

DOI: 10.19783/j.cnki.pspc.240254

基于模态时频图与 Resnet-BiGRU 模型的 MMC 子模块开路故障诊断

刘述喜^{1,2}, 刘科¹, 王乾蕴¹, 曲雨霏¹, 罗钦¹

(1. 重庆理工大学电气与电子工程学院, 重庆 400054; 2. 重庆市能源互联网工程技术研究中心, 重庆 400054)

摘要: 针对电力系统中模块化多电平换流器(modular multilevel converter, MMC)在故障诊断过程中存在提取特征信息易遗漏、诊断精度低和计算量大等问题, 提出一种基于模态时频图与残差网络(residual network, Resnet)-双向门控循环单元(bidirectional gated recurrent unit, BiGRU)模型的分立化 MMC 开路故障诊断方法。根据开路故障特性, 合理选择输出相电流和桥臂电压作为故障参量。使用改进灰狼优化算法搜寻自适应噪声完全经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)过程中的最优参数, 结合 CEEMDAN 最优参数将故障参量分解为敏感且优质的固有模态(intrinsic mode function, IMF)分量并进行重构。为充分挖掘重构信号中的敏感成分, 利用连续小波变换将重构信号转化为模态时频图; 将不同故障类别下的模态时频图输入到 Resnet-BiGRU 模型中进行训练、测试并输出诊断结果, 完成对故障桥臂的诊断与子模块中故障绝缘栅双极型晶体管(insulated-gate bipolar transistor, IGBT)的定位。实验结果表明: 其诊断故障桥臂与定位子模块中故障 IGBT 的准确率分别达到 98.63%和 99.87%, 诊断精度高; 诊断过程拥有秒级响应时间; 与其他方法相比, 所提方法在小样本、数据不平衡和噪声干扰等极端条件下具有较高准确率, 为电力系统故障诊断提供了一种新思路。

关键词: 模块化多电平换流器; 开路故障诊断; 模态时频图; Resnet-BiGRU 模型

Open-circuit fault diagnosis of MMC sub modules based on modal time-frequency diagrams and the Resnet-BiGRU model

LIU Shuxi^{1,2}, LIU Ke¹, WANG Qianyun¹, QU Yufei¹, LUO Qin¹

(1. School of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China;

2. Chongqing Energy Internet Engineering Technology Research Center, Chongqing 400054, China)

Abstract: There are problems of easy omission of extracted feature information, low diagnostic accuracy and large computation volume in the fault diagnosis process for the modular multilevel converter (MMC) in power systems. Thus a discretized MMC open-circuit fault diagnosis method with modal time-frequency diagrams and Resnet-BiGRU model is proposed. From the open-circuit fault characteristics, the output phase currents and bridge arm voltages are selected as fault parameters. The improved gray wolf optimization algorithm is used to search the optimal parameters in the process of complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN). Combined with the optimal parameters of CEEMDAN, the fault parameters are decomposed into sensitive and high-quality intrinsic mode function (IMF) components and reconstructed. To fully exploit the sensitive components in the reconstructed signals, those signals are transformed into modal time-frequency diagrams using continuous wavelet transforms; the modal time-frequency diagrams in different fault categories are input to the Resnet-BiGRU model for training, testing and outputting the diagnostic results, so as to complete the diagnosis of the faulty bridge arms and the localization of the faulty IGBT in the sub modules. The experimental results show that: its diagnosis of faulty bridge arms and localization of faulty IGBT in the sub modules reach an accuracy of 98.63% and 99.87%, with high diagnostic accuracy; the diagnostic process possesses a response time of seconds; compared with other methods, the proposed method has a higher accuracy in extreme conditions such as small samples, data imbalance, and noise interference. The work provides a new way for the diagnosis of power system faults.

This work is supported by the National Natural Science Foundation of China (No. 52207004).

Key words: modular multilevel converter; open-circuit fault diagnosis; modal time-frequency diagrams; Resnet-BiGRU model

基金项目: 国家自然科学基金项目资助(52207004); 重庆市教委科学技术研究计划项目资助(KJQN202001128)

0 引言

近年来,随着电力系统复杂性增加,其故障诊断和保护变得至关重要,模块化多电平换流器(modular multilevel converter, MMC)拥有新能源能量转换效率高、在柔性直流输电中的独立有功无功功率控制能力强以及对异步联网的高效支持等优点,现阶段在电力新能源分配、柔性直流输电技术和特种大功率变流装备等相关领域应用广泛^[1]。由于工业应用中的 MMC 输出电平数在不断升高,其内部子模块(sub modules, SM)的数量也持续增加,所有子模块中功率管等电气元件都可能变成潜在故障发生点。文献[2]指出换流器发生故障的原因大部分来自绝缘栅双极型晶体管(insulated-gate bipolar transistor, IGBT), IGBT 故障通常有短路与开路两种类型,短路故障虽破坏力度大,但驱动电路部分往往有熔断装置对发生短路部分进行切除^[3],而开路故障特征表现不明显,若没有合适的诊断方法可能会使 MMC 发生三相不对称与电压输出波形产生畸变等问题,严重影响电力系统安全稳定运行。

现阶段 MMC 中 IGBT 开路故障诊断的研究基本分为 3 类,即基于硬件、基于模型和基于人工智能。随着信息化时代的到来,基于人工智能的定位方式逐渐取代其他方法,将以人工智能为主体的信息化技术与电力科学深度结合,现逐渐成为研究焦点。因其克服了对数学模型的依赖,通过对 MMC 状态变量如桥臂电压和输出电流等数据进行特征提取和故障诊断,其中特征提取的过程又被称为特征工程,它直接决定了后续故障诊断模型设计的复杂性,建立特征工程是故障诊断的关键之一,即应用人工智能进行故障诊断包括两步:特征工程的建立和诊断模型的设计^[4]。因此研究人工智能背景下的 MMC 子模块中 IGBT 开路故障诊断方法是有意义的。

从建立特征工程上来看,文献[5]通过快速傅里叶变换对级联 H 桥多电平逆变器开路故障原始数据进行了特征提取,但在处理过程中存在频谱泄漏以及负载敏感性的问题。文献[6]采用离散傅里叶分析方法,分析了 MMC 三相电压的高频谐波,并以此为依据进行故障检测,但当不同故障产生相似的高次谐波时,这种方法只能实现故障的检测而无法准确定位故障发生的具体位置,尤其是在 IGBT 模块中的故障定位上存在一定的局限性。文献[7]结合经验模态分解(empirical mode decomposition, EMD)进行特征提取,无需人为设定阈值,故障诊断迅速,但 EMD 属于递归式分解,易出现模态混叠,使诊断精度受到影响。为解决 EMD 的不足,文献[8]利

用集合经验模态分解的方法来提取信号特征,即在 EMD 的基础上加入了均值为 0、方差恒定的白噪声,但在分解过程中会残留刚刚引入的白噪声,导致重构信号过程中误差较大。文献[9]通过小波包分解提取各时段特征熵作为信号特征,但是小波变换不能自适应分解,存在频带遗漏等问题。文献[10]提出了一种改进变分模态分解,对复杂信号适应性较强,对故障信号分解也有不错的应用效果,但是对数据做平均或抽样操作时会忽略部分信息。文献[11]利用自适应噪声完全集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)算法对上述方法的不足做出改进,通过在信号分解阶段自适应加入高斯白噪声,得到重构误差可忽略不计的固有模态函数(intrinsic mode function, IMF)分量,可解决模态混叠、重构误差大和频带遗漏等问题,完备性较佳,但是该方法需要人为设计较多参数,主观性较强,易丢失故障信息。

从设计诊断模型上来看,基于深度学习的诊断模型因其在缺陷识别与故障检测等相关领域的卓越表现而被广泛应用。文献[12]利用传感器来采集原始 SM 电容电压并结合一维卷积神经网络(convolutional neural network, CNN)来对 MMC 进行诊断与定位,但当 SM 数量剧增时,采集故障过程中的数据量会呈爆炸级上升趋势,导致 CNN 模型会产生“维度爆炸”等参数灾难问题。文献[13]利用一种改进型深度可分离卷积网络来分离高度耦合的 SM 故障信号特征,但在模型训练中常涉及大量浮点小数的计算,计算机内部算力资源消耗较大。文献[14]提出了一种新的功率器件开路故障诊断方法,该方法基于一维深度学习混合型网络,可有效避免因依赖人工专家知识而可能出现的故障特征泄露等问题,但模型输入端只能为一维长时序数据,无法充分捕捉故障特征相关空间信息。文献[15]将 SM 电容电压叠加为多通道数据带集合,并将其输入至自动编码器中进行训练与测试,但其叠加通道数是 24,其通道数量过多,计算量太大,导致利用效率不高。文献[16]利用自动编码器和极限小波学习机对 SM 电容电压内部蕴含的故障特征进行提取并对桥臂故障进行诊断,其诊断精度较高,但 SM 数量过多时计算量较大。

综上所述,本文提出一种基于模态时频图与残差网络(residual network, Resnet)-双向门控循环单元(bidirectional gated recurrent unit, BiGRU)模型的新方法。首先,深入分析 MMC 在正常与异常状态下的基本运行原理,采用能够有效区分各类故障类别的电信号作为故障特征量,将其作为后续解决故障诊断问题的基础;其次,采用经过改进灰狼算

法(the improved gray wolf algorithm, IGWO)优化后 CEEMDAN 算法将复杂的故障参量信号逐步分解为敏感且优质的 IMF 分量, 确保各模态分量不会混叠, 将 IMF 分量进行叠加重构, 利用连续小波变换将其转换为模态时频图, 提升特征提取的性能; 最后, 结合 Resnet 单元与 BiGRU 单元来搭建故障诊断模型, 以此来提高分类诊断精度, 检验此法对 MMC 中 IGBT 开路故障的诊断和定位能力。实验表明该方法能减少数据计算量, 使模型诊断与定位速度加快, 准确定位故障位置, 迭代次数少, 在不平衡和噪声干扰等极端条件下仍可达到较高准确率。

1 MMC 故障特性分析及特征变量选取

目前在电力工业上应用最广泛的三相 MMC 拓扑结构如图 1 所示。MMC 每一相由串联 N 个子模块的上下桥臂连接而成, 上下桥臂中间串联两个对相间环流起抑制作用的电抗器。 u_{jo} 和 i_{jo} ($j = A, B, C$) 分别为交流侧输出相电压和相电流; L 为桥臂电抗值; U_{dc} 为直流侧电压; I_{dc} 为直流侧电流; u_{jp} 和 u_{jn} 分别为上、下桥臂电压; i_{jp} 和 i_{jn} 分别为上、下桥臂电流。左上为半桥子模块结构, 其中 T_1 和 T_2 为子模块中的 IGBT, u_c 为子模块电容电压。

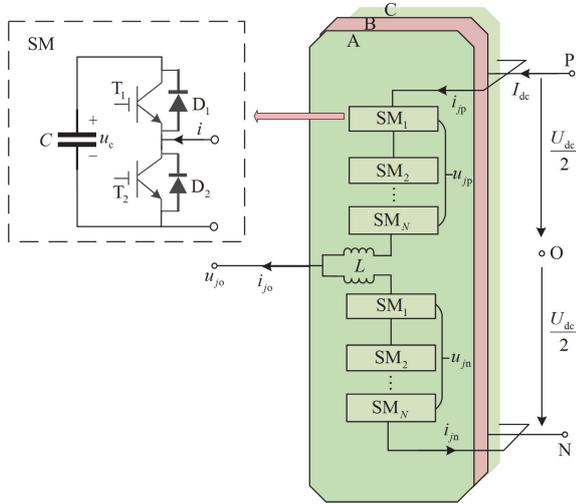


图 1 MMC 拓扑图

Fig. 1 MMC topology diagram

MMC 正常工作时 SM 电流 i 的流向路径如表 1 所示。

表 1 中, 在模式 1 和 2 下 MMC 中子模块的 u_c 和输出电压相等; 若某个 SM 被切除, 那么输出电压会逐渐衰减为 0。在正常工作下的 MMC 每相子模块都是交替工作的, 其电压和始终保持为 U_{dc} 。为了确保 MMC 交流端口正常输出三相电压, 只需

保证每个 SM 的开断状态投切合理即可。

表 1 SM 电流 i 流向路径

Table 1 SM current i flow path

模式	T_1	T_2	i	流经器件	电容状态	工作条件
1	开	断	>0	D_1 -C	充电	投入
2	开	断	<0	C- T_1	放电	投入
3	断	开	>0	T_2	旁路	切除
4	断	开	<0	D_2	旁路	切除
5	断	断	>0	D_1 -C	充电	闭锁
6	断	断	<0	D_2	旁路	闭锁

MMC 子模块中 T_1 若发生开路故障, 在表 1 中模式 2 下会对 MMC 造成影响; 子模块中 T_2 若发生开路故障, 在表 1 中模式 3 下会对 MMC 造成影响。如图 2(a)所示, 在子模块工作时电容应该正常放电, 但 T_1 开路故障时电流将会经过二极管 D_2 使得电容不能经 T_1 放电, 此刻正常 u_c 会低于故障 u_c ; 图 2(b)中当 T_2 发生开路故障, 电流会通过二极管 D_1 , 电容将被串联至电路中使其不能被 T_2 旁路从而被迫充电, 此刻正常 u_c 也会低于故障 u_c 。

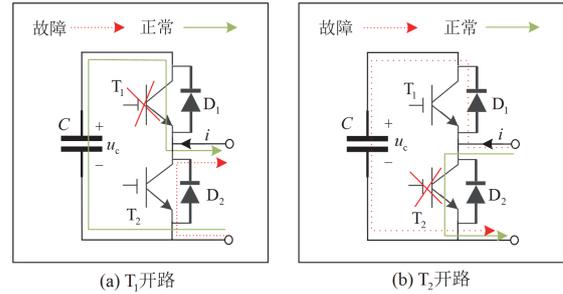


图 2 子模块中 IGBT 不同开路故障下的工况

Fig. 2 Working conditions of IGBT under different open circuit faults in the SM

在 IGBT 发生开路故障后, 故障 u_c 均会异于正常 u_c , 可以考虑选用 u_c 作为故障检测与定位的指标, 但在 MMC 中子模块数量过多, 单独以 u_c 作为故障特征参量, 会导致数据量过大, 特别是利用深度学习模型时会产生维数灾难等问题。因此需要找到计算量不大且能反映有关特征的参量, 以减少计算量。

当子模块中 IGBT 出现开路故障时, 会导致直流分量进入交流侧。当第 j 相上桥臂发生故障时, 该桥臂会出现正的直流分量, 其平均值为最大且为正, 根据 KCL 定理, 三相电流在任意时间其电流和都为 0, 其他两相会出现负的直流分量, 均值为负。当第 j 相下桥臂发生开路故障时三相电流情况与第 j 相上桥臂发生故障时刚好相反, 即不同的相中 IGBT 开路故障时, 输出三相电流可用于故障桥臂诊断, 根据三相电流的变化规律可以定位到具体的

故障桥臂；在 MMC 工作过程中，子模块的桥臂电压和每一个子模块的开关状态有关，每个子模块的开关状态受 MMC 调制策略的影响。在载波移相控制下，子模块的开关时序信号是固定的，当有子模块发生故障时，不同故障子模块带来的桥臂电压数据是有差别的，而且每个子模块故障对应的数据特点不会改变。即在载波移相控制策略下，桥臂电压可以用于子模块中故障 IGBT 的定位。

综上，选择三相电流和桥臂电压作为诊断故障桥臂与定位子模块中故障 IGBT 的故障特征变量。

2 MMC 故障诊断基本算法

2.1 IGWO-CEEMDAN 算法

CEEMDAN 在对故障信号进行自适应分解中参数往往是人为设计的，随机性太强，可能会使故障信号分解的不彻底，为此针对 CEEMDAN 优化参数的问题，提出 IGWO 策略来寻找最优参数。

传统 GWO 算法来源于大自然中狼群的分工与觅食行为，是一种通过模拟灰狼的层次结构和捕食行为的智能算法。GWO 的种群结构为正金字塔形，社会等级第一层为 α 狼， α 狼主要负责对捕食和栖息等活动做出决策；第二层为 β 狼，它服从 α 狼并协助其做出决策；第三层为 δ 狼，它服从 α 狼和 β 狼的命令，同时支配下层阶级的狼；最底层为 ω 狼，它通常需要服从高级层次的狼，是整个种群的基础。GWO 算法将每只狼视为一个潜在解，其中 α 狼为第一最优解， β 狼和 δ 狼分别为第二最优解和次最优解， ω 狼为候选解。GWO 算法本质上是一个不间断的更新 α 狼、 β 狼和 δ 狼位置的优化迭代过程。其迭代过程主要包括追捕、围猎和攻击阶段，其具体实现步骤在文献[17]中已有详细介绍。

MMC 开路故障种类多且特征相似导致难以凭借经验进行故障诊断，借助 CEEMDAN 算法将 MMC 中的复杂信号分解为不同尺度下的 IMF 分量

和残差分量，但在分解完复杂信号后产生 IMF 分量数目过多，可能存在虚假分量，利用相关系数-峭度准则可消除虚假分量，保留敏感 IMF 分量便于后续对于重构信号的构建。通过相关系数-峭度准则可以筛选出含有故障信息最多和冲击成分最强的 IMF 分量，方便后续转换出的模态时频图含有主要故障特征成分。

现多数研究中 CEEMDAN 算法的噪声幅值权重 W 和添加次数 N 均采用默认设定^[18]，缺乏固定的选择标准。但 MMC 故障信号具有非常复杂的非线性特征，采用单一参数标准无法适用于复杂信号，会在分解过程中存在误差，导致相邻 IMF 分量中含有共模成分，出现模态混叠现象。传统 GWO 算法在寻找最优参数时，由于灰狼个体缺乏变异机制，导致在进化过程中因种群多样性的缺失造成局部最优解。为了解决此问题，本文提出基于柯西高斯变异算子的 IGWO 寻优策略。即利用柯西高斯算子在变异过程前后选择处于最优位置的灰狼个体进行下一次迭代，以避免局部最优解产生，提高全局搜索的能力。将柯西高斯算子引入传统 GWO 算法中，得到 α 、 β 和 δ 三狼更新后的位置为

$$X_{best} = X(t+1)[1 + \lambda_1 Cauchy(0, \sigma^2) + \lambda_2 Gauss(0, \sigma^2)] \quad (1)$$

式中： X_{best} 为灰狼变异后的最优位置； λ_1 和 λ_2 为迭代自适应调整参数，当 λ_1 减小、 λ_2 增大时，灰狼可摆脱局部最优解状态； σ 为标准差系数； $Cauchy(0, \sigma^2)$ 和 $Gauss(0, \sigma^2)$ 分别为柯西和高斯分布随机变量。

为了验证本文所提 IGWO 算法的优越性，采用不同测试函数对 IGWO 算法、传统 GWO 算法、粒子群优化(particle swarm optimization, PSO)算法和麻雀搜索(sparrow search algorithm, SSA)算法进行测试。在测试中设置各算法的种群数量为 50，迭代参数为 1000，适应度函数为最小样本熵，各算法对不同测试函数均进行 10 次寻优试验，一次试验中各算法在不同测试函数上的收敛曲线如图 3 所示。

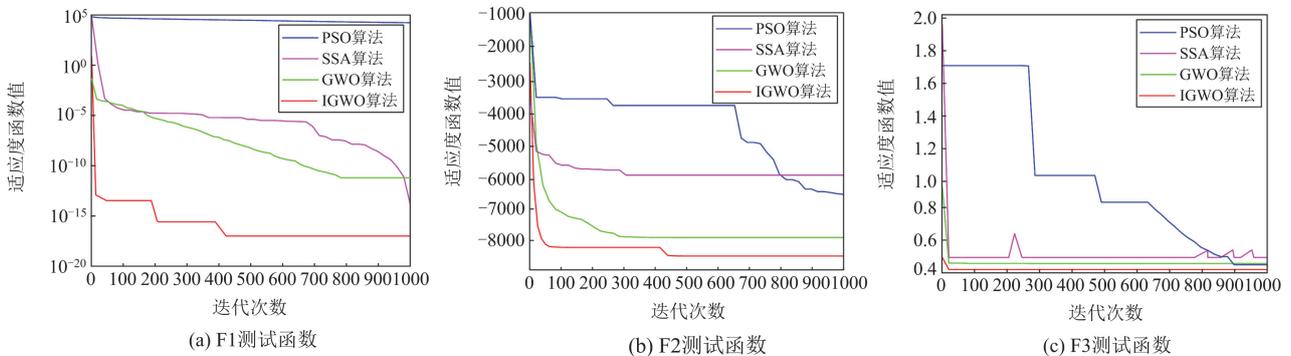


图 3 不同寻优算法在测试函数上的收敛曲线

Fig. 3 Convergence curves of different optimization algorithms on test functions

图 3 中, 针对不同测试函数, 当适应度函数开始收敛时, IGWO 算法的迭代次数总是最少的, 收敛速度快; PSO、SSA 和 GWO 算法收敛曲线在不同测试函数上随着迭代次数的增加, 出现了走势平缓陷入局部最优解且缺乏全局优化能力和走势振荡未达到收敛且缺乏局部搜索能力的问题, IGWO 算法的收敛曲线呈快速阶梯式下降, 有效跳出了局部最优解的局面, 以便继续寻找最优解, 取得最佳收敛精度。由此证明, IGWO 算法无论是在收敛速度还是收敛精度上均优于其他算法, 因此 IGWO 算法的寻优性能得到进一步提升, 可用于 CEEMDAN 的参数寻优中。IGWO-CEEMDAN 寻优算法的步骤如下所述。

(1) 设计 CEEMDAN 算法的参数搜索范围, 同时初始化 IGWO 的种群规模、加速变量极值、运行迭代次数、优化参数 W 和 N 的范围。

(2) 随机生成灰狼群落, 各个灰狼群落的个体坐标包括两个维度, 分别是初始值 W 和 N , 根据给定的初始值 W 和 N 来计算 CEEMDAN 算法后的 IMF 分量的适应度函数值, 个体的适应度值由样本的最小样本熵来表征。

(3) 计算每条灰狼的适应度, 根据适应度的大小将灰狼种群划分为 α 狼、 β 狼、 δ 狼和 ω 狼这 4 个等级, 对群落中的个体进行坐标更新, 利用柯西高斯变异策略对灰狼个体进行位置更新, 并更新全局最优解。

(4) 如果迭代次数大于允许次数, 则结束寻优过程, 输出最优参数 (W_{best}, N_{best}) , 否则, 继续循环步骤(3)直到获得最优参数。

(5) 将获得的 (W_{best}, N_{best}) 导入 MMC 故障信号的 CEEMDAN 分解过程中, 从而得到优质且敏感的 IMF 分量。

2.2 模态时频图转化算法

连续小波变换(continuous wavelet transform, CWT)在处理复杂信号过程中, 会存在分解不彻底和频带泄漏等问题, 导致小波时频图提取特征性能不足^[19]。经过 IGWO-CEEMDAN 算法后可以有效解决该问题, 将复杂信号分解为敏感且优质的单模态分量信号 IMF1、IMF2、 \dots 、IMFK, 既保证原始信号的完备性, 又增强对时频特征的提取能力。

在 CWT 过程中选择合适的小波基函数是时频图转换的关键^[20], 由于 MMC 故障信号产生的冲击特性与 Morlet 小波相似, 但其缺点是过渡带较宽, 通带不够平直。基于此提出复数 Morlet 小波基函数, 其相比于 Morlet 小波具有更加优秀的自适应性, 适用于处理时频局部化要求较高的信号, 复数 Morlet 小波的数学表达式如式(2)所示。

$$\omega(t) = (\pi F_b)^{0.5} e^{2i\pi F_c t} e^{-t^2/F_b} \quad (2)$$

式中: $\omega(t)$ 为频率变化量; F_b 和 F_c 分别为带宽因子与中心频率因子。

假设 IGWO-CEEMDAN 算法分解故障信号得到敏感且优质的 IMF1、IMF2、 \dots 、IMFK 分量, 将 IMF1、IMF2、 \dots 、IMFK 分量进行重构以提高信号纯净度。以重构信号作为 CWT 的输入, 生成模态时频图, 以模态时频图作为后续 MMC 诊断模型的输入。

2.3 Resnet-BiGRU 模型算法

Resnet 作为残差块核心结构的深度学习网络架构, 相比于浅层网络, 它拥有更多的非线性结构映射层, 这使得其非线性表达能力会随着网络深度的增加而显著增强, 这种结构的巧妙设计有效缓解了梯度反向传播过程中可能出现的消失爆炸问题。

针对 MMC 在发生开路故障后采集的电信号数据具有明显的时序特性, 借助 RNN 可以更好地捕捉采集数据间的时序相关性, 深入分析与挖掘数据间的相互联系。GRU 作为 RNN 的改进版本, 不仅保持对时序数据的敏感特性, 相比于 LSTM, 在减少参数量、提升模型训练效率以及降低过拟合风险等方面更具明显优势。GRU 基本结构如图 4 所示。

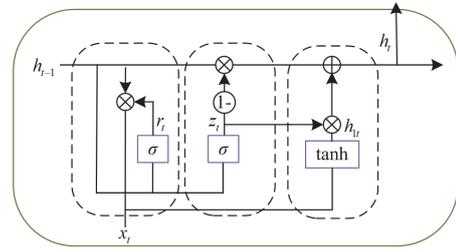


图 4 GRU 基本结构

Fig. 4 GRU basic structure

图 4 中, GRU 有重置门 r_t 与更新门 z_t , r_t 是控制新信息和历史信息结合的量, z_t 是控制历史信息及时保存至当前时间戳的量。当 GRU 使用 t 时刻的输入 x_t 和前一时刻的输出 h_{t-1} 作为输入时, 有

$$r_t = \sigma(W_{rx}x_t + W_{rh}h_{t-1} + b_r) \quad (3)$$

$$z_t = \sigma(W_{zx}x_t + W_{zh}h_{t-1} + b_z) \quad (4)$$

$$h_t = \tanh(W_{hx}x_t + r_t \odot h_{t-1}W_{hh} + b_h) \quad (5)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot h_t \quad (6)$$

式中: W_{rx} 、 W_{rh} 、 W_{zx} 、 W_{zh} 、 W_{hx} 、 W_{hh} 和 b_r 、 b_z 、 b_h 均为不同节点神经网络的权重矩阵和偏置向量; \odot 为点乘运算; σ 和 \tanh 为激活函数; h_t 为候补隐藏状态; h_t 为传递到下一时刻的隐藏状态。

BiGRU 的基本结构如图 5 所示。图 5 中 BiGRU

由两个相反方向的 GRU 单元组成，二者分别起着捕获过去时序信息和未来时序信息的作用。最终将捕获的信息结果进行输出并按照对应维度进行位置合并，以加强整体模型的预测准确性。

对于 Resnet 结构，虽然可以挖掘数据之间的内在关联，但无法充分利用 MMC 中故障数据的时序特性；而单一 BiGRU 结构虽然可以充分发挥故障数据之间的时序特性，但对于故障数据中的原始关联性表征不足。故本文结合二者优点，将 Resnet 单元和 BiGRU 单元相结合的故障诊断模型如图 6 所示。

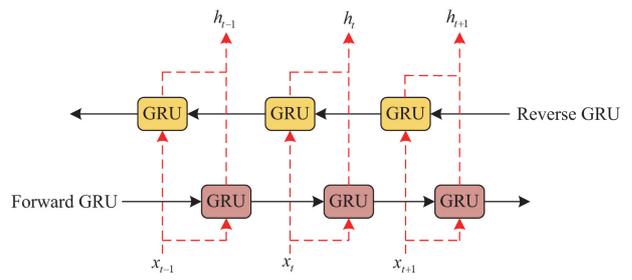


图 5 BiGRU 基本结构

Fig. 5 BiGRU basic structure

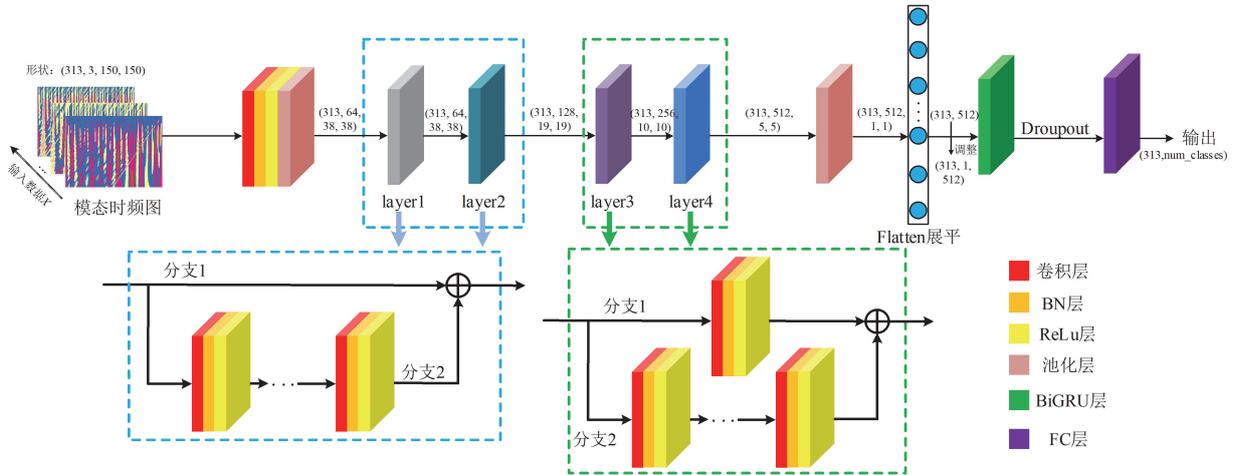


图 6 Resnet-BiGRU 基本结构

Fig. 6 Resnet-BiGRU basic structure

Resnet-BiGRU 模型由卷积模块、Resnet 模块与 BiGRU 模块构成。通过卷积模块初步提取模态时频图故障特征，再引入 4 个 Resnet 模块，利用不同分支结构来构成不同的映射以此来学习不同权重大小，使故障特征的学习能力得到再次增强，可解决传统模型中易出现的梯度消失和爆炸等问题，再将相应特征融合后输入至 BiGRU 模块，充分挖掘故障信息分量的时空特征，捕捉故障信息中的动态变化，弥补 Resnet 网络在处理动态序列中的不足。将 Resnet 与 BiGRU 相结合，并在整体融合模型中进行模块化串行连接，充分利用两者优势，从模态时频图中提取出既包含空间特征又包含时序特征的信息，以提高模型的收敛速度、拟合能力和语义记忆能力，进一步提高 MMC 故障诊断的准确性。

Resnet-BiGRU 模型能缓解梯度消失和爆炸问题、捕捉长序列之间的语义关联、提高模型的泛化能力和加快模型的收敛速度。

3 MMC 故障诊断流程

为实现 MMC 中故障桥臂的诊断与子模块故障

IGBT 的定位，现提出一种 MMC 分立化诊断方法，具体如下所述。

(1) 根据诊断思路，以九电平 MMC 为诊断对象，利用实验平台模拟 7 种桥臂运行状态，对不同桥臂故障下的输出相电流 i_{jo} 进行采样，将其作为诊断桥臂的原始信号；确定 MMC 发生故障的桥臂后，以故障桥臂为诊断对象，基于实验平台模拟桥臂中 17 种子模块中 IGBT 运行状态，对不同 IGBT 故障下桥臂电压 u_{jp} 进行采样，将其作为定位故障 IGBT 的原始信号。

(2) 将 i_{jo} 和 u_{jp} 进行归一化处理，不同故障类别下的 i_{jo} 和 u_{jp} 通过滑动窗口特征提取算法分割样本，得到原始电流样本 1 和原始电压样本 2。

(3) 对(2)中采集到的原始电流样本数据和原始电压样本数据进行 IGWO-CEEMDAN，得到一系列敏感且优质的 IMF 分量，并将 IMF 分量进行重构，将重构信号作为 CWT 输入，生成模态时频图。对模态时频图进行预处理后得到故障桥臂诊断数据集 1 和故障 IGBT 定位数据集 2，将数据集 1 和数据集

2 随机划分为训练集、验证集和测试集, 三者数据互不交叉。训练集用于输入到设置好参数的 Resnet-BiGRU 模型中进行训练, 每一轮次训练结束后, 验证集都会进行模型寻优验证, 以此来确保模型在训练过程中持续优化, 性能会不断提升, 则需调整模型超参数。当训练到达设定迭代次数后, 将训练模型保存, 用于后续测试。

(4) 将测试集输入到(3)中保存的模型, 对模型性能进行评估, 若评估结果显示此时模型诊断与定位的能力并未达到最优, 接着返回(3)中再次进行模型训练与验证, 直到模型性能达到一定的标准, 则此刻可训练出性能最优模型, 后续可将该离线模型投入到实际 MMC 工作生产中进行在线诊断。

图 7 所示为 MMC 故障诊断整体流程图。

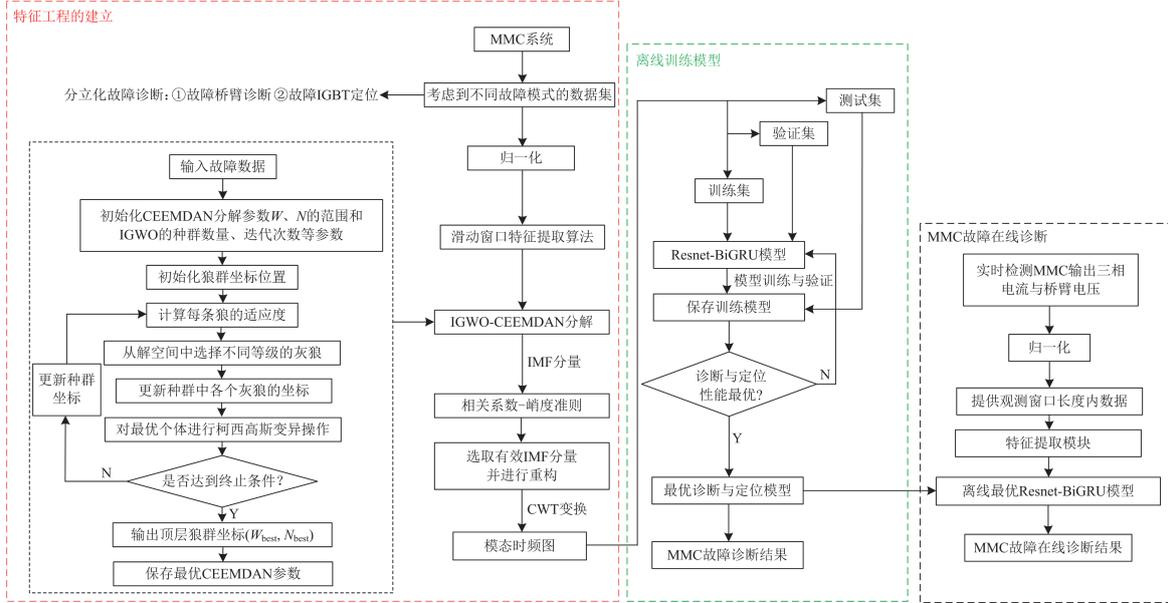


图 7 MMC 故障诊断整体流程图

Fig. 7 MMC failure diagnosis overall flowchart

4 实验与分析

4.1 MMC 分立化故障诊断与定位数据集制作

为了检验本文方法的准确性, 现利用 Matlab/Simulink 平台设计了三相 MMC 系统, 并经过如图 8 所示的实时半实物平台(real time semi-physical laboratory, RT-LAB)来验证所搭建 MMC 系统的可行性。通过图 8 中示波器的实际显示结果与仿真结果对比, 发现两者显示出高度的一致性, 即得出所搭建的 MMC 系统在实际应用中有一定的可行性。MMC 系统的部分设计参数及其取值如表 2 所示,

不同故障类别下样本标签及其数量如表 3 所示, 其中 C_down 表示 C 相下桥臂, $SM_8_T_2$ 代表第 8 个子模块中第 2 个 IGBT。

表 2 MMC 系统部分参数

Table 2 MMC system partial parameters

参数	取值	参数	取值
子模块总数量/个	48	负载电感 L_f /mH	15
直流母线电压 U_{dc} /V	800	开关频率 f_s /Hz	1500
桥臂电抗 L /mH	4.7	基频/Hz	50
子模块电容 C /mF	3.5	额定功率 P /kW	20
负载电阻 R /Ω	15	调制比 m	0.95

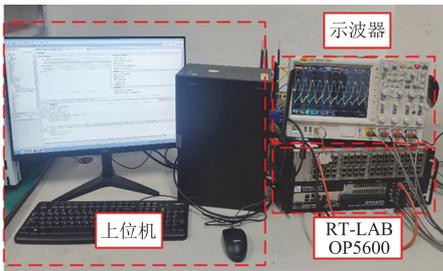


图 8 验证 MMC 系统可行性过程的 RT-LAB

Fig. 8 RT-LAB to verify the feasibility of MMC system

表 3 故障类别样本标签和数量

Table 3 Failure category sample labels and quantities

桥臂故障类别	样本标签	样本数量	子模块中 IGBT 开路故障类别	样本标签	样本数量
正常	0	313	正常	0	313
A_up	1	313	$SM_1_T_1$	1	313
A_down	2	313	$SM_1_T_2$	2	313
⋮	⋮	⋮	⋮	⋮	⋮
C_down	6	313	$SM_8_T_2$	16	313

针对不同桥臂发生故障的诊断问题，MMC 系统工作时间为 0.5 s 并考虑在 0.1 s 时刻模拟不同 IGBT 位置发生开路故障。由表 3 可得可采集 7 组不同相电流数据，其中部分故障下三相输出电流波形如图 9 所示；若诊断出已发生开路故障的所在单相

桥臂，那么只对单相桥臂进行研究即可。现以 A 相上桥臂发生开路故障为例，由表 3 得能够采集 17 组故障类别下的 A 相上桥臂电压，部分故障下 A 相上桥臂电压波形如图 10 所示。

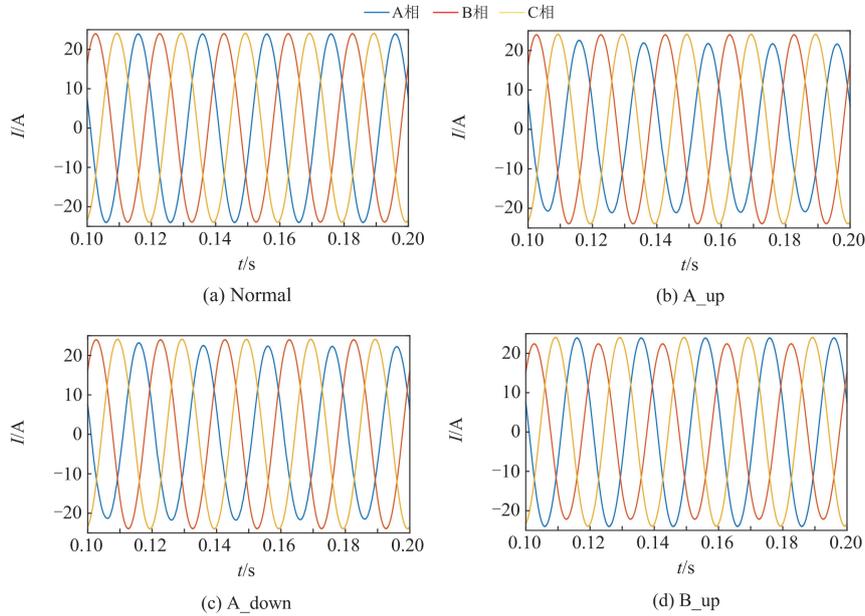


图 9 部分故障类别下的 MMC 输出相电流

Fig. 9 MMC output phase current under partial fault categories

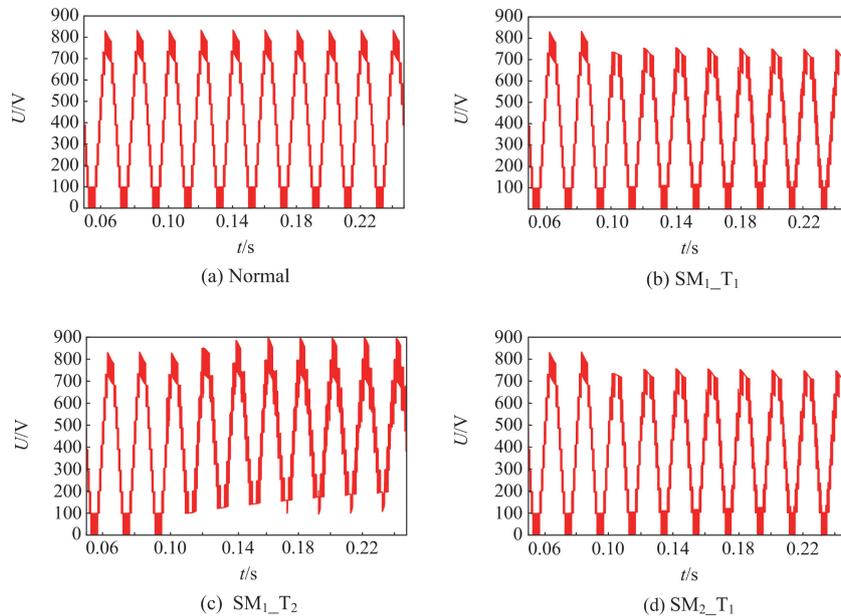


图 10 部分故障类别下的 MMC 桥臂电压

Fig. 10 MMC bridge arm voltage under partial fault categories

图 9 中，直接采集三相输出电流作为诊断模型的故障参量，会导致因计算量过大而出现维数灾难

问题。为解决此问题，现提取对应故障类别下的故障相电流作为故障参量，图 9 中 MMC 在正常工作

时不同相的上下桥臂故障后差异性较大, 可提取出有效故障信息, 但同相上下桥臂电流波形在时域上观察区别较小, 难以挖掘有效故障信息, 现需要更加精细的特征提取方法来进行处理。文献[21]中提出一种滑动窗口特征提取算法来对离线数据进行处理, 动态更新所得故障数据, 以扩充样本量, 综合考虑下设计滑动窗口长度为 2000 个采样点, 滑动步长为 250 个采样点, 则故障相电流信号可依次分为 313 个样本, 总样本数为 $313 \times 7 = 2191$ 个。图 10 中相同子模块中不同位置上 IGBT 在发生开路故障后其桥臂电压有明显畸变, 但不同子模块相同位置上 IGBT 在发生开路故障后桥臂电压通过时域观察来

进行分辨较为困难, 同样需精细的特征提取方法来处理。现设计滑动窗口长度为 2000 个采样点, 滑动步长为 250 个采样点, 则故障桥臂电压信号可依次分为 313 个样本, 总样本数为 $313 \times 17 = 5321$ 个。

对不同故障类别下的相电流样本与桥臂电压样本进行 IGWO-CEEMDAN, 以 A 相上桥臂发生故障和 SM_1 中 T_1 发生开路故障为例进行分析, 设计 IGWO 算法的灰狼种群规模为 10, 最大迭代次数为 500, 适应度函数为最小样本熵值, 噪声幅值权重 W 和添加次数 N 的优化范围分别是 $[0.15, 0.65]$ 和 $[50, 650]$ 。IGWO 算法迭代曲线如图 11 左侧所示。

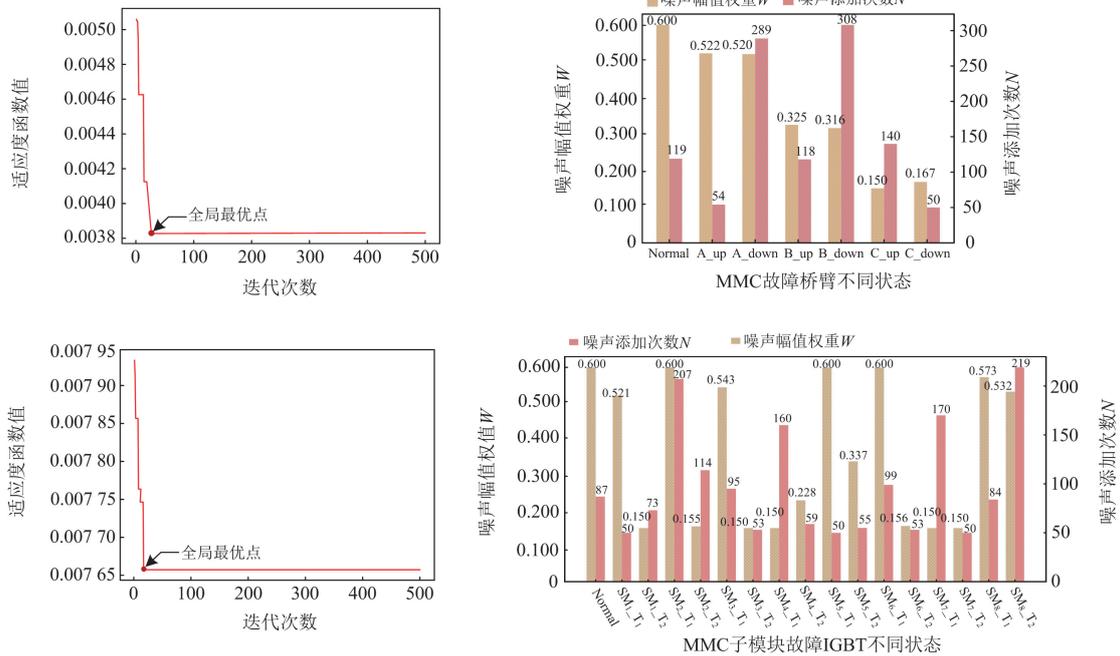


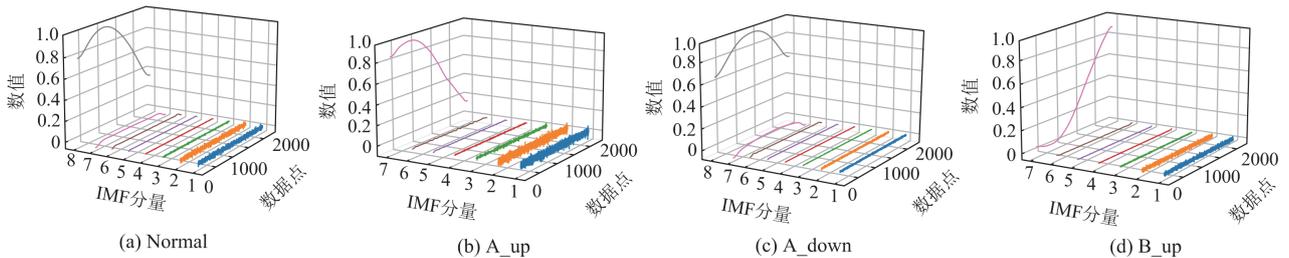
图 11 IGWO 算法迭代曲线和 CEEMDAN 最优参数

Fig. 11 IGWO algorithm iteration curve and CEEMDAN optimal parameters

图 11 左侧中 IGWO 算法无论是诊断桥臂还是定位子模块故障 IGBT 都能在迭代初期到达全局最优点, 迭代速度快, 性能优异, 成功实现收敛。将图 11 右侧中的最优参数代入 CEEMDAN 中, 对 MMC 故障信号进行自适应分解。部分故障类别下的 IGWO-CEEMDAN 算法分解结果如图 12 所示。为了避免虚假分量影响后续分析和减少了对故障

特征的分析维度, 利用相关系数-峭度准则来评估各 IMF 分量与原始信号的紧密程度。以 A 相上桥臂和 SM_1 中 T_1 发生开路故障为例, IMF 分量的峭度与相关系数图如图 13 所示。

图 13 中, 不同故障类别下的前四阶 IMF 分量的相关系数和峭度较大, 说明这些 IMF 分量包含的原始故障信息与冲击能量较多, 则选择 IMF1、IMF2、



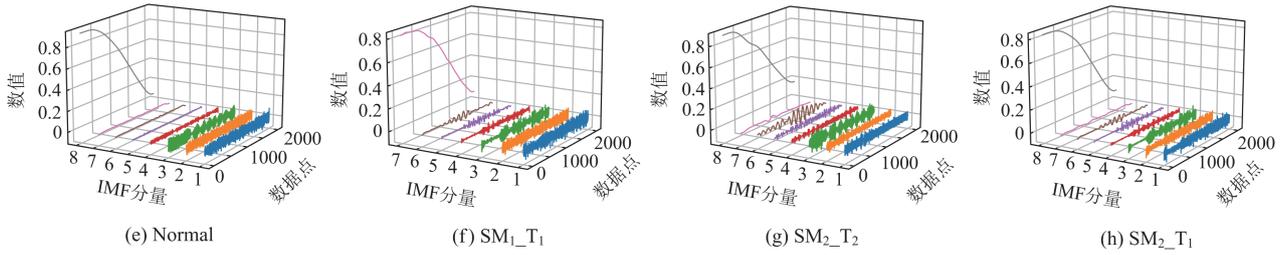


图 12 部分故障类别下 IGWO-CEEMDAN 算法分解结果

Fig. 12 Decomposition results of the IGWO-CEEMDAN algorithm in partial failure categories

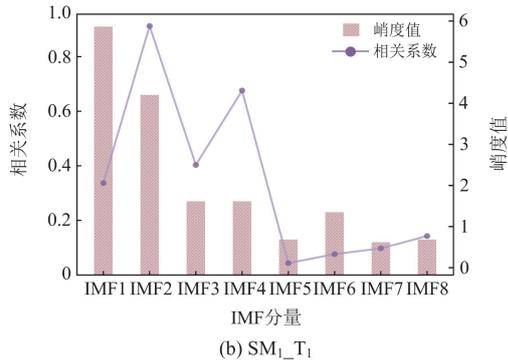
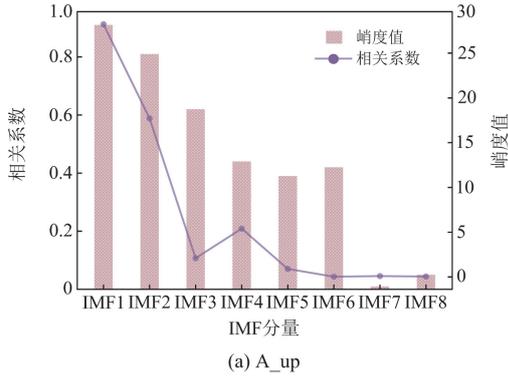


图 13 部分故障类别下 IMF 分量峭度-相关系数图

Fig. 13 Plot of IMF component cliff-correlation coefficients for partial failure categories

IMF3 和 IMF4 分量为敏感且优质的有效分量, 将有效分量进行叠加重构, 将重构信号作为 CWT 的输入, 其中尺度序列长度选为 128, 小波基函数为复 Morlet 小波, 生成故障信号的模态时频图。

在 MMC 分立化故障诊断与定位中, 根据上述特征提取方法, 在诊断桥臂时, 不同故障类别下可制作 313 张模态时频图, 共计 $313 \times 7 = 2191$ 张模态时频图, 将其组建为诊断数据集 1; 在定位子模块中故障 IGBT 位置时, 不同故障类别下可制作 313 张模态时频图, 总计 $313 \times 17 = 5321$ 张模态时频图, 将其组建为定位数据集 2。在综合考虑下为减少计算资源的浪费, 设计模态时频图分辨率为 150×150 , 将数据集 1 和数据集 2 分别按 7:3 随机划分为训练集

和测试集, 二者互不干扰, 方便应用于诊断模型的训练与测试过程。不同数据集下部分经本文方法转化得来的模态时频图样本如图 14 和图 15 所示。

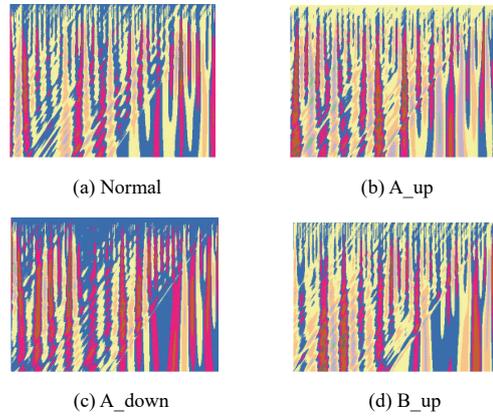


图 14 数据集 1 中部分故障桥臂下模态时频图

Fig. 14 Modal time-frequency diagrams under partial faulty bridge arm in dataset 1

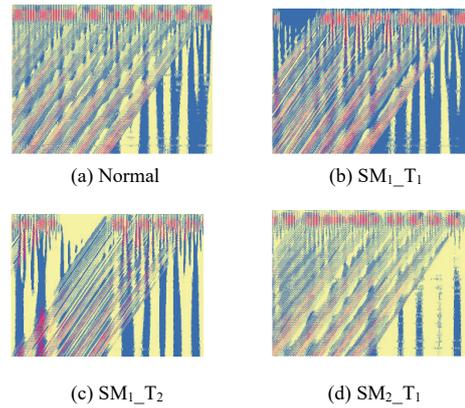


图 15 数据集 2 中部分故障 IGBT 下模态时频图

Fig. 15 Modal time-frequency diagrams under partial faulty IGBT in dataset 2

图 14 和图 15 中, 不管是诊断数据集 1 还是定位数据集 2, MMC 发生开路故障后, 其故障特征完全不一样, 故障特征都清晰易辨, 各种故障类别经过 IGWO-CEEMDAN 后, 去除了很多冗余信息, 保

留了明显的故障特征, 区分度高, 便于后续 Resnet-BiGRU 模型的训练、保存和测试。

4.2 MMC 诊断与定位结果及对比分析

实验过程中硬件参数为: Intel(R) Core(TM) i5-10200H 处理器, NVIDIA GeForce GTX 1650 显卡, 使用 CPU 和 GPU 交叉训练, 16 G 内存, 深度学习框架是 Pytorch, 编程语言是 Python3.11。

在深度学习模型训练中将数据集进行随机洗牌, 模型采用交叉熵损失函数, 便于衡量估计值与实际值间的差异性。利用 Adam 优化算法来根据历史梯度动态调整学习率大小。设定 150 轮迭代, 初始学习率设置为 0.001。考虑到模型更好地收敛, 设计每经过 10 轮迭代, 学习率会减少 10%, 每次迭代样本数量即批大小设定为 32, 利于平衡计算效率。

4.2.1 实验与结果分析

在验证本文所提特征提取方法和诊断模型的可行性研究中, 采用 4.1 节中制作的不同数据集(包括数据集 1 和数据集 2)分别输入至所设计诊断模型中, 不同数据集在模型迭代中, 其训练准确率迅速上升, 损失函数值迅速下降, 能快速适应训练集, 并有效地从数据集的模态时频图中学习故障特征, 如图 16 所示。在迭代轮次约为 35 次时, 数据集 1 和 2 的训练准确率与损失函数值均趋于稳定, 此时模型开始逐渐收敛, 在迭代次数为 150 次时模型达到最好效果。针对数据集 1, 其训练准确率约为 99.93%, 损失率约为 0.001 31, 针对数据集 2, 训练

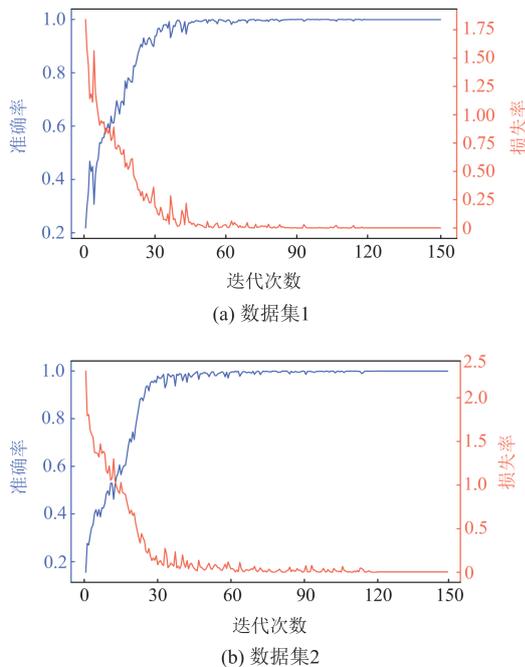
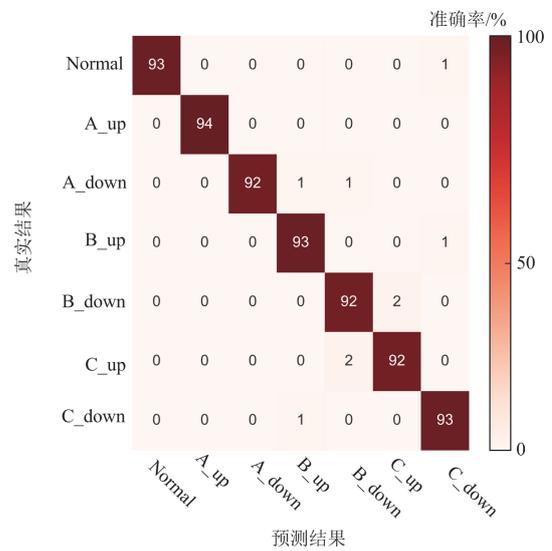


图 16 训练过程中准确率与损失函数曲线图

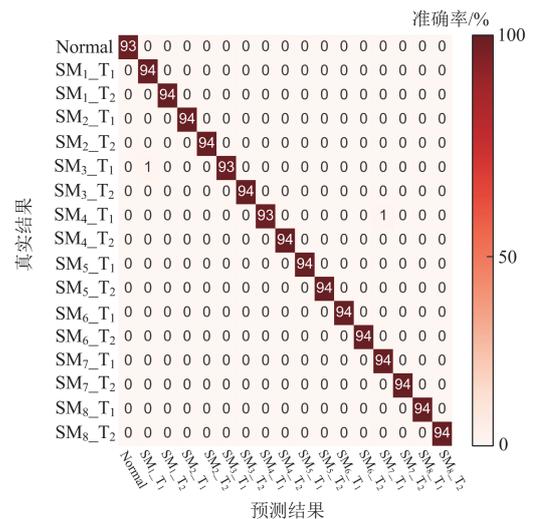
Fig. 16 Plot of accuracy and loss function during training

准确率约为 99.94%, 损失率约为 0.004 68, 此时模型不仅实现收敛状态, 还在不同数据集上表现出极强的泛化性。鉴于在第 150 次迭代时模型性能达到最优, 该模型将被用于后续故障诊断和定位中, 以实现 IGBT 开路故障的快速识别和处理。

为验证 Resnet-BiGRU 模型的泛化能力, 将不同数据集中测试集分别输入至上述第 150 次迭代模型中, 其测试准确率可达到 98.63%和 99.87%。本文基于混淆矩阵对桥臂故障和子模块故障 IGBT 识别准确率等信息进行定量分析, 如图 17 所示。无论是针对数据集 1 或者数据集 2, 不同故障类别下的模态时频图样本都可以被诊断模型进行精确诊断与分类, 识别准确率高, 泛化性能强, 有效诊断发生



(a) 数据集1



(b) 数据集2

图 17 测试过程中诊断结果的混淆矩阵

Fig. 17 Confusion matrix of diagnostic results during testing

故障的桥臂和定位故障 IGBT 位置, 则所提方法具备可行性。考虑到诊断时间的长短, 训练模型的时间不会影响故障诊断系统的性能, 关键在于在线故障诊断过程中的花费时长^[22]。本文将不同测试集输入到已经训练好的目标模型中, 诊断故障桥臂约为 1.35 s, 定位 IGBT 故障位置约为 3.55 s, 模型拥有秒级诊断反应时间, 该诊断模型后续可投入到实际 MMC 运行中进行在线诊断与实时监测。

为了突出本文所提方法对数据集 1 和数据集 2 中相关故障特征的学习性能, 利用 t 分布随机邻域嵌入 (t-distributed stochastic neighbor embedding, t-SNE) 来进行高维度可视化与判断不同样本聚类程度的技术操作。t-SNE 技术将相应阶段的高维特征降维到二维层面并以二维散点图的形式进行可视化, 数据集 1 和数据集 2 中测试集在 t-SNE 技术下的未经预处理原始数据、Resnet-BiGRU 模型输入层数据和输出层数据, 分别如图 18 和图 19 所示。

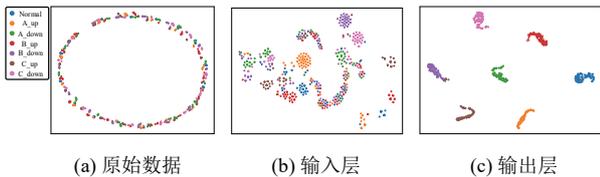


图 18 数据集 1 不同阶段 t-SNE 可视化

Fig. 18 Visualization of t-SNE at different stages of dataset 1



图 19 数据集 2 不同阶段 t-SNE 可视化

Fig. 19 Visualization of t-SNE at different stages of dataset 2

从图 18 和图 19 可以看出, 无论是数据集 1 或是数据集 2, 在原始数据没有进行预处理的情况下, 不同故障类型不能真正有效地合并与聚类; 在原始数据集根据所设计的特征提取方法转化为模态时频图后, 不同的故障类别已有聚类趋势, 但在各故障样本的交界处仍然非常混乱; 当故障样本根据所设计的 Resnet-BiGRU 模型对相关特征进行二次提取、学习训练和识别输出后, 不同故障类别下样本特征都实现异类特征的分离与同类特征的合并。t-SNE 的降维可视化分析证明本文方法在 MMC 子模块中 IGBT 开路故障诊断问题上有着较强的敏感度和较高的准确性。

4.2.2 消融实验与对比分析

(1) 消融实验: 为检验构建模态时频图方法的优

势, 现不改变 Resnet-BiGRU 模型的应用来完成消融实验, 即方案①: 原始数据经过 IGWO-CEEMDAN, 重构信号利用递归图(recurrence plots, RP)编码技术转换为递归时频图^[23]; 方案②: 原始数据经过 IGWO-CEEMDAN, 重构信号利用格拉姆角场(gramian angular field, GAF)编码技术转换为 GASF 时频图和 GADF 时频图^[24]; 方案③: 原始数据直接利用 CWT 转化为小波时频图^[25]。为节省篇幅, 仅展示 A 相上桥臂发生故障后经过不同方案生成的特征时频图, 如图 20 所示。以诊断故障桥臂为例, 将不同方案生成的特征时频图分别作为 Resnet-BiGRU 模型的输入, 为避免小概率现象出现, 均进行 5 次实验, 最终结果取平均值, 如图 21 所示。现利用精确度、准确率、召回率和 F_1 分数来定量分析不同时频图对诊断性能的评价指标^[13]。

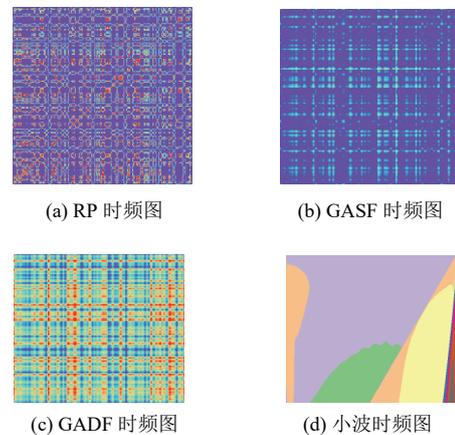


图 20 不同特征时频图

Fig. 20 Time-frequency diagrams of different features

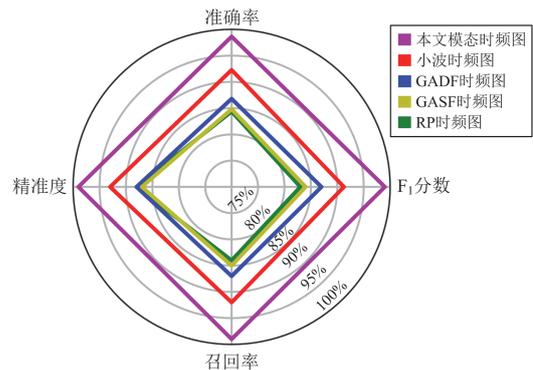


图 21 不同特征图像下的评价指标

Fig. 21 Evaluation indicators under different feature images

(2) 对比实验: 为检验本文设计模型的优势, 保证构建模态时频图的方法不变, 与 Resnet 模型、Resnet-LSTM 模型、Resnet-BiLSTM 模型和 Resnet-GRU 模型进行 5 次对比实验, 最终结果取平均值, 如图 22 所示。将 4.1 节中数据集 1 作为各个模型的

所提方法仍具备良好的泛化性与准确性。

(2) IGBT 发生开路故障后虽破坏性大,但其发生频率较低,可能会导致难以收集到足够的故障样本,这种样本的不平衡性使得正常和故障样本的数量差异显著,不利于在故障诊断过程中深入探究故障发生时的蕴含特征。为实现现实工作运作下的 MMC 故障诊断情况,现进行数据样本不平衡实验,根据 MMC 中正常和故障情况的发生频率进行不同比例的数据采样,划分实验数据集为正常类别下 300 组,其余各自不同故障类别下 150 组,总计 $150 \times 17 + 200 = 2750$ 组模态时频图样本,将训练集和测试集以 7:3 随机划分,将其送入 Resnet-BiGRU 模型中进行训练、保存与测试。不平衡下模型训练过程中诊断准确率、损失函数与测试过程中混淆矩阵定量分析结果分别如图 25 和图 26 所示。

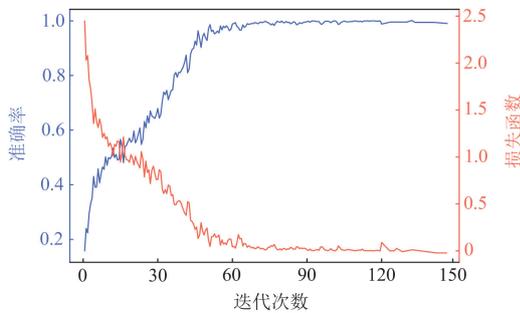


图 25 不平衡下训练准确率与损失函数曲线

Fig. 25 Training accuracy and loss function curves under the data imbalance

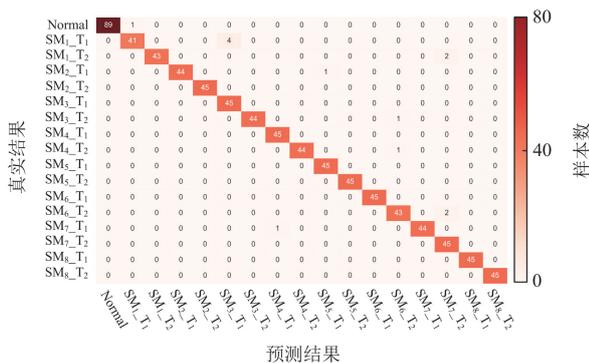


图 26 不平衡下测试混淆矩阵

Fig. 26 Testing the confusion matrix under the data imbalance

图 25 中,随着训练迭代次数不断增加,模型准确率在训练中快速上升,损失率快速下降,在迭代次数约为 60 次时,其准确率和损失率基本趋于稳定达到收敛状态,最终在迭代次数为 150 次时取得最好效果,训练准确率达到 98.83%,损失率达到 0.0894,此刻模型已经达到收敛状态。迭代训练结

束后模型测试过程中的准确率为 98.40%,相较于非极端因素下测试过程中的准确率仅下降了 1.47%,图 26 中本文方法在样本数量不平衡情况下针对不同故障类别的诊断识别精准度高,即本文所提方法针对不平衡情况也具备良好适应性和泛化性。

(3) 作为电力系统核心组件之一的 MMC 内部的相关电气器件在工作中产生的振动都会不可避免地产生噪音扰动,导致采集电压和电流等信号容易受到污染,即对诊断模型而言,具备良好的抗扰动能力是至关重要的,为了验证本文模型在现实工作条件下的抗扰性,采用第 4.1 节制作的数据集 2 下的模态时频图,其中用于训练集的图像样本不变,通过对测试集中加入不同信噪比的高斯白噪声,信噪比(signal noise ratio, SNR)如式(7)所示。

$$R_{SN} = 10 \log \frac{P_s}{P_n} \quad (7)$$

式中: P_s 和 P_n 分别表示原始信号与噪声信号的功率; R_{SN} 为信噪比,其值越大,信号受到噪声干扰就越小。

选用 -2 dB、0 dB、4 dB 和 6 dB 的噪声信号加入测试集中来对本文诊断方法及其对比方法测试,实验测试 5 次并计算平均准确率,不同诊断方法的抗噪结果如图 27 所示。

图 27 中,在不同的噪声背景下,本文所提方法在所有实验中准确率均高于其他方法。当 $R_{SN} = -2$ dB 时,本文所提方法仍能保证 87.65% 的平均诊断准确率,比准确率相差最多的模态时频图-Resnet 模型方法高出了 31.91%。伴随 SNR 数值的不断升高,其他方法诊断准确率虽然有着不同幅度的提升,但是它们的测试准确率相比于本文所提方法准确率仍然是较低的。将模态时频图与 Resnet-BiGRU 模型的有机结合能够有效提取 MMC 内部蕴含的故障特征,减少外界噪声的扰动,使其在整体上具备优异的抗噪性能。现通过相关抗噪对比实验可得本文方法能够对 MMC 中开路故障进行有效诊断,同时具备较强的抗噪性能。

5 结论

针对现有 MMC 子模块中 IGBT 的开路故障诊断方法中存在的不足,本文将模态时频图与 Resnet-BiGRU 模型相结合并应用于 MMC 分立化故障诊断方法中。以 MMC 相关故障信号构建模态时频图,经过预处理后作为 Resnet-BiGRU 模型的输入,由模型自动提取时频特征,对 MMC 中不同故障模式下的信号进行故障识别,实验结果证明本文所提方法具有较高的故障诊断准确率、较强的泛化能力和

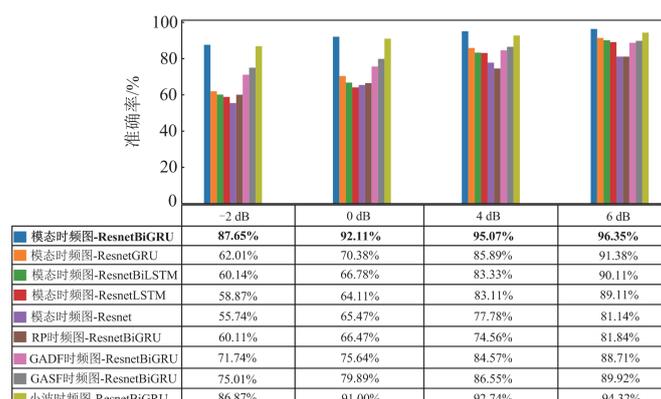


图 27 不同诊断方法的抗噪性能分析

Fig. 27 Noise immunity performance analysis of different diagnostic methods

抗噪能力, 具体得出以下结论:

(1) 对 MMC 故障诊断中存在的子模块数量过多导致计算量庞大和难以精确定位子模块故障 IGBT 的问题, 提出了分立化故障诊断方法, 通过合理选择故障参量, 不仅避免了维数灾难, 计算量变小, 还实现了精确定位。

(2) 对故障诊断中存在的特征提取单一或特征提取缺失导致的诊断准确率较低的问题, 提出了一种基于柯西高斯变异算子的 IGWO 算法来对 CEEMDAN 分解过程进行参数优化, 将分解后的敏感且优质的 IMF 分量利用 CWT 变换生成模态时频图的特征提取方法, 充分利用特征提取方法的优点, 深度挖掘故障参量内存在的特征信息, 加强了信息间的关联性, 从多尺度增强特征数据的诊断识别能力, 以便后续更好发挥诊断模型的故障识别能力。

(3) 对故障诊断中存在人工选择阈值困难、诊断准确率易受客观影响的问题, 将 Resnet 单元和 BiGRU 单元结合为 Resnet-BiGRU 诊断模型, 相比于其他模型在捕捉双向上下文时空信息、自动特征提取、时间序列建模、计算复杂度和泛化性等方面都具有优势, 设计模型有着快速测试的能力, 可迅速定位开路故障位置, 在 IGBT 开路故障导致严重损害前及时识别并切断故障子模块, 避免进一步的损害。

(4) 本文方法的鲁棒性和泛化能力较强, 在小样本情况、样本不平衡和噪声干扰等极端条件下, 仍然能够保证较高的诊断准确率。

参考文献

[1] 陈新岗, 张金京, 马志鹏, 等. 基于 MMC 的光伏直流升压并网系统故障分析及限流控制策略[J]. 电力系统保护与控制, 2023, 51(22): 145-154.
CHEN Xingang, ZHANG Jinjing, MA Zhipeng, et al. MMC-based fault analysis and current-limiting control strategy for a photovoltaic DC boost grid-connected

system[J]. Power System Protection and Control, 2023, 51(22): 145-154.
[2] LIU Zhijie, LI Kejun, WANG Jinyu, et al. General model of modular multilevel converter for analyzing the steady-state performance optimization[J]. IEEE Transactions on Industrial Electronics, 2021, 68(2): 925-937.
[3] 王海亮, 王兴贵, 李锦键, 等. 基于改进支持向量机的 MMC-MG 系统桥臂故障诊断[J]. 电力系统保护与控制, 2023, 51(7): 1-13.
WANG Hailiang, WANG Xingguo, LI Jinjian, et al. Bridge arm fault diagnosis of the MMC-MG system based on an improved support vector machine[J]. Power System Protection and Control, 2023, 51(7): 1-13.
[4] LI Gongfa, LI Jiahua, JU Zhaojie, et al. A novel feature extraction method for machine learning based on surface electromyography from healthy brain[J]. Neural Computing and Applications. 2019, 31(12): 9013-9022.
[5] 刘卓, 王天真, 汤天浩, 等. 一种多电平逆变器故障诊断与容错控制策略[J]. 山东大学学报(工学版), 2017, 47(5): 229-237.
LIU Zhuo, WANG Tianzhen, TANG Tianhao, et al. A fault diagnosis and fault-tolerant control strategy for multilevel inverter[J]. Journal of Shandong University (Engineering Science), 2017, 47(5): 229-237.
[6] PABLO L, RICARDO A, JOSE R. Fault detection on multi-cell converter based on output voltage frequency analysis[J]. IEEE Transactions on Industrial Electronics, 2009, 56(6): 2275-2283.
[7] HASMAT M, ABDULAZIZ A, MAJED A, et al. Power quality disturbance analysis using data-driven EMD-SVM hybrid approach[J]. Journal of Intelligent & Fuzzy Systems, 2022, 42(2): 669-678.
[8] 张朝龙, 赵筛筛, 何怡刚. 基于集成经验模态分解与集成机器学习的锂离子电池剩余使用寿命预测方法[J]. 电力系统保护与控制, 2023, 51(13): 177-186.
ZHANG Chaolong, ZHAO Shaishai, HE Yigang. Remaining useful life prediction method for lithium-ion batteries based on ensemble empirical mode decomposition and ensemble machine learning[J]. Power System Protection and Control, 2023, 51(13): 177-186.
[9] 孙来军. 振动信号小波包特征熵的时变与频变特性分析[J]. 高电压技术, 2007, 33(8): 146-150.

- SUN Laijun. Time-variation and frequency-variation analysis of wavelet packet-characteristic entropy for vibration signals[J]. High Voltage Engineering, 2007, 33(8): 146-150.
- [10] DRAGOMIRETSKIY K, ZOSSO D. Variational modedecomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [11] 江莉, 向世召. 基于 CEEMDAN-VSSLMS 的滚动轴承故障诊断[J]. 计算机集成制造系统, 2024, 30(3): 1138-1148. JIANG Li, XIANG Shizhao. Rolling bearing fault diagnosis based on CEEMDAN-VSSLMS[J]. Computer Integrated Manufacturing Systems, 2024, 30(3): 1138-1148.
- [12] DENG Fujin, JIN Ming, LIU Chengkai, et al. Switch open-circuit fault localization strategy for MMCs using sliding-time window based features extraction algorithm[J]. IEEE Transactions on Industrial Electronics, 2021, 68(10): 10193-10206.
- [13] 曾昭璐, 何怡刚. 基于 SE-DSCNN 的 MMC 开关管故障诊断方法[J]. 电力自动化设备, 2022, 42(5): 104-111. ZENG Zhaorong, HE Yigang. Fault diagnosis method for switches in MMC based on SE-DSCNN[J]. Electric Power Automation Equipment, 2022, 42(5): 104-111.
- [14] 杨彦杰, 董哲, 姚芳, 等. 基于 1D-CNN-LSTM 混合神经网络模型的双桥并联励磁功率单元故障诊断[J]. 电网技术, 2021, 45(5): 2025-2032. YANG Yanjie, DONG Zhe, YAO Fang, et al. Fault diagnosis of double bridge parallel excitation power unit based on 1D-CNN-LSTM hybrid neural network model[J]. Power System Technology, 2021, 45(5): 2025-2032.
- [15] 尹桥宣, 段斌, 沈梦君, 等. 模块化五电平逆变器子模块开路故障的智能诊断方法[J]. 电力系统自动化, 2018, 42(12): 127-133. YIN Qiaoxuan, DUAN Bin, SHEN Mengjun, et al. Intelligent diagnosis method for open-circuit fault of sub-modules of modular five-level inverter[J]. Automation of Electric Power Systems, 2018, 42(12): 127-133.
- [16] 孔令瑜, 张彼德, 洪锡文, 等. MMC 五电平逆变器故障的深度小波极限学习机诊断方法研究[J]. 电力系统及其自动化学报, 2020, 32(7): 25-32. KONG Lingyu, ZHANG Bide, HONG Xiwen, et al. Study on fault diagnosis method for MMC five-level inverter based on DWELM[J]. Proceedings of the CSU-EPSA, 2020, 32(7): 25-32.
- [17] 欧阳鑫, 李志斌. 基于样本扩充和特征优选的 IGWO 优化 SVM 的变压器故障诊断技术[J]. 电力系统保护与控制, 2023, 51(18): 11-20. OUYANG Xin, LI Zhibin. Transformer fault diagnosis technology based on sample expansion and feature selection and SVM optimized by IGWO[J]. Power System Protection and Control, 2023, 51(18): 11-20.
- [18] 马卫东, 刘子全, 姚楠, 等. AOA-CEEMDAN 和融合特征在齿轮箱故障诊断中的应用[J]. 机电工程, 2024, 41(5): 817-826. MA Weidong, LIU Ziquan, YAO Nan, et al. AOA-CEEMDAN and fusion features and its application in gearbox fault diagnosis[J]. Journal of Mechanical & Electrical Engineering, 2024, 41(5): 817-826.
- [19] 李海英, 孙越, 张笑, 等. 模态时频图与 ResNet50 融合的真空接触器故障诊断方法[J]. 高电压技术, 2023, 49(5): 1831-1840. LI Haiying, SUN Yue, ZHANG Xiao, et al. Fault diagnosis of vacuum contactor based on modal time-frequency diagram and ResNet50[J]. High Voltage Engineering, 2023, 49(5): 1831-1840.
- [20] 王雪芹, 张大海, 李猛, 等. 基于小波能量谱和 SSA-GRU 的混合直流输电系统故障测距方法[J]. 电力系统保护与控制, 2023, 51(12): 14-24. WANG Xueqin, ZHANG Dahai, LI Meng, et al. Fault location method for a hybrid DC transmission system based on wavelet energy spectrum and SSA-GRU[J]. Power System Protection and Control, 2023, 51(12): 14-24.
- [21] 杨贺雅, 邢纹硕, 陈聪, 等. 基于随机森林二分类器的模块化多电平换流器子模块开路故障检测方法[J]. 中国电机工程学报, 2023, 43(10): 3916-3928. YANG Heya, XING Wenshuo, CHEN Cong, et al. A fault detection and location strategy for sub-module open-circuit fault in modular multilevel converters based on random forest binary classifier[J]. Proceedings of the CSEE, 2023, 43(10): 3916-3928.
- [22] 李世晓, 杜锦华, 龙云. 基于一维卷积神经网络的机电作动器故障诊断[J]. 电工技术学报, 2022, 37(增刊 1): 62-73. LI Shixiao, DU Jinhua, LONG Yun. Fault diagnosis of electromechanical actuators based on one-dimensional convolutional neural network[J]. Transactions of China Electrotechnical Society, 2022, 37(S1): 62-73.
- [23] 赵莹莹, 何怡刚, 邢致恺, 等. 基于信息融合与深度残差收缩网络的 DAB 变换器开路故障诊断方法[J]. 电力自动化设备, 2023, 43(2): 112-118. ZHAO Yingying, HE Yigang, XING Zhikai, et al. Open-circuit fault diagnosis method of DAB converter based on information fusion and DRSN[J]. Electric Power Automation Equipment, 2023, 43(2): 112-118.
- [24] DONG Weiguang, LU Haobo, LI Shengchang. Three-phase inverter fault diagnosis model based on GAF-CNN[J/OL]. Journal of Measurement Science and Instrumentation: 1-11[2024-02-27]. <http://kns.cnki.net/kcms/detail/14.1357.TH.20240126.1042.002.html>.
- [25] 刘子昌, 白永生, 李思雨, 等. 基于小波时频图与 Swin Transformer 的柴油机故障诊断方法[J]. 系统工程与电子技术, 2023, 45(9): 2986-2998. LIU Zichang, BAI Yongsheng, LI Siyu, et al. Diesel engine fault diagnosis method based on wavelet time-frequency diagram and Swin Transformer[J]. Systems Engineering and Electronics, 2023, 45(9): 2986-2998.
- [26] ZHANG Xin, HE Chao, LU Yanping, et al. Fault diagnosis for small samples based on attention mechanism[J]. Measurement, 2022, 187: 110242-11026.

收稿日期: 2024-03-05; 修回日期: 2024-04-16

作者简介:

刘述喜(1969—), 男, 博士, 教授, 研究方向为电力传动及其控制、智能控制、电气设备在线监测与故障诊断等; E-mail: shuxi@cqut.edu.cn

刘科(2000—), 男, 通信作者, 硕士研究生, 研究方向为深度学习与电气设备故障诊断。E-mail: liuke666@stu.cqut.edu.cn

(编辑 魏小丽)