]. *电测与仪表*,2014,51(1):17-21.
MIN Yuemei, WANG Honghua, HAN wei. Review on fault diagnosis methods of three-phase boost type PWM rectifiers[J]. *Electrical Measurement & Instrumentation*, 2014,51(1):17-21.
- [9] GOU B, XU Y, XIA Y, et al. An online data driven method for simultaneous diagnosis of IGBT and current sensor fault of three-phase PWM inverter in induction motor drives[J]. *IEEE Transactions on Power Electronics*,2020,35(12):13281-13294..
- [10] WANG T Z, QI J, XU H, et al. Fault diagnosis method based on FFT-RPCA-SVM for cascaded-multilevel inverter [J]. *ISA Transactions*,2016,60:156-163.
- [11] 于生宝,何建龙,王睿家,等. 基于小波包分析和概率神经网络的电磁法三电平变换器故障诊断方法[J]. *电工技术学报*,2016,(17):102-112.
YU Shengbao, HE Jianlong, WANG Ruijia, et al. Fault diagnosis of electromagnetic three-level inverter based on wavelet packet analysis and probabilistic neural networks [J]. *Transactions of China Electrotechnical Society*, 2016, (17):102-112.
- [12] 何瑞,谢振刚,程昱舒. 具有主动故障穿越能力的光伏逆变器自治控制方法研究[J]. *高压电器*,2022,58(7):101-110.
HE Rui, XIE Zhengang, CHENG Yushu. Research on autonomous control method of photovoltaic inverter with active fault ride-through capability[J]. *High Voltage Apparatus*, 2022,58(7):101-110.
- [13] 许水清,陶松兵,何怡刚,等. 基于相电流瞬时频率估计的永磁直驱风电变流器开路故障诊断[J]. *电工技术学报*,2022,37(2):433-444.
XU Shuiqing, TAO Songbing, HE Yigang, et al. Open-circuit fault diagnosis for back-to-back converter of PMSG wind generation system based on estimated instantaneous frequency of phase current[J]. *Transactions of China Electrotechnical Society*,2022,37(2):433-444.
- [14] KAMEL T, BILETSKIY Y, CHANG L C. Fault diagnosis and on-Line monitoring for grid-connected single-phase inverters[J]. *Electric Power Systems Research*, 2015, 126: 68-77.
- [15] 张国恒,高锋阳,石岩,等. 基于贝叶斯网络的牵引逆变器开路故障多特征融合诊断方法[J]. *铁道科学与工程学报*,2020,17(3):732-740.
ZHANG Guoheng, GAO Fengyang, SHI Yan, et al. Multi-feature fusion diagnosis method of open circuit fault for traction inverter based on Bayesian network[J]. *Journal of Railway Science and Engineering*,2020,17(3):732-740.
- [16] 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.
- [17] 周嘉琪,毕利. 基于GAN的光伏逆变器数据异常检测技

- 术[J]. 电力系统保护与控制,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.
- [18] 安群涛,孙力,孙立志,等. 三相逆变器开关管故障诊断方法研究进展[J]. 电工技术学报,2011,26(4):135-144.
- AN Quntao, SUN Li, SUN Lizhi, et al. Recent Developments of fault diagnosis methods for switches in three-phase inverters[J]. Transactions of China Electrotechnical Society,2011,26(4):135-144.
- [19] 王福忠,侯奥,张丽. 基于T-S模糊神经网络的光伏组件在线健康诊断[J]. 传感器与微系统,2021,40(12):153-156+160.
- WANG Fuzhong, HOU Ao, ZHANG Li. Online health diagnosis of PV modules based on T-S fuzzy neural network[J]. Transducer and Microsystem Technologies, 2021,40(12):153-156+160.
- [20] 姬鑫,陈超波,张彬彬,等. 基于Prony算法的三电平逆变器开路故障诊断方法[J]. 电测与仪表,2023,60(8):97-104.
- JI Xin, CHEN Chaobo, ZHANG Binbin, et al. Open-circuit fault diagnosis method of three-level inverter based on Prony algorithm[J]. Electrical Measurement & Instrumentation,2023,60(8):97-104.
- [21] 吕洪武,赵航,王宏志,等. 基于模糊神经网络的MVB故障诊断算法[J]. 吉林大学学报:理学版,2020,58(1):104-108.
- LU Hongwu, ZHAO Hang, WANG Hongzhi, et al. Fault diagnosis algorithm for MVB based on fuzzy neural network[J]. Journal of Jilin University: Science Edition,2020,58(1):104-108.
- [22] 李亚鹏,韩旭,于旭光,等. 模型和数据混合驱动的双边协商电力市场合约价格预测方法[J]. 电力系统自动化,2022,46(18):179-189.
- LI Yapeng, HAN Xu, YU Xuguang, et al. Hybrid model-driven and data-driven approach to price forecasting in bilateral contract electricity markets[J]. Automation of Electric Power Systems,2022,46(18):179-189.
- [23] 刘任,李琳. 基于模拟退火与Levenberg-Marquardt混合算法的Energetic磁滞模型参数提取[J]. 中国电机工程学报,2019,39(3):875-884+966.
- LIU Ren, LI Lin. Parameter extraction for energetic hysteresis model based on the hybrid algorithm of simulated annealing and Levenberg-Marquardt[J]. Proceedings of the CSEE,2019,39(3):875-884+966.
- [24] QIAO J F, ZHOU H B. Modeling of energy consumption and effluent quality using density peaks-based adaptive fuzzy neural network[J]. IEEE/CAA Journal of Automatica Sinica,2018,5(5):968-976.
- [25] ZHOU H B, QIAO J F. Soft sensing of effluent ammonia nitrogen using rule automatic formation-based adaptive fuzzy neural network[J]. Desalination and Water Treatment, 2019,140(2):132-142.

(上接第32页 = Continued from page 32)

- [41] HARKER P T, PANG J-S. Existence of optimal solutions to mathematical programs with equilibrium constraints[J]. Operations Research Letters,1988,7(2): 61-64.
- [42] FANG X, HU Q, LI F, et al. Coupon-based demand response considering wind power uncertainty: a strategic bidding model for load serving entities[J]. IEEE Transactions on Power Systems,2016,31(2): 1025-1037.
- [43] 荆朝霞,朱继松. 月度电量集中竞价市场规则的仿真实验分析[J]. 电力系统自动化,2017,41(24): 42-48.
- JING Zhaoxia, ZHU Jisong. Simulation experiment analysis on market rules for monthly centralized bidding[J]. Automation of Electric Power Systems,2017,41(24): 42-48.
- [44] 孙培博,周明,张磊,等. 基于ABM仿真的实时市场结算不平衡费用分析[J]. 电力系统自动化,2022,46(5): 171-182.
- SUN Peibo, ZHOU Ming, ZHANG Lei, et al. Analysis of unbalanced cost in real-time market settlement based on agent-based model simulation[J]. Automation of Electric Power Systems,2022,46(5): 171-182.
- [45] 唐成鹏,张粒子,邓晖,等. 考虑风险管理的电力市场多时段均衡分析方法[J]. 电力系统自动化,2022,46(10): 171-180.
- TANG Chengpeng, ZHANG Lizi, DENG Hui, et al. multi-period equilibrium analysis method for electricity market considering risk management[J]. Automation of Electric Power Systems,2022,46(10):171-180.
- [46] 唐成鹏,张粒子,刘方,等. 基于多智能体强化学习的电力现货市场定价机制研究(一):不同定价机制下发电商报价双层优化模型[J]. 中国电机工程学报,2021,41(2): 536-553.
- TANG Chengpeng, ZHANG Lizi, LIU Fang, et al. Research on pricing mechanism of electricity spot market based on multi-agent reinforcement learning (part I): bi-level optimization model for generators under different pricing mechanisms[J]. Proceedings of the CSEE, 2021, 41(2): 536-552.
- [47] WATKINS C J C H, DAYAN P. Q-learning[J]. Machine Learning,1992,8(3-4): 279-292.