

DOI: 10.19783/j.cnki.pspc.240926

基于小波散射变换与 IRCA-ICA-Res 结合的电压源控制型 静止同步补偿系统的故障诊断

毕贵红, 张靖超, 赵四洪, 陈仕龙, 孔凡文, 陈冬静

(昆明理工大学电力工程学院, 云南 昆明 650500)

摘要: 为了充分利用电压源控制静止同步补偿器(voltage source controlled static synchronous compensator, VSC-STATCOM)IGBT 开路故障电流信号中包含的时频信息, 以提高 IGBT 故障诊断和识别的准确性, 提出了一种基于小波散射变换(wavelet scattering transform, WST)与改进残差通道注意力(improved residual channel attention, IRCA)模块、改进坐标注意力(improved coordinate attention, ICA)模块和残差神经网络(residual neural network, Resnet)相结合的新算法—WST-IRCA-ICA-Res。首先, 运用 Matlab/Simulink 平台仿真不同工况下 VSC-STATCOM 模块 22 类故障类型, 获取故障样本集。其次, 利用 WST 对故障信号进行自动鲁棒的特征提取, 构建包含时频信息的特征矩阵。最后, 利用 IRCA-ICA-Res 模型对特征矩阵进行深层次提取、强化和识别。实验结果表明, 所提方法具有较强的抗噪性能, 能够高精度识别 IGBT 故障类型。

关键词: 小波散射变换; 注意力模块; 神经网络; 故障诊断; 时频信息

Fault diagnosis of voltage source controlled static synchronous compensator based on combination of wavelet scattering transform and IRCA-ICA-Res

BI Guihong, ZHANG Jingchao, ZHAO Sihong, CHEN Shilong, KONG Fanwen, CHEN Dongjing
(Kunming University of Science and Technology, School of Electric Power Engineering, Kunming 650500, China)

Abstract: To fully utilize the time-frequency information contained in the IGBT open-circuit fault current signals of voltage source controlled static synchronous compensator (VSC-STATCOM) and improve the accuracy of fault diagnosis and identification, a novel WST-RCA-ICA-Res algorithm is proposed. This algorithm combines wavelet scattering transform (WST) with an improved residual channel attention (IRCA) module, and an improved coordinate attention (ICA) module with a residual neural network (Resnet). First, the Matlab/Simulink platform is used to simulate 22 types of faults in the VSC-STATCOM module under different operating conditions to obtain the fault sample set. Then, automatic robust feature extraction of fault signals is carried out using WST to construct a feature matrix containing time-frequency information. Finally, the IRCA-ICA-Res model is used to deeply extract, strengthen, and identify the feature matrix. Experimental results show that the proposed method has strong anti-noise performance and can accurately distinguish different IGBT fault types.

This work is supported by the National Natural Science Foundation of China (No. 51767012).

Key words: wavelet scattering transform; attention module; neural network; fault diagnosis; time-frequency information

0 引言

电压源控制静止同步补偿器(voltage source controlled static synchronous compensator, VSC-STATCOM)是一种用于提高电力系统稳定性和可靠性的设备, 可通过高效的电力电子控制技术实现电

力系统功率的灵活调节, 从而增强系统稳定性, 提升电能质量。IGBT 作为 VSC-STATCOM 的核心元件之一, 其可靠性仍然受到电力电子器件可靠性的制约^[1]。相关研究表明, 38%的电力电子器件故障是由开关器件引起的^[2]。IGBT 的故障可分为短路故障和开路故障两大类。其中, 短路故障往往伴随短路电流, 可在短时间内造成变换器永久性损坏^[3], 可通过硬件检测、快速熔断^[4]等技术快速保护。开

基金项目: 国家自然科学基金项目资助(51767012)

路故障发生后, VSC-STATCOM 可短时间内运行, 但故障相所在轴臂上会出现波形突变, 受并联负载补偿作用的影响, 突变后的波形呈现出衰减现象, 同时正常相也会出现波形畸变, 降低电能质量。因此, VSC-STATCOM 发生开路故障时, 需要快速检测故障发生位置, 避免二次故障, 造成更大的损失。

故障诊断方法通常分为特征提取和故障识别两个部分^[5]。基于特征提取的方法可以归纳为时域分析法、频域分析法以及时频分析法^[6]。文献[7]采用经验模态分解三相电流构建信号特征, 但分解后的模态变量存在混叠和端点效应。针对经验模态算法的不足, 文献[8-9]分别利用经验小波分解和变分模态分解来解决此问题, 但通过分解算法来构建信号特征会增加复杂度。文献[10]以三相电流经快速傅立叶变换得到的频域特征并作为信号特征, 但傅立叶变换作为全局时域提取特征的信号分析方法, 不能很好地反映信号的局部特征^[11]。为了更好地描述信号的频域特征, 文献[12]融合逆变器三相故障电流多种频域非线性特征, 来弥补单一频域特征不足的缺陷。上面所述方法仅从时域或频域来描述信号特征, 信号特征提取有所侧重, 缺乏对其他模态的联合提取, 难以全面反映信号特征^[13]。通过时频分析, 可以实现信号全面、准确地描述和诊断, 但也存在一些缺陷。文献[14]利用短时傅里叶时频图来描述永磁同步电机三相电流特征, 但短时傅里叶变换受窗口函数的限制, 分辨率比较单一。以小波分析^[15-16]为代表的时频分析法被证明可以有效描述信号的局部特征, 关注信号的细节变化, 但会随时移变化, 泄露特征信息。小波散射变换是一种有效描述特征的方法, 在每个尺度上对信号进行逐层分解, 逐步完善细化特征, 具有平移不变和局部形变稳定性, 解决了短时傅里叶变换分辨率单一、小波变换随时移变化的缺陷。文献[17-18]利用小波散射变换(wavelet scattering transform, WST)来描述信号细节特征信息, 减小信号的复杂度和运算量, 实现信号的高效表达和处理。

故障识别包含机器学习^[19-20]和深度学习^[21-22]等方法。机器学习算法一般包括信号分析、人工特征选取、分类器分类 3 个步骤。特征提取阶段依赖专家经验、缺乏适应性。而深度学习方法避免了人工选择特征的主观性, 通过其自动特征学习与高效分类能力, 在故障诊断方面展现出卓越的优越性。相对于传统卷积网络, 残差网络具有解决梯度爆炸、退化, 提升诊断准确率, 丰富特征的优势; 注意力机制具有强化关键信息、提高特征表达的优势。通过注意力机制强化残差网络, 学习输入信号更深层次

的特征, 进而提高准确率。文献[23-24]利用不同的注意力模块来优化残差网络, 以提高诊断的准确率。

综上所述, 小波散射变换能对原始信号进行逐层分解, 在不同尺度下完善信息, 提高信号的特征表达能力; 深度学习方法能灵活地从复杂数据中提取信号的深层特征。两者的组合可以更全面地描述和完善信号的特征表示, 提高信号处理和诊断的准确性和效率。文献[25]通过 WST 描述输电线路三相电流特征, 进而利用 BiLSTM 来实现准确分类。文献[26]将 WST 和 CNN 组合进行滚动轴承的故障诊断。

因此, 为了更好地描述 VSC-STATCOM 发生开路故障的电流波形特点, 准确地区分故障类别, 本文提出一种基于 WST 和改进残差通道注意力(improved residual channel attention, IRCA)模块、改进坐标注意力(improved coordinate attention, ICA)模块和残差神经网络(residual neural network, Resnet)结合的 VSC-STATCOM 故障诊断方法。首先, 利用 WST 对 22 类故障信号进行多尺度分解, 逐层细化信号在不同频率和尺度下的特征, 提供更全面的信号描述; 其次, 利用 IRCA-ICA-Res 组合模型对 IGBT 散射特征进行深层次的学习和识别。其中, IRCA 和 ICA 的组合模型能利用 IRCA 全局特征强化能力和 ICA 坐标维度特征强化能力进行特征融合, 实现特征的重点强化, 再由 Resnet 丰富特征信息, 提高信息表征能力, 以此诊断故障类型。通过在不同环境下对该算法进行仿真分析, 以验证 WST 和 IRCA-ICA-Res 组合算法能够快速、准确识别 IGBT 故障类型。

1 数据库建立

1.1 原理分析

图 1 为 VSC-STATCOM 拓扑结构图, 包括交流部分和控制部分。变流器含有 6 个功率开关管 S_1 — S_6 和电容 C 。变流部分的交流侧并有非线性负载, 通过改变其负载的大小, 给予系统不同的补偿值。控制部分引入电网端电压(v_{Ga} 、 v_{Gb} 、 v_{Gc})、补偿电流 i_{svC} 和电容端电压 v_c , 然后通过相关变换生成控制信号送入 PWM 模块来控制变流器。其中, 低通滤波器 LPF 能将瞬时功率 p 中的振荡功率过滤, 保留平稳功率; 比例积分调节器 PI 可以确定一个附加功率 p_{ac} 来保证电容端电压 v_c 在固定的参考值附近。abc 坐标系下的参数和 $\alpha\beta$ 坐标下的参数的转换关系分别如式(1)和式(2)所示。

$$\begin{bmatrix} F_\alpha \\ F_\beta \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} f_a \\ f_b \\ f_c \end{bmatrix} \quad (1)$$

$$\begin{bmatrix} f_a \\ f_b \\ f_c \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & 0 \\ -\frac{1}{2} & \frac{\sqrt{3}}{2} \\ -\frac{1}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} F_\alpha \\ F_\beta \end{bmatrix} \quad (2)$$

式中： f_a 、 f_b 、 f_c 分别为 abc 坐标系下的 A、B、C 相的参数； F_α 、 F_β 分别对应 $\alpha\beta$ 坐标系下的 α 、 β 相的参数。

考虑到 IGBT 开路故障的位置和数量，有 21 种

故障状态，加上正常运行状态，共计 22 种类型，故障类型如表 1 所示。

表 1 IGBT 故障类型

Table 1 IGBT fault types

故障类型	故障的 IGBT
正常状态	无故障(NF)
单管故障	S ₁ 、S ₂ 、S ₃ 、S ₄ 、S ₅ 、S ₆
同相桥臂双管故障	S ₁ S ₂ 、S ₃ S ₄ 、S ₅ S ₆
上下桥臂双管故障	S ₁ S ₃ 、S ₁ S ₅ 、S ₂ S ₄ 、S ₂ S ₆ 、S ₃ S ₅ 、S ₄ S ₆
交叉桥臂双管故障	S ₁ S ₄ 、S ₁ S ₆ 、S ₂ S ₃ 、S ₂ S ₅ 、S ₃ S ₆ 、S ₄ S ₅

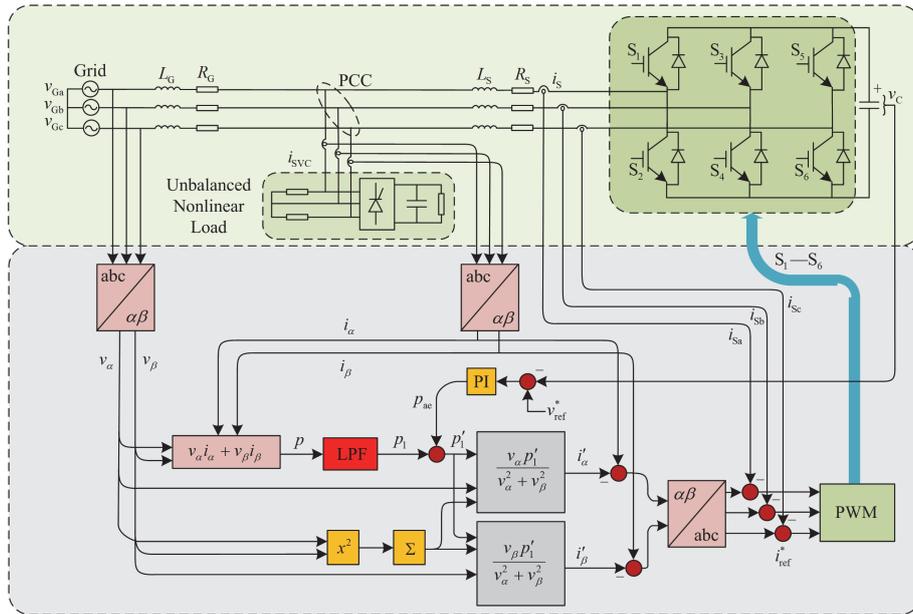


图 1 VSC-STATCOM 拓扑结构

Fig. 1 VSC-STATCOM topology

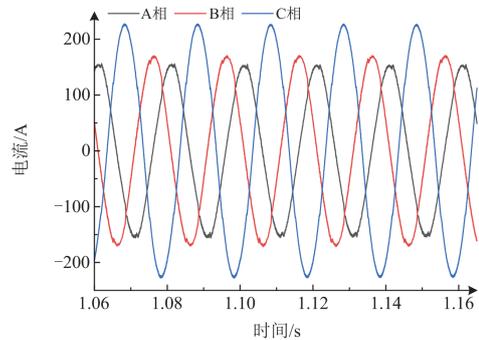
1.2 信号采集

本文利用 Matlab/Simulink 仿真平台搭建 VSC-STATCOM 模型。设置该模型的基波频率为 50 Hz、开关频率为 10 kHz。将模型中不同的 IGBT 设置为常开，模拟不同位置的开路状态，生成样本数据集。首次发生开路故障的时间为 1.1 s，以偏移量 $\Delta = 2$ ms 来改变故障发生的时间，共设置 9 次偏移量，则故障发生的时间为 $1.1\text{ s} + \Delta (i = 0, 1, \dots, 9)$ 。其次，在每个故障时刻，调整非线性负载的权重值，模拟不同负载条件对系统带来的影响，权重范围为 0~0.09，步长为 0.01。在 50 kHz 的采样频率下采集故障时刻前 0.3 周期及后 1 周期的三相电流信号，共计 2200 组样本集。

1.3 信号分析

波形能够清晰地反映 VSC-STATCOM 的运行状态，不同的 IGBT 开路故障下，交流输出端的波

形表现出不同的波动特性。从表 1 的 5 种故障类型分别选取其中一种进行可视化。图 2(a)为 VSC-STATCOM 正常运行时不对称负载下的电流波形。图 2(b)为 S_1 在 1.1 s 发生开路的波形；图 2(c)、图 2(d)和图 2(e)分别为 S_1 和 S_2 、 S_1 和 S_3 、 S_1 和 S_6 在 1.1 s 同时发生开路的波形。



(a) 正常运行的波形

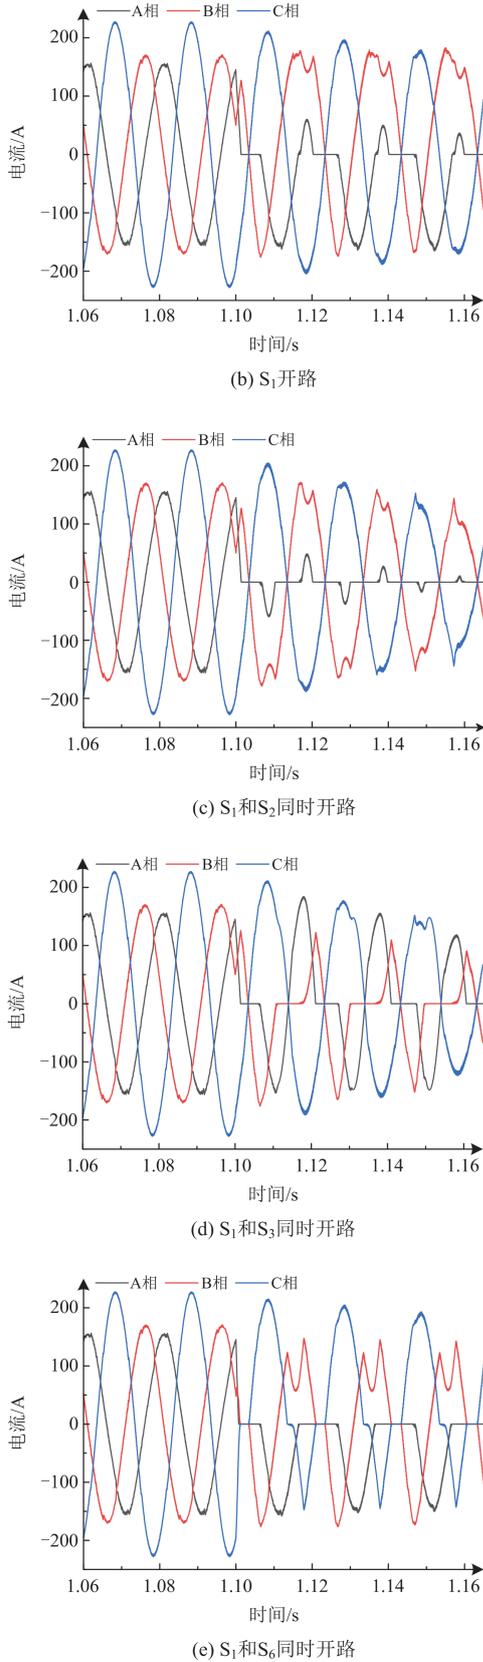


图2 不同故障类型的输出波形

Fig. 2 Output waveforms for different fault types

2 小波散射网络

2.1 小波散射变换

小波散射变换是一种时频分析技术, 利用复数小波函数和非线性变换算子交替作用, 逐层提取信号在不同时间尺度和频率上的特征信息。通过多级处理, 将原始信号转化为一组描述其局部频率特性的高维特征向量, 这些特征向量能够有效地捕捉到信号的结构和频率分布信息。

信号 x 的复数小波变换可表示为

$$x \odot \psi_{\lambda_i}(u) = x \odot \psi_{\lambda_i}^a(u) + jx \odot \psi_{\lambda_i}^b(u) \quad (3)$$

复数小波构建的尺度图系数可表示为

$$U_{\lambda_i} x = |x \odot \psi_{\lambda_i}(u)| \quad (4)$$

则小波散射系数可表示为

$$V_{\lambda_i} x = |x \odot \psi_{\lambda_i}(u)| \odot \phi_J(u) \quad (5)$$

式中: $\psi_{\lambda_i}(u)$ 为复数小波算子; λ_i 为散射传播路径; $\phi_J(u)$ 是尺度为 2^J 的高斯低通滤波器, J 为最大尺度; “ $|\cdot|$ ” 为取模值运算; “ \odot ” 为卷积操作。

图3为小波散射网络前3层结构。对输入信号 x 进行小波散射变换可获得平移不变、局部稳定的信号特征。首先, 输入信号 x 在低通滤波器的平均池化运算下输出第0层散射系数 $V_0 x$, 在复数小波算子 $\psi_{\lambda_0}(u)$ 的作用下输出第0层尺度图系数 $U_0 x$; 接着对 $U_0 x$ 进行第二次低通滤波操作, 输出第1层散射系数 $V_1 x$, 对 $U_0 x$ 进行第二次连续小波变换输出第1层尺度图系数 $U_1 x$; 上层输出的尺度图系数作为下层运算的输入, 重复此过程, 可获得第2层—第 n 层的散射系数和尺度图系数。

2.2 小波散射网络

小波散射网络是一种特殊的神经网络, 一般由多层结构组成, 每一层包括小波卷积、非线性、平均池化3部分, 如图4所示。首先, 散射网络第一层经过连续小波卷积、取模运算非线性、低通滤波器平均池化来初步提取故障信号的特征; 接着, 将提取的初步特征保留下来, 用于构建小波散射特征。同时, 这些特征也被继续输入到下层网络结构, 以提取更高级小波散射特征。上层输出特征保留构建小波特征的同时作为下层输入, 重复此过程, 构建更为全面的故障信号的小波散射特征。这种方法不仅降低了网络的训练复杂度和运算量, 还有助于捕捉到输入信号的低方差特征信息, 为深度学习模型提供了更为强大和高效的特征表示能力。

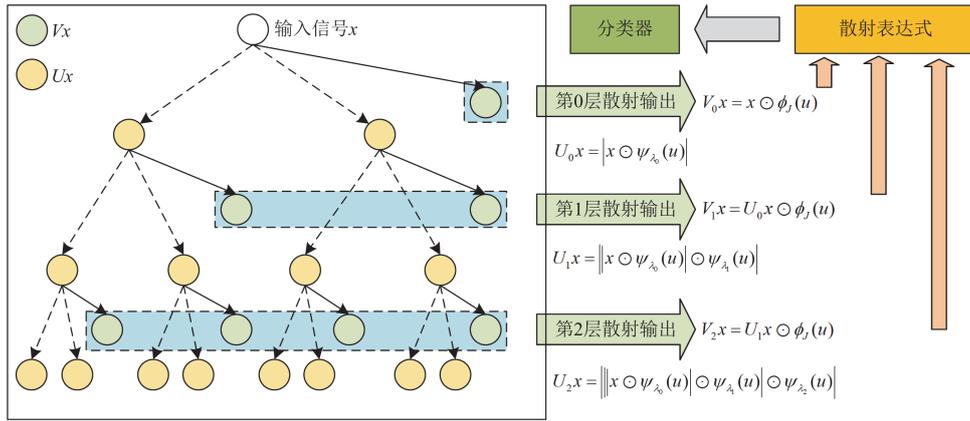


图3 小波散射网络前3层结构

Fig. 3 Structure of the first 3 layers of the wavelet scattering network

散射网络的卷积源于预先设定的小波基函数，输出系数来源于每一层的变换运算；而卷积神经网络的卷积需要经反向传播算法逐级调整网络参数，输出系数来自训练好的网络的最后一层特征值。散射网络不需要进行数据学习，能够逐层提取不同尺度的特征，具备良好的计算效率和稳健性；卷积网络需要从大量数据中学习特征表示，能够灵活地从复杂数据中提取特征，具备提高信号表征能力的优势。因此，将散射网络和卷积神经网络组合可以更全面地提取和强化信号特征，提高信号处理和分析的准确性和效率。

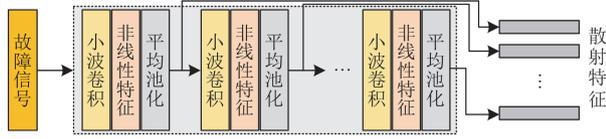


图4 小波散射网络结构

Fig. 4 Wavelet scattering network structure

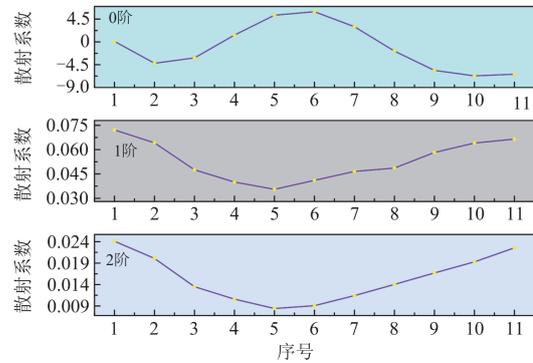
2.3 基于 WST 的信号分析

在采样率为 50 kHz、不变性尺度为 0.013 s、质量因子为 8 和 1 的条件下，采用 WST 方法进行信号处理，可获得各类 IGBT 故障信号在经两次变换后所对应的 0—2 阶散射系数。图 5 展示了正常运行状态 NF 与 S₁ 开路故障状态下的 0—2 阶散射系数分布特征。分析图 5 可知，0 阶散射系数数值存在正负抵消，具有较小的能量分布，而 1 阶和 2 阶系数数值(每类信号的 1 阶散射系数有 44 条，2 阶散射系数有 60 条，选取其中 1 条分析)位于正数轴上，显示出更高的能量分布。值得注意的是，1 阶散射系数数值总体上大于 2 阶系数数值，意味着 1 阶系数能量分布较大，2 阶系数能量分布较小。

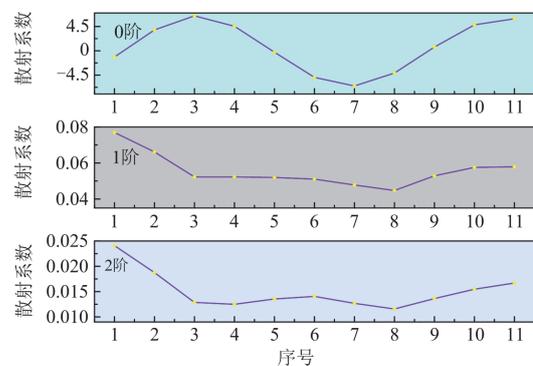
进一步观察发现，不同开路故障的 IGBT 三相

电流散射系数存在显著的差异，这为准确识别 IGBT 故障类型提供了依据。

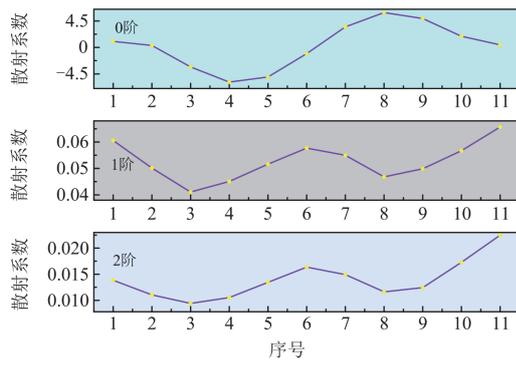
对不同故障类型的 IGBT 三相电流 1 阶散射系数进行特征可视化，如图 6 所示。经过观察，发现散射时频谱的高、中、低频段的特征信息都能够清晰表达。从频率轴上看，能量主要集中在 10 kHz 和 20 kHz 频段；从时间轴上看，能量分布于不同的时间段，表现出不同的特征。不同开路类型的散射系数差异分布可为 IGBT 开路信号的识别提供了一种有效依据。



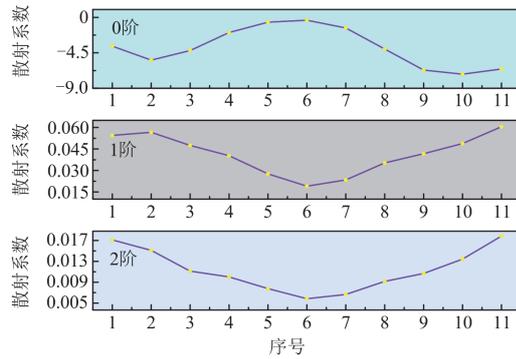
(a) 正常运行A相信号散射分布



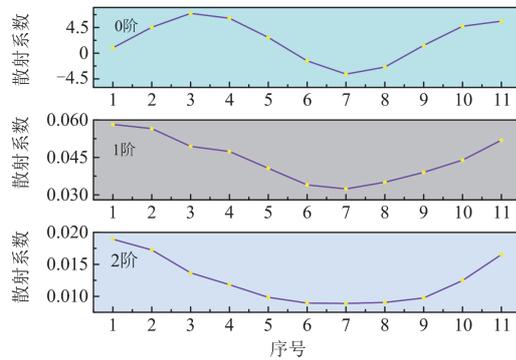
(b) 正常运行B相信号散射分布



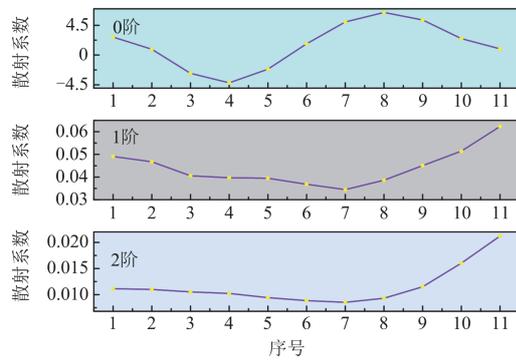
(c) 正常运行C相信号散射分布



(d) S_1 故障A相信号散射分布



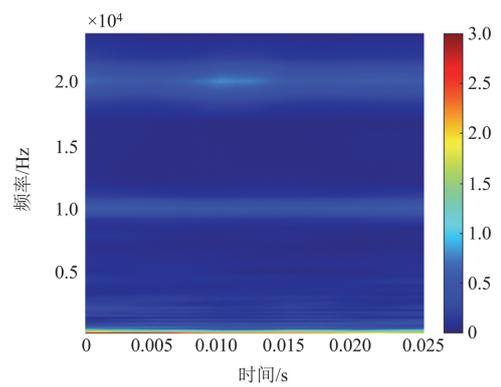
(e) S_1 故障B相信号散射分布



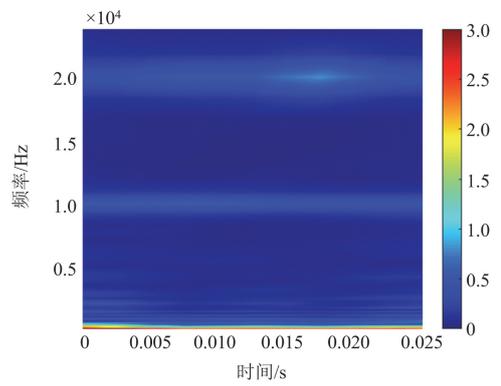
(f) S_1 故障C相信号散射分布

图5 不同故障类型的0—2阶散射系数分布

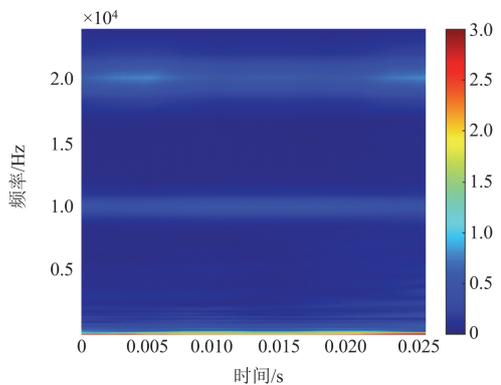
Fig. 5 Distribution of 0—2nd order scattering coefficients for different fault types



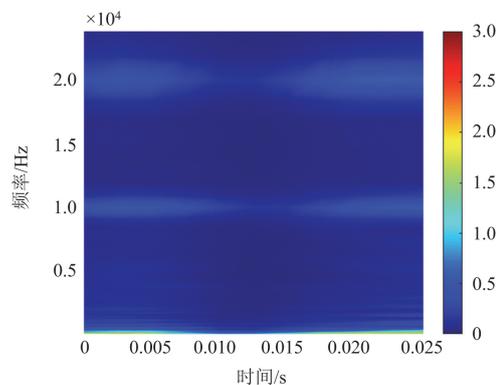
(a) 正常运行A相1阶散射分解变换



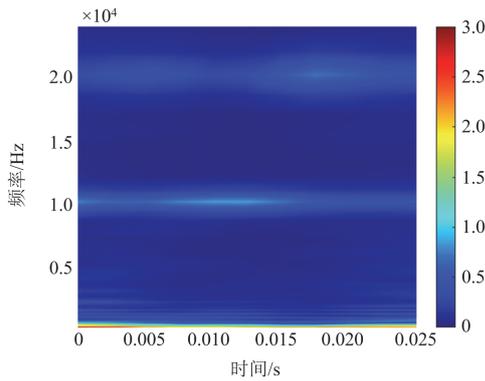
(b) 正常运行B相1阶散射分解变换



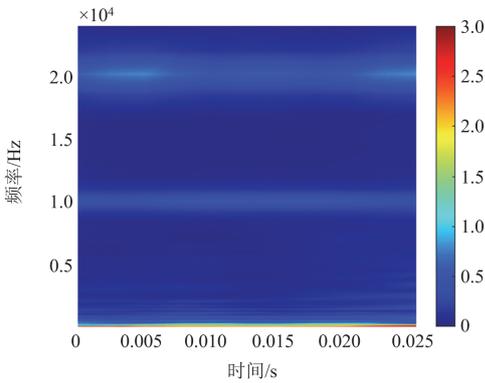
(c) 正常运行C相1阶散射分解变换



(d) S_1 开路A相1阶散射分解变换



(e) S₁开路B相1阶散射分解变换



(f) S₁开路C相1阶散射分解变换

图 6 不同故障类型的 1 阶散射系数时频图

Fig. 6 Time-frequency plots of 1st order scattering coefficients for different fault types

3 WST-IRCA-ICA-Res 故障诊断模型

3.1 残差网络

CNN 以强大的特征提取能力，遍历输入信号的各个位置，以逐层卷积的方式提取出越来越高级别的特征。然而，随着网络深度的增加，传统的 CNN 面临着梯度消失或爆炸的问题，以及网络性能可能不再提升甚至退化的挑战。为了克服这些难题，残差网络应运而生，如图 7 所示。残差结构的输入与输出有很大的关联性，当输入 Z 与输出 $D(Z)$ 的维度不一致时，输入 Z 无法直接与输出 $D(Z)$ 进行短

接，必须经过 1×1 CNN 模块的捷径调整输入维度后，才能实现两者的相加操作，连接方式如图 7 的带降采样的残差块(residual block with downsampling, RBD)所示。当输入 Z 与输出 $D(Z)$ 的维度相同时，输入 Z 可以直接与输出 $D(Z)$ 相加，无需额外的维度调整，连接方式如图 7 中的标准残差块(standard residual block, SRB)所示。

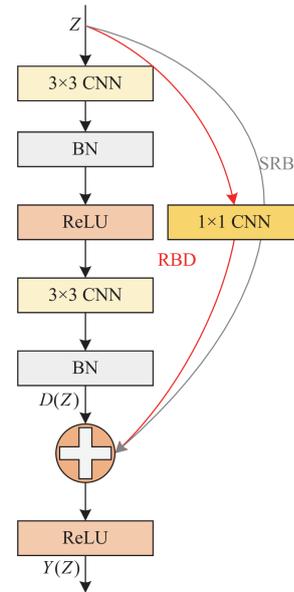


图 7 Resnet 模块

Fig. 7 Resnet module

3.2 改进的通道注意力模块

注意力机制能够抑制无效特征的同时增强有效模块特征，突出重要信息。改进的通道注意力(improved convolutional block attention, ICBA)模块如图 8 所示。首先，将全连接层替换为 1×1 的二维卷积，对最大池化和平均池化计算后的特征进行注意力权重计算。然后，对经过 Sigmoid 非线性激活函数的两个分支的特征图进行逐元素相乘操作，相对于加法，这种乘法操作能够更好地突出同时在两个分支中都具有重要权重的通道位置，更加关注重要位置的信息，同时抑制那些只有一个注意力权

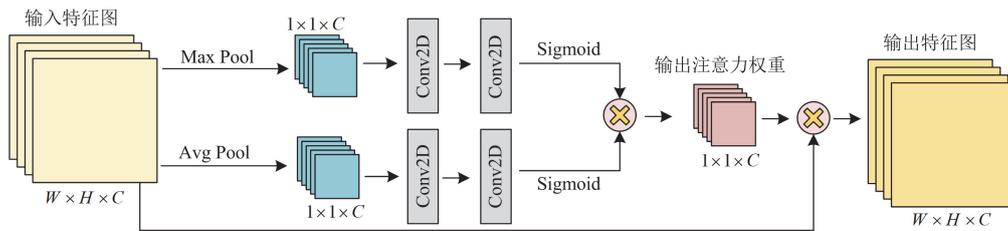


图 8 ICBA 模块

Fig. 8 ICBA module

重较高或两个权重均较低的通道位置信息的表达, 有助于深度学习模型在面对复杂多变的输入时保持稳定的性能表现。

3.3 改进的坐标注意力

图 9 为 ICA 模块, 引入 X 轴和 Y 轴维度的平均池化和最大池化运算, 在不同层面上增强输入特征,

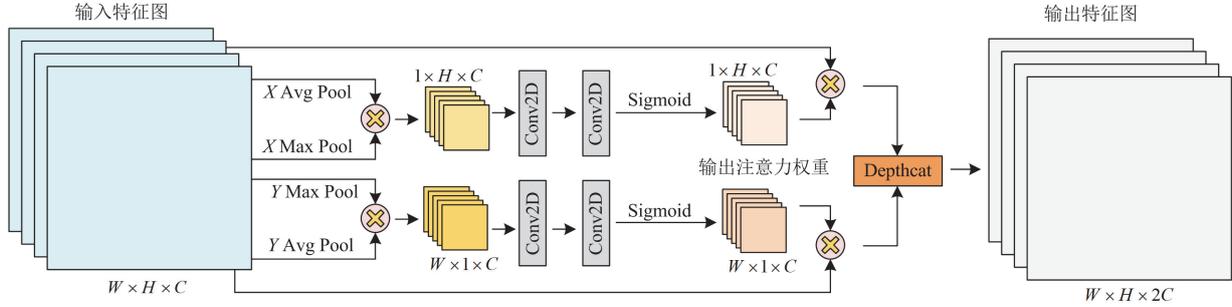


图 9 ICA 模块

Fig. 9 ICA module

3.4 WST-IRCA-ICA-Res 模型

为了更好地提取 VSC-STATCOM 中发生开路故障三相电流包含的时频信息和细节特征, 本文提出了 WST-IRCA-ICA-Res 诊断模型, 其详细结构如图 10 所示。该诊断模型主要由散射网络、下采样结构块、IRCA 模块、ICA 模块和 SRB 残差模块等组成, 分别构成了时频特征获取、初步特征提取、全局特征强化、局部特征强化和深度特征提取模块。首先, 作为模型的起点, 小波散射网络凭借其多尺度分析能力, 有效捕捉输入三相电流信号中的时频特征, 并将捕捉到的特征送入下采样结构块进行细

使其包含更加全面和丰富的信息。将增强的 X 轴和 Y 轴特征图进行深度拼接, 形成了更为复杂和多样化的输出特征图。这种深度拼接的方式不仅保留了原始特征的空间结构, 还通过跨维度的信息融合机制引入了新的组合特征与交叉特征, 为后续的神经网络处理提供了更为丰富的特征信息。

化; 其次, 将细化后的特征引入 IRCA 模块, 由 ICBA 模块来强化二次细化的特征, 提取整张特征图的关键信息, 并通过短连接来实现特征相加, 丰富特征信息; 再次, 在全局特征强化的基础上, ICA 模块进一步从 X 轴(频域)和 Y 轴(时域)两个维度分别提取关键信息, 提高特征表示的准确性。IRCA 模块和 ICA 模块的组合, 实现了从全局到局部的特征强化, 更能把握输入信号的变化细节; 最后, 再由 SRB 模块充分提取强化的特征, 全局平均池化捕捉整体特征, 以加快收敛速度, 提高诊断准确率。

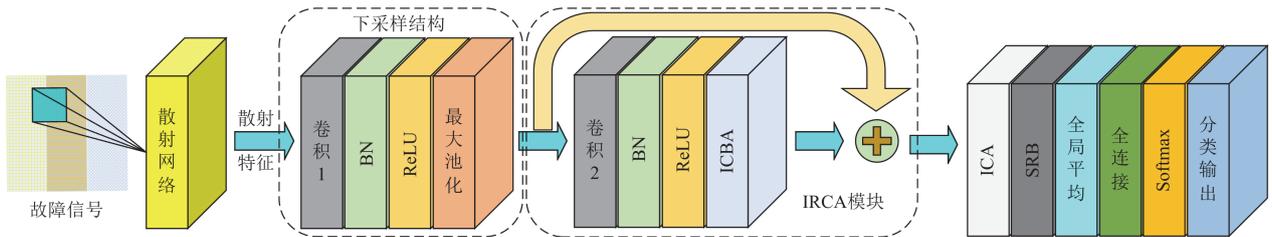


图 10 WST-IRCA-ICA-Res 模型

Fig. 10 WST-IRCA-ICA-Res module

4 实验分析

本文通过仿真 VSC-STATCOM 模块 IGBT 开路的 22 种故障类型, 获取样本数据。每种故障类型采集数据各 100 组, 共计 2200 组三相电流故障样本。在基波为 50 Hz、采样频率为 50 kHz 的条件下, 采集了故障时刻前 0.3 周期和后持续 1 周期的数据, 故信号长度为 1301, 22 种三相电流故障信号组成了

1301×6600 的样本矩阵。按照不同比例, 将这些样本矩阵划分为训练集和测试集。受外界各种因素的干扰, 原始信号可能包含噪声, 为验证该模型抗噪性能, 在测试样本集中加入不同信噪比的高斯白噪声。

4.1 数据预处理

利用小波散射变换对 1301×6600 的样本矩阵进行自适应分解, 分解成 105×11×6600 的三维矩

阵，一定程度上减少了数据量，降低了复杂度，其中 105 为散射路径数，11 为时间步长。对于含有三相的单个样本，按照 A 相、B 相和 C 相的顺序沿着第三维度进行矩阵拼接，形成 $105 \times 11 \times 3$ 三维矩阵，以便 IRCA-ICA-Res 模型对存在于三相电流局部中的大量故障细节信息进行特征提取。表 2 为 IRCA-ICA-Res 的结构参数。

表 2 IRCA-ICA-Res 的结构参数

Table 2 Structural parameters of IRCA-ICA-Res

序号	层类型	激活函数	输出尺寸
1	输入	—	$105 \times 11 \times 3$
2	卷积 1	ReLU	$53 \times 6 \times 64$
3	最大池化	—	$27 \times 3 \times 64$
4	卷积 2	ReLU	$27 \times 3 \times 64$
5	ICBA	Sigmoid	$27 \times 3 \times 64$
6	ICA	Sigmoid	$27 \times 3 \times 128$
7	RBD	ReLU	$27 \times 3 \times 128$
8	全局平均池化	—	$1 \times 1 \times 128$
9	全连接	Softmax	$1 \times 1 \times 22$

4.2 样本数量的选择

样本数量过多或过少都会对故障诊断模型造成数影响。当样本量过少时，故障诊断模型不能充分提取故障特征，影响诊断准确率；当样本数量过多时，故障诊断模型训练时间加长、计算量增加，成本提高。因此，合理的样本数量可以确保模型能够得到足够训练的同时降低计算成本。三相信号以 $105 \times 11 \times 3$ 的格式输入到 IRCA-ICA-Res 模型，采用 Adam 优化器，设置小批量样本个数为 30，训练次数为 420 次。表 3 是每类故障的训练样本个数为 10、20，测试样本个数为 90、80 时，散射特征输入到 IRCA-ICA-Res 模型的准确率，取 10 次实验结果的平均值作为最终的实验结果。

表 3 不同训练样本个数的实验结果

Table 3 Experimental results of the number of training samples

训练样本个数	不同信噪比下的诊断准确率/%			
	无噪声	30 dB	20 dB	10 dB
10	98.82	98.31	98.08	96.18
20	99.73	98.97	98.3	97.13

由表 3 可以看出，无噪声、30 dB、20 dB 和 10 dB 信噪比环境下，训练样本个数为 10 的准确率相对训练样本个数为 20 分别下降了 0.91%、0.66%、0.22% 和 0.95%。

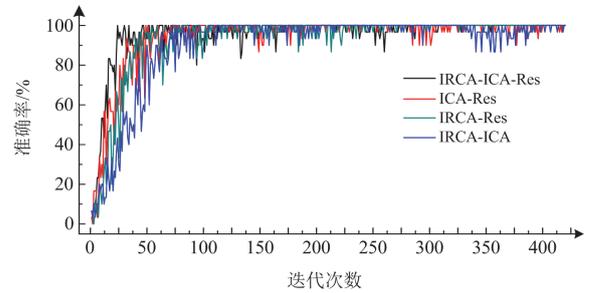
无噪声到 10 dB 信噪比变化过程中，训练样本个数为 10 时，准确率下降了 2.64%，而训练样本个数为 20 时，准确率下降了 2.6%。经过对比分析，本文最终选择训练样本为 20 个、测试样本为 80 个

进行实验分析。

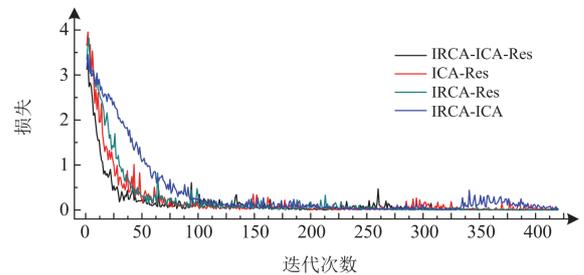
4.3 消融实验

为了验证 IRCA-ICA-Res 在诊断 IGBT 故障类型方面的卓越性能，本节采用 IRCA-ICA-Res、ICA-Res、IRCA-Res 和 IRCA-ICA 对相同的样本集进行训练和测试，并通过多个方面来综合分析它们在诊断 IGBT 故障信号的表现。

由图 11 的准确率曲线和损失曲线的变化可以看出，IRCA-ICA-Res 在 60 次迭代时就已经趋于收敛；ICA-Res 和 IRCA-Res 的收敛速度基本接近，在 80 次迭代时基本趋于收敛；而 IRCA-ICA 则收敛较慢，在迭代 100 次时才达到收敛，表明 IRCA-ICA-Res 收敛速度最快。



(a) 不同结构模型的训练准确率曲线



(b) 不同结构模型的训练损失曲线

图 11 不同结构模型的训练曲线

Fig. 11 Training curves for different structural models

进一步分析表 4 不同结构模型的准确率可知，在噪声环境下，相较于 IRCA-ICA 模型，其他 3 种模型具有残差结构，能够充分提取经注意力模块强化后的特征，保持 99% 以上的诊断准确率。在具备残差结构的模型中，各模型提取特征的方式各有特点。IRCA-Res 模型侧重于从全局提取散射矩阵的时频特征，ICA-Res 模型聚焦从不同维度提取散射矩阵的时频特征，而 IRCA-ICA-Res 模型表现更为优异，它能够实现从全局到局部的信号特征精准挖掘，更加凸显关键信息。因此，IRCA-ICA-Res 在 4 种信噪比环境中的诊断准确率都高于其他 3 种模型。

表 4 不同结构模型的准确率对比

Table 4 Comparison of the accuracy of different structural models

模型	不同信噪比下的诊断准确率/%				训练时间/s
	无噪声	30 dB	20 dB	10 dB	
IRCA-ICA-Res	99.73	98.97	98.3	97.13	15
ICA-Res	99.18	98.47	97.59	96.51	11
IRCA-Res	99.05	98.33	97.44	96.41	12
IRCA-ICA	98.79	97.91	97.24	96.15	14

4.4 不同注意力机制的比较

为了验证本文提出的 ICBA 与 ICA 注意力机制组合的有效性, 本文将 CAM 和 SENet 这两种经典的注意力模块替换 IRCA-ICA-Re 模型中的注意力机制模块, 构造了具有不同注意力机制的 4 种模型 (CAM-ICA-Res、SENet-ICA-Res、ICRA-SENet-Res 和 CAM-SENet-Res)。

图 12 为 5 个不同注意力机制模型下的故障诊断准确率雷达图。分析图 12 可知, 本文提出的注意力模型在不同环境下的准确率曲线均位于高准确率的外围区域, 这表明该组合在识别 IGBT 故障类型时具有更高的准确率和稳定性。相比之下, 其他注意力机制组合的准确率曲线则出现了不同程度的向内收缩, 反映出其在面对复杂或噪声环境时, 识别能力的下降和不稳定。

进一步对表 5 不同注意力机制组合的准确率进行对比分析, 在无噪声环境下, IRCA-ICA-Res 模型相较于 CAM-ICA-Res、SENet-ICA-Res、ICRA-SENet-Res 和 CAM-SENet-Res 的准确率分别提升了 0.3%、0.45%、0.53%和 0.59%。这一提升虽看似微

小, 但在高准确率要求的故障诊断领域, 却是至关重要的。而在更为严苛的信噪比为 10 dB 的环境下, IRCA-ICA-Res 的优势更加明显, 其准确率相较于其他模型分别提高了 0.42%、0.6%、0.68%和 0.92%。这一结果充分表明, IRCA-ICA-Res 模型具备更强的噪声鲁棒性, 能够在复杂噪声环境中保持出色的故障诊断能力。

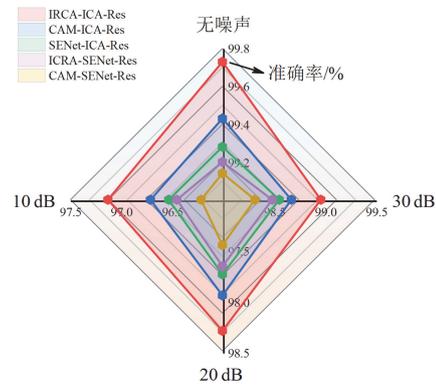


图 12 不同注意力机制的实验分析

Fig. 12 Experimental analysis of different attentional mechanisms

表 5 不同注意力机制组合的诊断准确率对比

Table 5 Comparison of different combinations of attention mechanisms

模型	不同信噪比下的诊断准确率/%				训练时间/s
	无噪声	30 dB	20 dB	10 dB	
IRCA-ICA-Res	99.73	98.97	98.3	97.13	15
CAM-ICA-Res	99.43	98.68	97.95	96.71	15
SENet-ICA-Res	99.28	98.56	97.74	96.53	14
ICRA-SENet-Res	99.2	98.49	97.66	96.45	14
CAM-SENet-Res	99.14	98.32	97.45	96.21	14

4.5 不同模型比较

为了验证本文提出的 IRCA-ICA-Res 模型在故障诊断任务中的优越性, 将其与多个经典且广泛应用的深度学习模型—Alexnet、Darknet-19 以及 Resnet-18 进行对比。对这些对比模型进行微调, 使它们能够满足本文输入矩阵格式。

图 13 给出了不同模型训练过程的准确率曲线,

其中的训练曲线直观展示了 IRCA-ICA-Res 模型在收敛性能上的显著优势。在较少的迭代次数内, 该模型学习曲线迅速收敛于高准确率, 这不仅证明了其高效的学习特征能力, 也反映了其结构设计对于小波散射矩阵的良好适应性。相比之下, Alexnet、Darknet-19 和 Resnet-18 等模型在达到相似性能水平时, 往往需要更多的迭代次数。

进一步地,表 6 给出了不同模型在不同噪声水平下的诊断准确率,可以看出 IRCA-ICA-Res 在不同噪声环境下展现出了优异性能。在信噪比为 10 dB 和 30 dB 的噪声环境下,IRCA-ICA-Res 诊断准确率不仅显著高于其他 3 种模型,而且在信噪比为 10 dB 的极端条件下,相比 Resnet-18、Darknet-19 和 Alexnet 分别提升了 0.55%、0.88%和 1.17%。这一结果表明,IRCA-ICA-Res 模型不仅具备较高的识别精度,而且具有优异的抗噪性能,能够在复杂多变的环境中保持稳定的性能输出。

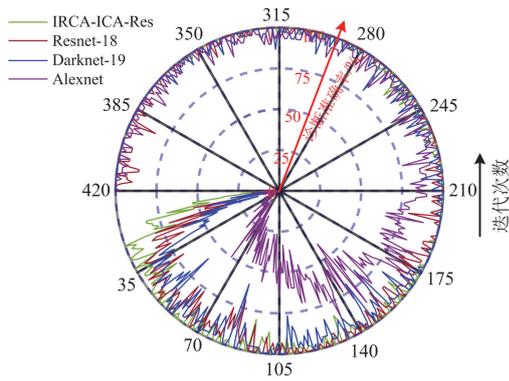


图 13 不同模型的训练准确率曲线

Fig. 13 Training accuracy curves for different models

表 6 不同模型的比较

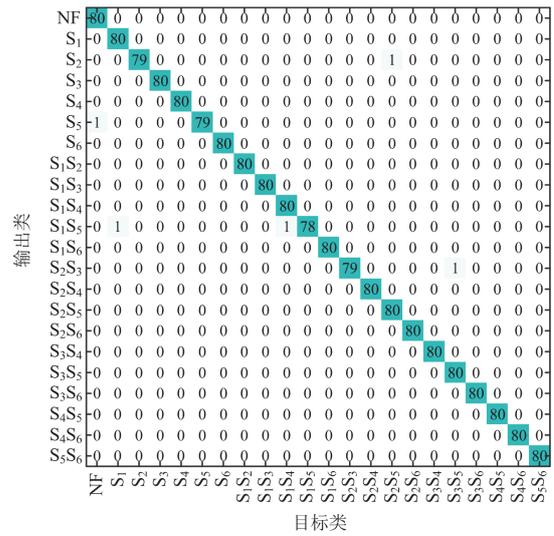
Table 6 Comparison of different models

模型	不同信噪比下的诊断准确率/%				训练时间/s
	无噪声	30 dB	20 dB	10 dB	
IRCA-ICA-Res	99.73	98.97	98.3	97.13	15
Resnet-18	99.51	98.63	97.95	96.58	17
Darknet-19	99.21	98.34	97.46	96.25	13
Alexnet	99	98.06	97.11	95.96	40

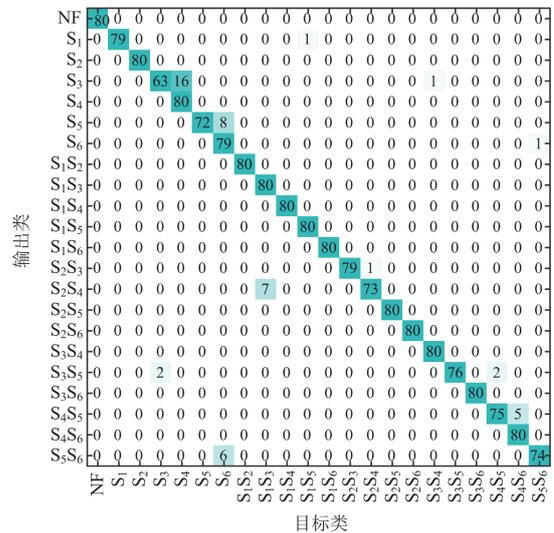
4.6 不同方法的比较

为了进一步验证小波散射方法和 IRCA-ICA-Res 模型结合的优越性,现将 $105 \times 11 \times 3 \times 2200$ 的小波散射样本、 $1301 \times 3 \times 1 \times 2200$ 的原始数据样本、快速傅里叶变换后 $1301 \times 3 \times 1 \times 2200$ 的频域样本以及 $1301 \times 3 \times 1 \times 2200$ 的原始数据样本与同维频域样本组合形成 $1301 \times 3 \times 2 \times 2200$ 的时频域样本,分别输入到 IRCA-ICA-Res 模型,其诊断结果如图 14 所示。

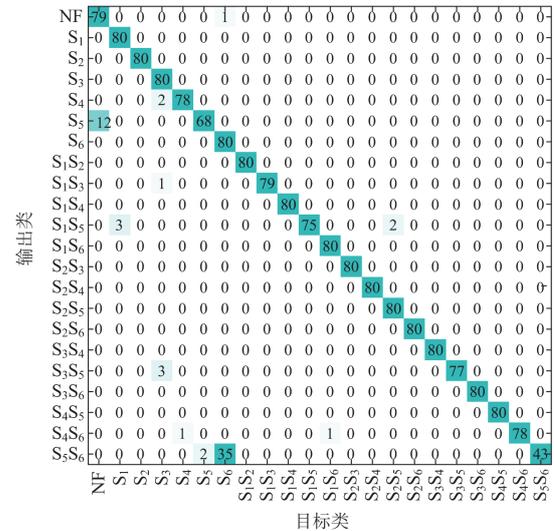
由图 14 可知,当采用小波散射特征作为输入时,仅有 4 个故障样本被错误分类为其他类故障,总体准确率高达 99.72%。这一结果表明,小波散射变换在捕捉信号中的关键信息方面表现出卓越的能力,显著提高了信息的表征能力。相比之下,当直接使用原始数据样本或频域样本作为特征时,分类



(a) 小波散射方法



(b) 原始数据作为特征



(c) 傅里叶变换方法

速傅里叶变换方法分类效果最差。

4.7 相数的比较实验

图 16 展现了三相、两相以及单相电流经 WST 后输入 IRCA-ICA-Res 后的诊断准确率，可以看出，单相散射矩阵作为特征时，其准确率稳定在 80%左右，这显示了其在区分不同故障类别上的局限性。相比之下，两相散射矩阵作为特征时，准确率较高，尽管略逊于三相特征，但仍表现出极高的诊断性能。

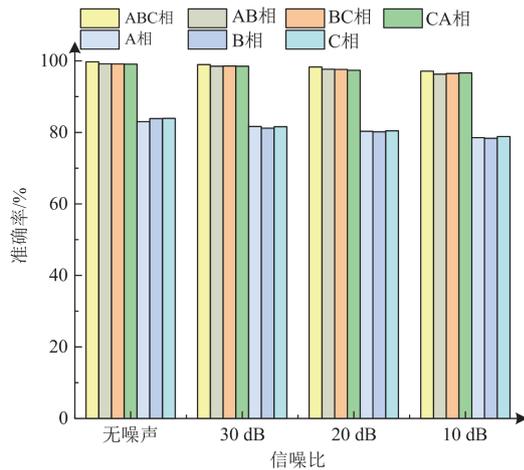


图 16 不同相数的比较

Fig. 16 Comparison of different phases

表 7 中为不同信噪比下不同相数的诊断准确率。可以发现，即使在各种环境条件下，以三相电流散射矩阵为特征的总体准确率始终略高于以任意两相为特征的准确率。这种微小但持续的优势表明，三相电流信号在完整性和故障特征表达上可能具有更高的冗余度，也更加全面，从而能够更精确地捕捉到故障引起的细微变化。

表 7 不同信噪比下不同相数的诊断准确率比较

Table 7 Comparison of diagnostic accuracy for different phases at different signal-to-noise ratios

相别	不同信噪比下的诊断准确率/%			
	无噪声	30 dB	20 dB	10 dB
ABC 相	99.73	98.97	98.3	97.13
AB 相	99.17	98.51	97.67	96.29
BC 相	99.14	98.56	97.63	96.48
CA 相	99.09	98.52	97.38	96.63
A 相	83.01	81.65	80.32	78.52
B 相	83.86	81.19	80.17	78.36
C 相	83.92	81.59	80.44	78.85

特别是在信噪比为 10 dB 的强噪声环境下，三相特征的优势更加凸显。这种情况下，三相特征的准确率相比两相特征有 0.5%~0.84% 的提升，说明三相电流数据在抗噪声干扰方面表现更佳，能够更有

效地从噪声中提取出有用的故障信息。

综上所述，虽然两相电流特征在多数情况下已经能够实现较高的诊断准确率，但三相电流特征在提升识别精度和抗干扰能力方面均展现出了其独特的优势。因此，在实际应用中，尤其是在对诊断精度和可靠性要求较高的场合，推荐使用三相电流作为故障诊断的输入特征。

5 结论

本文提出了一种基于小波散射变换与 IRCA-ICA-Res 组合的 VSC-STATCOM 故障诊断方法，通过对比分析和实验验证，得到以下结论。

1) 本文采用小波散射变换技术，对故障信号进行了深入且细致的多层次分解，旨在逐步挖掘并提取出更为细腻和精确的特征信息。这一过程不仅丰富了信号的时频特性表征，还使得原本难以察觉的局部细微变化变得清晰可见，微弱故障特征得到了强化。此举为后续 IRCA-ICA-Res 模型在捕捉和分析这些时频特征时提供了更为丰富和准确的参考依据。

2) 本文提出的 IRCA-ICA-Res 模型，将 IRCA、ICA 与 Resnet 3 种模型进行组合，能够有效地处理小波散射矩阵，深入挖掘并有效利用其时频特征。具体而言，IRCA 以其全局视野，统揽并优化散射矩阵中的时频信息全貌；ICA 则擅长从多维度独立解析，精准剥离并强化单一时频特征；而 Resnet 凭借其多尺度特征提取能力，专注于捕捉并细化局部细节，确保不遗漏任何关键信息。三者的有机结合，不仅实现了优势互补，有效避免了信息冗余，还极大地提升了故障信号分类的准确性和效率。

3) 小波散射变换凭借其降低信号复杂性 with 增强稳健性的特性，与卷积神经网络在提升信号表征能力方面形成互补。两者的组合不仅深化了对信号本质特征的理解，还构建了一个全面且细致的信号表征体系。具体而言，小波散射变换通过其多层分解与特征提取机制，有效简化了信号的复杂结构，同时保留了关键信息，增强了信号处理的稳健性。而卷积神经网络则以其强大的特征学习能力，进一步提升了信号在多维空间中的表征精度与泛化能力。

参考文献

[1] 罗皓泽, 陈忠, 杨为, 等. 压接式 IGBT 和晶闸管器件失效模式与机理研究综述[J]. 中国电力, 2023, 56(5): 137-152.
 LUO Haoze, CHEN Zhong, YANG Wei, et al. Review on failure mode and mechanism of press-pack IGBT and thyristor devices[J]. Electric Power, 2023, 56(5): 137-152.
 [2] FUCHS F W. Some diagnosis methods for voltage source

- inverters in variable speed drives with induction machines—a survey[C] // IECON 03. 29th Annual Conference of the IEEE Industrial Electronics Society, November 2-6, 2003, Roanoke, VA, USA: 1378-1385.
- [3] LAMB J, MIRAFZAL B. Open-circuit IGBT fault detection and location isolation for cascaded multilevel converters[J]. IEEE Transactions on Industrial Electronics, 2017, 64(6): 4846-4856.
- [4] 公铮, 丁家伟, 刘允浩, 等. 基于增量学习的光伏并网逆变器故障诊断[J/OL]. 电力系统及其自动化学报: 1-10[2024-07-03]. DOI:10.19635/j.cnki.csu-epsa.001480. GONG Zheng, DING Jiawei, LIU Yunhao, et al. Fault diagnosis of photovoltaic grid-connected inverter based on incremental learning[J/OL]. Proceedings of the CSU-EPSA: 1-10[2024-07-03]. DOI: 10.19635/j.cnki.csu-epsa.001480.
- [5] 谢丽蓉, 严倡, 吐松江·卡日, 等. 基于特征判定系数的电力变压器振动信号故障诊断[J]. 电力工程技术, 2024, 43(3): 217-225. XIE Lirong, YAN Lü, TUSONGJIANG·Kari, et al. Power transformer vibration signal fault diagnosis based on feature determination coefficient[J]. Electric Power Engineering Technology, 2024, 43(3): 217-225.
- [6] 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.
- [7] 钱存元, 吴昊, 陈昊然. 基于 EMD-BPNN 的逆变器 IGBT 开路故障诊断方法[J]. 电气工程学报, 2024, 19(3): 432-442. QIAN Cunyuan, WU Hao, CHEN Haoran. Open-circuit fault diagnostics method for IGBT of inverter based on EMD-BPNN[J]. Journal of Electrical Engineering, 2024, 19(3): 432-442.
- [8] 李高原, 帕孜来·马合木提, 赵智强, 等. 基于 EWT-WOA-SVM 的三电平逆变器早期故障诊断[J]. 三峡大学学报(自然科学版), 2023, 45(2): 82-88. LI Gaoyuan, PAZILAI·Mahemuti, ZHAO Zhiqiang, et al. Incipient fault diagnosis of three-level inverter based on EWT-WOA-SVM[J]. Journal of China Three Gorges University (Natural Sciences), 2023, 45(2): 82-88.
- [9] 张彼德, 余海宁, 罗荣秋, 等. 光伏并网逆变器参数性故障的 VMD-WPE 和 MPA-LSTM 诊断方法研究[J]. 电力系统及其自动化学报, 2023, 35(2): 140-147. ZHANG Bide, YU Haining, LUO Rongqiu, et al. Research on VMD-WPE and MPA-LSTM diagnostic methods for parametric faults of photovoltaic grid-connected inverters[J]. Proceedings of the CSU-EPSA, 2023, 35(2): 140-147.
- [10] 孙权, 彭飞, 李宏胜, 等. 样本不均衡下基于 CGAN-CNN 的逆变器故障诊断方法[J]. 电源学报, 2024, 22(6): 318-326. SUN Quan, PENG Fei, LI Hongsheng, et al. Inverter fault diagnosis method based on CGAN-CNN under sample imbalance[J]. Journal of Power Supply, 2024, 22(6): 318-326.
- [11] 樊鑫, 程建远, 王云宏, 等. 基于小波散射分解变换的煤矿微震信号智能识别[J]. 煤炭学报, 2022, 47(7): 2722-2731. FAN Xin, CHENG Jianyuan, WANG Yunhong, et al. Intelligent recognition of coal mine microseismic signal based on wavelet scattering decomposition transform[J]. Journal of Coal Science & Engineering, 2022, 47(7): 2722-2731.
- [12] 冯莉, 罗洪林, 许水清. 采用 SDAE-FFNN 网络的 PMSM 逆变器开路故障诊断研究[J]. 重庆理工大学学报(自然科学), 2023, 37(8): 99-108. FENG Li, LUO Honglin, XU Shuiqing. Research on open circuit fault diagnosis of PMSM inverter with SDAE-FFNN network[J]. Journal of Chongqing University of Technology (Natural Science), 2023, 37(8): 99-108.
- [13] 薛阳, 雷文平, 岳帅旭, 等. 多模态学习方法在滚动轴承故障诊断中的应用[J]. 机械科学与技术, 2022, 41(8): 1149-1153. XUE Yang, LEI Wenping, YUE Shuaixu, et al. Application of multimodal deep learning method in rolling bearing fault diagnosis[J]. Mechanical Science and Technology for Aerospace Engineering, 2022, 41(8): 1149-1153.
- [14] 李政, 汪凤翔, 张品佳. 基于图像融合与迁移学习的永磁同步电机驱动器强泛化性故障诊断研究[J]. 中国电机工程学报, 2024, 44(12): 4933-4944. LI Zheng, WANG Fengxiang, ZHANG Pinjia. A strong generalized fault diagnosis method for PMSM drives with image fusion and transfer learning[J]. Proceedings of the CSEE, 2024, 44(12): 4933-4944.
- [15] 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.
- [16] 刘展, 包琰洋, 李大宇. 基于重采样降噪与主成分分析的宽卷积深度神经网络风机故障诊断方法[J]. 发电技术, 2023, 44(6): 824-832. LIU Zhan, BAO Yanyang, LI Dazi. Fault diagnosis method

of wind turbines based on wide deep convolutional neural network with resampling and principal component analysis[J]. Power Generation Technology, 2023, 44(6): 824-832.

[17] 余星辰, 李小伟. 基于小波散射变换的煤矿瓦斯和煤尘爆炸声音识别方法[J]. 煤炭科学技术, 2024, 52(增刊 1): 70-79.
YU Xingchen, LI Xiaowei. Sound identification method of coal mine gas and coal dust explosion based on wavelet scattering transform[J]. Coal Science and Technology, 2024, 52(S1): 70-79.

[18] 马亚飞, 李诚, 何羽, 等. 基于小波散射卷积神经网络的结构损伤识别[J]. 振动与冲击, 2023, 42(14): 138-146.
MA Yafei, LI Cheng, HE Yu, et al. Structural damage identification based on the wavelet scattering convolution neural network[J]. Journal of Vibration and Shock, 2023, 42(14): 138-146.

[19] 李东东, 蒋海涛, 赵耀, 等. 极端条件下基于改进深度森林的行星齿轮箱故障诊断方法[J]. 电力系统保护与控制, 2023, 51(11): 39-50.
LI Dongdong, JIANG Haitao, ZHAO Yao, et al. Fault diagnosis technology of a planetary gearbox based on an improved deep forest algorithm under extreme conditions[J]. Power System Protection and Control, 2023, 51(11): 39-50.

[20] CUI B, TIAN W. Switch open-circuit faults diagnosis of inverter based on wavelet and support vector machine[C]// 2019 14th IEEE International Conference on Electronic Measurement & Instruments, November 1-3, 2019, Changsha, China: 1178-1184.

[21] 朱琴跃, 于逸尘, 占岩文, 等. 基于短时傅里叶变换和深度网络的模块化多电平换流器子模块 IGBT 开路故障诊断[J]. 电工技术学报, 2024, 39(12): 3840-3854.
ZHU Qinyue, YU Yichen, ZHAN Yanwen, et al. IGBT open-circuit fault diagnosis of modular multilevel converter sub-module based on short-time Fourier transform and deep networks[J]. Transactions of China Electrotechnical Society, 2024, 39(12): 3840-3854.

[22] 宋威, 林建维, 周方泽, 等. 基于改进降噪自编码器的风机轴承故障诊断方法[J]. 电力系统保护与控制, 2022, 50(10): 61-68.
SONG Wei, LIN Jianwei, ZHOU Fangze, et al. Wind turbine bearing fault diagnosis method based on an improved denoising AutoEncoder[J]. Power System Protection and Control, 2022, 50(10): 61-68.

[23] 韩争杰, 牛荣军, 马子魁, 等. 基于注意力机制改进残差神经网络的轴承故障诊断方法[J]. 振动与冲击, 2023, 42(16): 82-91.
HAN Zhengjie, NIU Rongjun, MA Zikui, et al. Bearing fault diagnosis methods based on an attentional-mechanism-improved residual neural network[J]. Journal of Vibration and Shock, 2023, 42(16): 82-91.

[24] 毕贵红, 鲍童语, 陈臣鹏, 等. 基于混合分解多尺度时频图和 Res-GRU-AT 的电能质量复合扰动识别[J]. 电力系统保护与控制, 2024, 52(4): 12-25.
BI Guihong, BAO Tongyu, CHEN Chenpeng, et al. Composite PQDs identification based on a hybrid decomposition multi-scale time-frequency map and Res-GRU-AT[J]. Power System Protection and Control, 2024, 52(4): 12-25.

[25] 刘辉, 李永康, 高放, 等. 基于小波散射协同 BiLSTM 的输电线路故障诊断[J]. 国外电子测量技术, 2021, 40(12): 165-172.
LIU Hui, LI Yongkang, GAO Fang, et al. Transmission line fault diagnosis based on wavelet scattering with BiLSTM[J]. Foreign Electronic Measurement Technology, 2021, 40(12): 165-172.

[26] 卢绪祥, 刘顺顺, 陈向民, 等. 基于声发射及 WSTCNN 协同的滑动轴承润滑状态识别[J]. 振动与冲击, 2023, 42(22): 71-77, 229.
LU Xuxiang, LIU Shunshun, CHEN Xiangmin, et al. Identification of the lubrication state of journal bearings based on acoustic emission and WST -CNN collaboration[J]. Journal of Vibration and Shock, 2023, 42(22): 71-77, 229.

收稿日期: 2024-03-31; 修回日期: 2024-08-25

作者简介:

毕贵红(1968—), 男, 博士, 教授, 硕士生导师, 研究方向为新能源系统建模、优化与智能数据分析; E-mail: 1719847159@qq.com

张靖超(1998—), 男, 硕士研究生, 研究方向为电力系统故障诊断分析; E-mail: 3561643731@qq.com

赵四洪(1974—), 男, 通信作者, 硕士, 讲师, 研究方向为电能质量分析控制、电力电子变流器保护控制。E-mail: 20854325@qq.com

(编辑 张颖)