

基于双模式分解多通道输入的 VSC-STATCOM 逆变器故障诊断模型

孔凡文¹, 毕贵红^{1*}, 赵四洪¹, 王祥伟², 陈冬静¹, 张靖超¹, 陈仕龙¹

(1. 昆明理工大学 电力工程学院, 云南 昆明 650500;

2. 云南电网公司昆明供电局电力控制中心, 云南 昆明 650041)

Fault Diagnosis Model of VSC-STATCOM Inverter Based on Dual-Mode Decomposition Multi-Channel Input

KONG Fanwen¹, BI Guihong^{1*}, ZHAO Sihong¹, WANG Xiangwei², CHEN Dongjing¹,

ZHANG Jingchao¹, CHEN Shilong¹

(1. School of Electric Power Engineering, Kunming University of Science and Technology,
Kunming 650500, China;

2. Yunnan Power Grid Company Kunming Power Supply Bureau Power Control Center,
Kunming 650041, China)

Abstract: Aiming at the problems of insufficient signal feature extraction, insufficient recognition ability of deep learning network and low recognition rate under high noise condition in inverter fault diagnosis in traditional voltage source converter static synchronous compensator, an inverter fault diagnosis method based on the combination of dual-mode decomposition, multi-channel input (MCI), parallel convolutional neural network (PCNN), bi-directional long and short-term memory (BiLSTM) neural network and self-attention (SA) mechanism is proposed. Firstly, the three-phase current output of the inverter is decomposed by variational mode decomposition and time-varying filter empirical mode decomposition, which reduces the complexity of the original signal and realizes the law complementation between different modal components. Secondly, MCI-PCNN-BiLSTM-SA combined model is used to extract, learn and recognize the feature matrix. Finally, the proposed method is validated by simulation, and the results show that the proposed method has strong feature extraction ability, with an average recognition rate of 99.48% in the case of no noise and 95.59% in the case of high noise.

Key words: inverter fault diagnosis; dual-mode decomposition; multi-channel input; parallel convolutional neural network; self-attention

摘要: 针对传统电压源型静止同步补偿器中逆变器故

障诊断存在的信号特征提取不充分,深度学习网络识别能力不足以及高噪声情况下识别率较低等问题,提出了一种基于双模式分解、多通道输入(MCI)、并行卷积神经网络(PCNN)、双向长短期记忆(BiLSTM)网络和自注意力(SA)机制组合的逆变器故障诊断方法。首先利用变分模式分解和时变滤波经验模式分解对逆变器输出的三相电流进行分解,降低原始信号复杂程度,实现不同模态分量间的规律互补;其次,利用MCI-PCNN-BiLSTM-SA组合模型对特征矩阵进行深层特征提取、学习和识别;最后,通过仿真进行验证,结果表明所提方法特征提取能力强,在无噪声情况下平均识别率高达99.48%,在高噪声情况下平均识别率达95.59%。

关键词: 逆变器故障诊断; 双模式分解; 多通道输入; 并行卷积神经网络; 自注意力

0 引言

在双碳背景下,高比例可再生能源和高比例电力电子设备逐渐成为新型电力系统发展的重要趋势,而随着大规模的新能源并网、电力电子技术的广泛应用以及各种非线性负荷不断加入,电能质量恶化问题愈发严重^[1-2]。静止同步补偿器(Static Synchronous Compensator, STATCOM)作为无功补偿技术中的重要组成部分,不仅可以进行无功补偿,还可以改善系统稳定性、支撑关键节点

的电压^[3],在提高电网电能质量方面发挥重要作用。绝缘栅双极晶体管(Insulated Gate Bipolar Transistor, IGBT)作为 STATCOM 中的功率开关元件,在实际应用中极易发生单管和双管开路故障^[4]。及时检测和判断 IGBT 的故障情况是确保 STATCOM 安全可靠运行的前提,对保证电力系统的电压稳定及提高供电质量至关重要。

目前,数据驱动的逆变器故障诊断方法主要有基于统计分析的方法、基于信号处理的方法和基于人工智能的方法^[5-6]。其中基于人工智能的逆变器故障诊断方法主要有传统的机器学习方法和深度学习方法。传统的机器学习方法多与信号处理方法结合使用,首先通过快速傅里叶变换^[7]、小波包分解^[8]和经验模态分解(Empirical Mode Decomposition, EMD)^[9]等信号处理方法,得到逆变器故障电流或电压信号的特征分量;其次通过人工选择提取特征并计算其特征量;最后将提取到的特征通过反向传播神经网络^[10]、随机森林^[11]和贝叶斯网络^[12]等人工智能分类算法进行故障特征分类,进而达到故障诊断的目的。然而,该类方法在大规模数据上表现不佳,且特征提取过程主要依靠专家经验,受人为主观因素影响较大,无法适应当前大数据时代背景下逆变器的多类型故障诊断^[6]。为避免传统机器学习方法中人工选取特征的主观性,近年来,基于深度学习的逆变器故障诊断方法得到了快速发展。深度学习利用神经网络自动挖掘、提取特征,在大规模数据上表现较好,能够适应新型电力系统中逆变器故障诊断并达到较高识别率^[13]。基于深度学习的逆变器故障诊断方法主要分为信号预处理与逆变器故障诊断两步。信号预处理阶段对信号进行降噪、降维、分解及归一化等处理,减少噪声、冗余信息,降低原始信号复杂度,消除故障信号中局部变化较大的影响,为深度学习提供合适的输入样本;逆变器故障诊断阶段通过深度学习中的卷积神经网络(Convolutional Neural Network, CNN)^[14]、长短时记忆(Long Short-Term Memory, LSTM)^[15]网络等,对大量输入样本数据进行特征提取与学习,实现对逆变器不同类型故障的诊断。文献[14]使用压缩感知技术将光伏逆变器输出的三相电流信号进行压缩,并重构成二维特征图输入到 CNN 中进行训练,实现 IGBT 开路故障诊断,识

别率可达 98.68%。文献[15]将双桥并联励磁功率单元整流桥共阴极侧、共阳极侧电流和 AB 相线电压构造时序特征向量,通过一维卷积神经网络和 LSTM 提取故障的空间特征和时序特征,实现 IGBT 开路故障诊断,无噪声情况下识别率可达 97.92%,35 dB 噪声情况下识别率达 96.15%。

在深度学习网络结构方面,文献[16]提出一种基于三通道的二维卷积神经网络,将三相电压源型逆变器输出的三相电流信号作为输入数据,利用 3 个通道分别提取三相电流信号特征,对于逆变器单管故障具有较高的诊断精度。文献[17]提出一种并行卷积神经网络(Parallel CNN, PCNN),各分支可以对输入数据进行不同维度的特征学习,随后将学习到的特征进行特征融合进而挖掘更新、更强大的特征,实现对轴承故障的有效诊断,PCNN 相比于传统的 CNN 和残差神经网络具有更高的识别精度。文献[18]提出了一种基于多通道卷积双向长短时记忆(Bi-directional LSTM, BiLSTM)神经网络的输电线故障分类方法,将三相电压幅值数据输入到 3 通道的故障诊断模型中,随后将 3 个通道的特征进行融合,输入到 BiLSTM 网络中进行双向训练,充分利用了故障信号在时序上的特征,相较于其他模型具有更高的诊断精度。文献[19]提出一种基于注意力和 LSTM 网络的多信息特征融合诊断方法,针对中点钳位三电平逆变器 IGBT 开路故障,首先使用 LSTM 网络提取故障特征,随后融合注意力机制对重要特征进行关注,与其他模型相比具有更高的识别精度,但该方法并未考虑高噪声背景下的识别率问题。

目前专门针对变电站中压侧电压源换流器静止同步补偿器(Voltage Source Converter-STATCOM, VSC-STATCOM)的故障诊断研究较少。并网情况下逆变器的 IGBT 开路故障诊断需要考虑负载动态变化,复杂系统各元件间相互作用以及高噪声的影响等因素。针对单一的信号处理方法对复杂信号特征提取不充分、特征量不足等问题,文献[20]使用奇异谱分解和变分模态分解(Variational Mode Decomposition, VMD)对风速序列进行分解,将其分量进行合并输入到双通道 CNN-LSTM 网络中得到风速短期预测结果,实现

不同分解方法的规律互补,有效提高了预测精度。文献[21]首先使用集合 EMD 对风电功率进行初步分解,随后利用小波包分解对经集合 EMD 后的高频信号进一步分解得到特征更强的子序列,利用门控循环单元对不同序列进行预测,发现将不同数学机理的信号处理方法相结合可以有效提高模型的预测精度。

基于以上分析,本文从传统的信号处理和深度学习模型方面进行改进,提出了一种基于双模式分解多通道输入的逆变器故障诊断方法。在信号处理方面,将不同数学机理的信号分解方法相结合,使用 VMD 和时变滤波经验模态分解(Time-Varying Filter EMD, TVF-EMD)对故障信号进行分解,充分提取不同尺度下的故障特征,解决逆变器并网情况下负载动态变化导致的故障数据量大、复杂程度高,故障特征难以提取的问题。在深度学习模型方面,利用 PCNN 和 BiLSTM 充分提取故障数据的空间特征和时序特征,并融合自注意力(Self-Attention, SA)机制提升模型在高噪声背景下的适应能力,提高模型鲁棒性和泛化能力,解决逆变器并网情况下高噪声识别率较低的问题。在有噪声与无噪声情况下对所提方法进行仿真分析,比较单模式分解与双模式分解以及不同深度学习网络结构对故障诊断精度的影响,以此来验证所提方法的有效性。

1 VSC-STATCOM 原理及逆变器故障分析

1.1 VSC-STATCOM 工作原理

图 1 为实际情况下单相 VSC-STATCOM 等效电路及工作向量图。图 1 中: U_s 为电网电压; U_c 为 STATCOM 输出电压; θ 为 U_s 和 U_c 间的相位差; U_L 为电抗 X 和电阻 R 的压降; I 为 STATCOM 从电网侧吸收的电流; δ 为 STATCOM 输出电流与 U_L 夹角。

由 VSC-STATCOM 工作向量图可知, U_c 与 U_s 角度相差 θ ; U_s 与 I 角度相差 $90^\circ + \theta$, 电流存在有功分量。调整 θ 值即可改变 STATCOM 工作状态,对电网进行灵活无功补偿,使电压维持在合适的范围内,提高系统的电压稳定性^[22]。

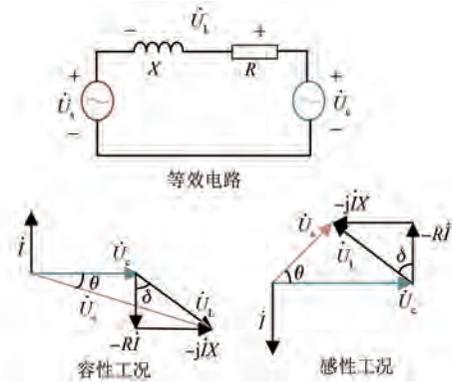


图 1 单相 VSC-STATCOM 等效电路及工作向量图
Fig. 1 Single-phase VSC-STATCOM equivalent circuit and operating vector diagrams

此外,由于电网中存在大量非线性、不对称负载,导致产生高次谐波及负序电流,而 VSC-STATCOM 可以对负序电流以及负荷谐波电流进行综合补偿,从而改善电能质量。

1.2 VSC-STATCOM 控制策略

目前,对于 STATCOM 的控制方法主要是基于对电流的控制,其实现方式有两种,一种是间接控制法,通过调整 STATCOM 的输出电压和相位来间接控制输出电流;另一种是直接控制法,直接控制输出电流的大小。直接控制法具有响应速度快、控制精度高等优点。由于两种方法都基于电流控制,所以电流检测技术在 STATCOM 中非常关键,是验证 STATCOM 是否能够准确进行电网无功补偿的重要前提。常见的电流检测方法有 pq 法、 i_p - i_q 法和 d - q 同步坐标变换法^[23]。本文采用 pq 法,即采用脉宽调制(Pulse Width Modulation, PWM)对 VSC-STATCOM 的输出电流瞬时值进行动态反馈控制,其控制原理如图 2 所示。

pq 法以瞬时电流有功分量作为参考值,主要由 4 个模块组成。

(1) 瞬时功率计算模块:将三相电压 v_{Ga} 、 v_{Gb} 、 v_{Gc} 和不平衡非线性负载处的三相电流 i_a 、 i_b 、 i_c 分别经 $abc-\alpha\beta$ 坐标变换得到其在 α 和 β 轴的分量 v_α 、 v_β 和 i_α 、 i_β ,并合成电压矢量 e 和电流矢量 i ,利用电流与电压相乘求和得到瞬时有功功率 p ,经低通滤波后保留其恒定分量,计算过程如式(1)和式(2)所示:

$$\begin{cases} \begin{bmatrix} v_\alpha \\ v_\beta \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} v_{G_a} \\ v_{G_b} \\ v_{G_c} \end{bmatrix} \\ \begin{bmatrix} i_\alpha \\ i_\beta \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} \end{cases} \quad (1)$$

$$\begin{cases} \mathbf{e} = v_\alpha + jv_\beta \\ \mathbf{i} = i_\alpha + ji_\beta \\ p = v_\alpha i_\alpha + v_\beta i_\beta \end{cases} \quad (2)$$

(2) 直流电压调节器模块:将 STATCOM 直流参考电压 v_{ref}^* 与直流侧电压 v_{dc} 相减后送入比例积分 (Proportional Integral, PI) 环节得到 STATCOM 的有功损耗 \bar{p}_{loss} 。

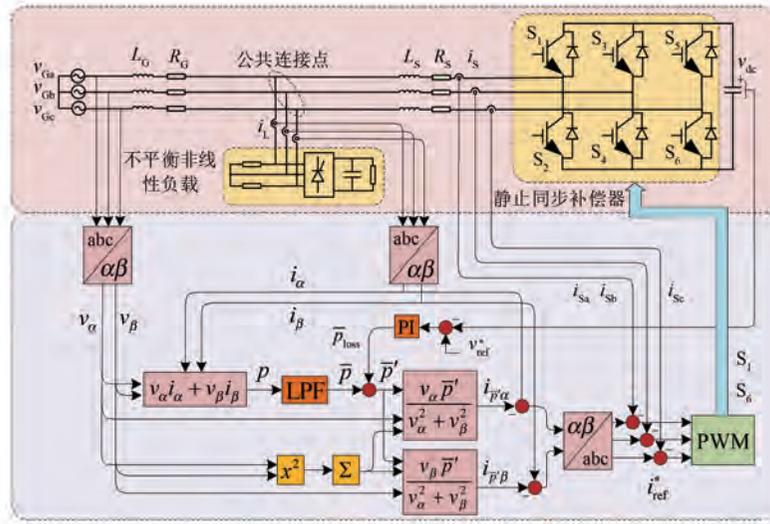


图 2 VSC-STATCOM 控制原理

Fig. 2 Control principle of VSC-STATCOM

(3) 电流参考值计算模块:将恒定有功分量 \bar{p} 和 \bar{p}_{loss} 相加后得到瞬时有功功率 \bar{p}' ;通过式(3)计算求得 α, β 轴上的瞬时有功电流 $i_{\bar{p}'\alpha}, i_{\bar{p}'\beta}$;将 $i_{\bar{p}'\alpha}, i_{\bar{p}'\beta}$ 与 i_α, i_β 相减得到的电流分量经 $\alpha\beta$ -abc 变换得到控制信号的参考电流值 i_{ref}^* 。

$$\begin{cases} i_{\bar{p}'\alpha} = \frac{v_\alpha}{v_\alpha^2 + v_\beta^2} \bar{p}' \\ i_{\bar{p}'\beta} = \frac{v_\beta}{v_\alpha^2 + v_\beta^2} \bar{p}' \end{cases} \quad (3)$$

(4) PWM 控制模块:将参考电流 i_{ref}^* 与逆变器输出电流 i_{S_a}, i_{S_b} 和 i_{S_c} 相减后得到调制信号,经 PWM 调制后生成脉冲信号控制 STATCOM 中功率器件的通断。

1.3 逆变器故障分析

VSC-STATCOM 中逆变器主电路由 6 个桥臂组成,6 个桥臂的 IGBT 模组在控制下依次间隔 60° 顺序导通,正常情况下任意时刻均有 3 个桥臂同时导通,每次变化均在上下两个桥臂之间进行。

在实际情况中三相电压源型逆变器极易发生 IGBT 开路故障,其中发生单管开路故障与双管开路故障居多。双管故障又分为同桥臂双管故障、同相位双管故障和交叉双管故障^[24]。本文针对 VSC-STATCOM 中逆变器发生单管及双管开路故障进行诊断,考虑 IGBT 不同故障位置以及正常工作状态,共计 22 种工作状态,如表 1 所示。

表 1 逆变器故障类型

Tab. 1 Inverter fault types

故障类型	故障位置
正常状态	无
单管故障	$S_1, S_2, S_3, S_4, S_5, S_6$
同桥臂双管故障	$S_1S_3, S_1S_5, S_3S_5, S_2S_4, S_2S_6, S_4S_6$
同相位双管故障	S_1S_2, S_3S_4, S_5S_6
交叉双管故障	$S_1S_4, S_1S_6, S_2S_3, S_3S_6, S_2S_5, S_4S_5$

图 3 为逆变器工作在不同状态下输出的三相电流波形。当系统处于正常运行状态, VSC-STATCOM 输出的电流波形接近正弦波,如图 3 (a) 所示。当逆变器发生单管故障时,输出的电流波形会出现半波缺失的现象,如图 3 (b) 所示,

在 $t = 1.1$ s 时 S_1 发生开路故障, A 相电流波形正半周缺失。当逆变器上桥臂两个开关管同时发生故障时,其所对应相输出电流正半周波形发生变化,如图 3(c) 所示,在 $t = 1.1$ s 时 S_1 、 S_3 发生开路故障, A、B 相电流波形正半周缺失, C 相电流波形为 $I_{Sc} = -(I_{Sb} + I_{Sa})$ 。当逆变器下桥臂两个开关管同时发生故障时,其所对应相输出电流正半周波形发生变化,如图 3(d) 所示,在 $t = 1.1$ s 时 S_2 、 S_4 发生开路故障, A、B 相电流波形负半周缺失, C 相电流波形为 $I_{Sc} = -(I_{Sb} + I_{Sa})$ 。当逆变器某一相

的两个开关管同时发生开路故障时,该相的输出电流为 0,如图 3(e) 所示,在 $t = 1.1$ s 时 S_1 、 S_2 发生开路故障, A 相电流波形输出为 0, B、C 相电流波形为 $I_{Sb} = -I_{Sc}$ 。当逆变器发生交叉双管开路故障时,若是上桥臂的开关管发生故障,其所对应相输出电流正半周波形将发生变化,若是下桥臂的开关管发生故障,其所对应相输出电流负半周波形将发生变化,如图 3(f) 所示,在 $t = 1.1$ s 时 S_1 、 S_6 发生开路故障, A、B 和 C 相电流输出波形为 $I_{Sc} + I_{Sb} + I_{Sa} = 0$ 。

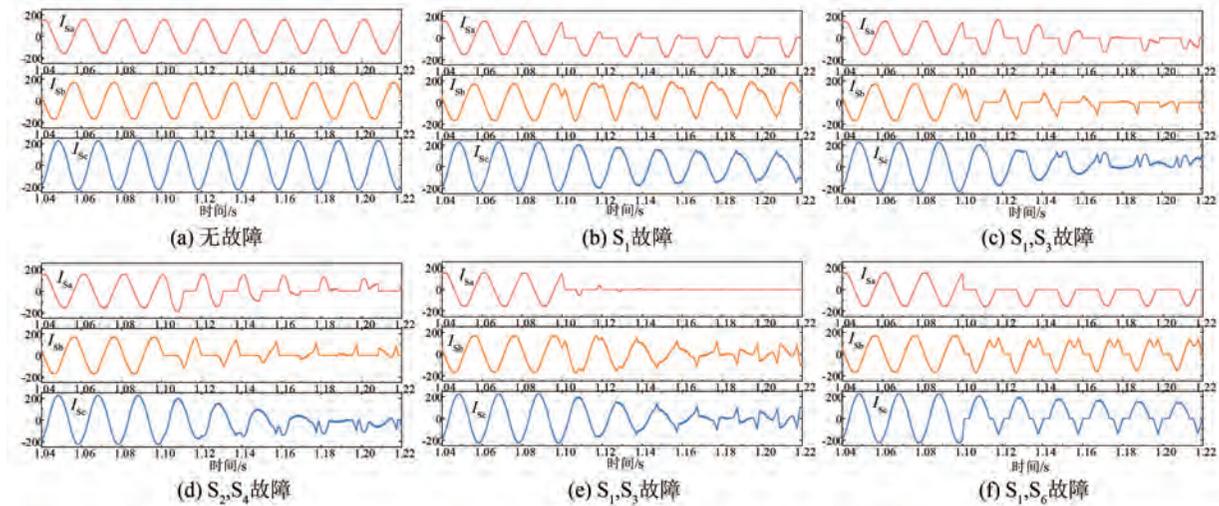


图 3 逆变器不同工作状态下电流输出波形

Fig. 3 Current output waveforms of the inverter in different operating states

2 模态分解方法

2.1 变分模态分解

VMD 算法将信号 $f(t)$ 构造为带约束条件的变分问题,通过多次迭代来寻找变分模型的最优解以此确定信号分解算法中的中心频率及带宽。VMD 算法具体过程如下^[25]。

(1) 通过希尔伯特变换计算得到每个模态函数 $u_k(t)$ 所对应的解析信号,获得其单边频谱,如式(4)所示:

$$\left[\delta(t) + \frac{j}{\pi t} \right] \cdot u_k(t) \quad (4)$$

式中: $\delta(t)$ 为 Dirac 分布。

(2) 将不同模态信号与其所对应的中心频率 ω_k 的指数 $e^{-j\omega_k t}$ 混叠,并将其频谱调制到相应的基频带,如式(5)所示:

$$\left\{ \left[\delta(t) + \frac{j}{\pi t} \right] \cdot u_k(t) \right\} \cdot e^{-j\omega_k t} \quad (5)$$

(3) 利用调节信号高斯平滑法得到各模态信号带宽,构造变分约束模型。该模型需要满足各个本征模态函数(Intrinsic Mode Function, IMF)分量之和等于原始信号 $f(t)$,如式(6)所示:

$$\begin{cases} \min_{\{u_k, \omega_k\}} \left\{ \sum_k \left\| \partial_t \left\{ \left[\delta(t) + \frac{j}{\pi t} \right] \cdot u_k(t) \right\} e^{-j\omega_k t} \right\|^2 \right\} \\ s. t. \sum_{k=1}^k u_k = f(t) \end{cases} \quad (6)$$

式中: $u_k = \{u_1, u_2, \dots, u_k\}$ 为各模态函数; $\omega_k = \{\omega_1, \omega_2, \dots, \omega_k\}$ 为各模态对应的中心频率。

(4) 为求解上式变分模型,引入增广函数 Lagrange 乘法因子 $\lambda(t)$ 和二次惩罚因子 α ,将有约束的变分问题变成无约束的变分问题,如式(7)所示:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \|\partial_t \left[\delta(t) + \frac{j}{\pi t} \right] \cdot u_k(t) e^{-j\omega_k t}\|^2 + \|f(t) - \sum_k u_k(t)\|^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (7)$$

式中： $\langle \cdot \rangle$ 为内积运算。

(5) 迭代交替更新各模态分量 u_k^{n+1} 及其中心频率 ω_k^{n+1} , 如式(8)所示:

$$\begin{cases} u_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i \neq k} u_i(\omega) + \frac{\lambda(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \\ \omega_k^{n+1} = \frac{\int_0^{+\infty} \omega |u_i(\omega)|^2 d\omega}{\int_0^{+\infty} |u_i(\omega)|^2 d\omega} \end{cases} \quad (8)$$

式中： n 为迭代次数； $u_i(\omega)$ 、 $u_k(\omega)$ 、 $f(\omega)$ 和 $\lambda(\omega)$ 分别为 $u_i(t)$ 、 $u_k(t)$ 、 $f(t)$ 和 $\lambda(t)$ 的傅里叶变换。

2.2 时变滤波经验模态分解

针对 EMD 无法区分频率在一个倍频内的两个分量,且容易受到噪声的间歇性影响而产生模态混叠的问题^[26],Li 等人提出 TVFEMD,利用 TVF 对 EMD 分解进行优化^[27],具体步骤如下。

(1) 输入信号 $x(t)$ 经希尔伯特变换后得到 $x'(t)$,其瞬时幅值 $A(t)$ 和瞬时相位 $\varphi'(t)$ 可表示为

$$A(t) = \sqrt{x(t)^2 + x'(t)^2} \quad (9)$$

$$\varphi'(t) = \frac{d}{dt} \arctan[x'(t)/x(t)] \quad (10)$$

对应的解析信号 $z(t)$ 为

$$z(t) = x(t) + jx'(t) = A(t)e^{j\varphi'(t)} \quad (11)$$

(2) 找到 $A(t)$ 的局部极大值和极小值,记为 $A(t_{\max})$ 和 $A(t_{\min})$ 。

(3) 解析信号 $z(t)$ 可以看作是二个信号的组合,如式(12)所示:

$$z(t) = A(t)e^{j\varphi'(t)} = A_1(t)e^{j\varphi'_1(t)} + A_2(t)e^{j\varphi'_2(t)} \quad (12)$$

式中： $A_1(t)$ 和 $A_2(t)$ 为两个分量信号的瞬时幅值； $\varphi'_1(t)$ 和 $\varphi'_2(t)$ 为两个分量信号的瞬时相位。

令 r_1 和 r_2 表示瞬时幅值的变化程度,如式(13)所示:

$$\begin{cases} r_1(t) = |A_1(t) - A_2(t)| \\ r_2(t) = A_1(t) + A_2(t) \end{cases} \quad (13)$$

由于 $A_1(t)$ 和 $A_2(t)$ 变化缓慢, $r_1(t)$ 可以通过 $A(t)$ 极小值 $A(t_{\min})$ 的集合 $\{A(t_{\min})\}$ 的插值来求解,同理可求解出 $r_2(t)$,如式(14)所示:

$$\begin{cases} A_1(t) = [r_1(t) + r_2(t)]/2 \\ A_2(t) = [r_2(t) - r_1(t)]/2 \end{cases} \quad (14)$$

(4) 用同样插值算法,计算 $\varphi'_1(t)$ 和 $\varphi'_2(t)$,令:

$$\begin{cases} \eta_1(t) = \varphi'_1(t) [A_1^2(t) - A_1(t)A_2(t)] + \varphi'_2(t) [A_2^2(t) - A_1(t)A_2(t)] \\ \eta_2(t) = \varphi'_1(t) [A_1^2(t) + A_1(t)A_2(t)] + \varphi'_2(t) [A_2^2(t) + A_1(t)A_2(t)] \end{cases} \quad (15)$$

则, $\varphi'_1(t)$ 和 $\varphi'_2(t)$ 可由式(16)得到:

$$\begin{cases} \varphi'_1(t) = \frac{\eta_1(t)}{2A_1^2(t) - 2A_1(t)A_2(t)} + \frac{\eta_2(t)}{2A_1^2(t) + 2A_1(t)A_2(t)} \\ \varphi'_2(t) = \frac{\eta_1(t)}{2A_2^2(t) - 2A_1(t)A_2(t)} + \frac{\eta_2(t)}{2A_2^2(t) + 2A_1(t)A_2(t)} \end{cases} \quad (16)$$

(5) 计算局部截止频率 $\varphi'_{\text{bis}}(t)$,如式(17)所示:

$$\varphi'_{\text{bis}}(t) = \frac{\varphi'_1(t) + \varphi'_2(t)}{2} = \frac{\eta_2(t) - \eta_1(t)}{4A_1(t)A_2(t)} \quad (17)$$

(6) 调整截止频率 $\varphi'_{\text{bis}}(t)$,解决间歇性问题,找出信号 $x(t)$ 局部极大值,记为 $u_i (i=1,2,3\cdots)$,判断 u_i 是否满足式(18),若满足则记 $\varepsilon_j = u_i (j=1,2,3\cdots)$ 。

$$\frac{\max[\varphi'_{\text{bis}}(u_i, u_{i+1})] - \min[\varphi'_{\text{bis}}(u_i, u_{i+1})]}{\min[\varphi'_{\text{bis}}(u_i, u_{i+1})]} > \rho \quad (18)$$

式中： ρ 为阈值参数,本文取 $\rho = 0.25$ 。

若 $\varphi'_{\text{bis}}(u_{i+1}) - \varphi'_{\text{bis}}(u_i) > 0$, ε_j 为上升沿,反之则为下降沿。对于每一个 ε_j ,若处于上升沿,则 $\varphi'_{\text{bis}}(\varepsilon_{j-1}) - \varphi'_{\text{bis}}(\varepsilon_j)$ 为边界;若处于下降沿,则 $\varphi'_{\text{bis}}(\varepsilon_j) - \varphi'_{\text{bis}}(\varepsilon_{j+1})$ 为边界。 $\varphi'_{\text{bis}}(t)$ 的其余部分则为峰值,在两个峰值之间进行插值,即可得到最终截止频率 $\varphi'_{\text{bis}}(t)$ 。

(7) 通过 $h(t) = \cos[\int \varphi'_{\text{bis}}(t) dt]$,计算出 $h(t)$ 。取 $h(t)$ 极大值点和极小值点作为节点

$m(t)$, 最终构成 B-样条逼近时变滤波器。

(8) 停止准则, 如式 (19) 所示, 若 $\theta(t) < \xi$, ξ 为给定阈值, 则 $x(t)$ 记为局部窄带信号, 否则令 $x(t) = x(t) - m(t)$ 并重复步骤 (1) ~ (8)。

$$\theta(t) = \frac{B_{\text{Loughlin}}(t)}{\varphi_{\text{avg}}(t)} \quad (19)$$

$$B_{\text{Loughlin}}(t) = \sqrt{\frac{A_1'^2(t) + A_2'^2(t)}{A_1^2(t) + A_2^2(t)} + \frac{A_1'(t)A_2'(t)[\varphi_1'(t) - \varphi_2'(t)]^2}{[A_1^2(t) + A_2^2(t)]^2}} \quad (20)$$

式中: $A_1'(t)$ 、 $A_2'(t)$ 分别为 $A_1(t)$ 、 $A_2(t)$ 的导数; $\varphi_{\text{avg}}(t)$ 为加权平均瞬时频率。

3 故障诊断模型

卷积神经网络具有较好的特征提取能力, 通过卷积和池化操作可以自动提取数据中的重要特征, 但对于某些复杂特征, 需要更多的层数堆叠才能将特征提取出来。随着网络的堆积, 出现梯度消失和梯度爆炸的现象将会越来越严重, 导致最终训练效果较差。因此为了解决深层网络出现的梯度消失和梯度爆炸的问题, 提高故障诊断网络的鲁棒性和泛化能力, 提出了基于 MCI-PCNN-BiLSTM-SA 的逆变器故障诊断模型, 模型结构如图 4 所示。

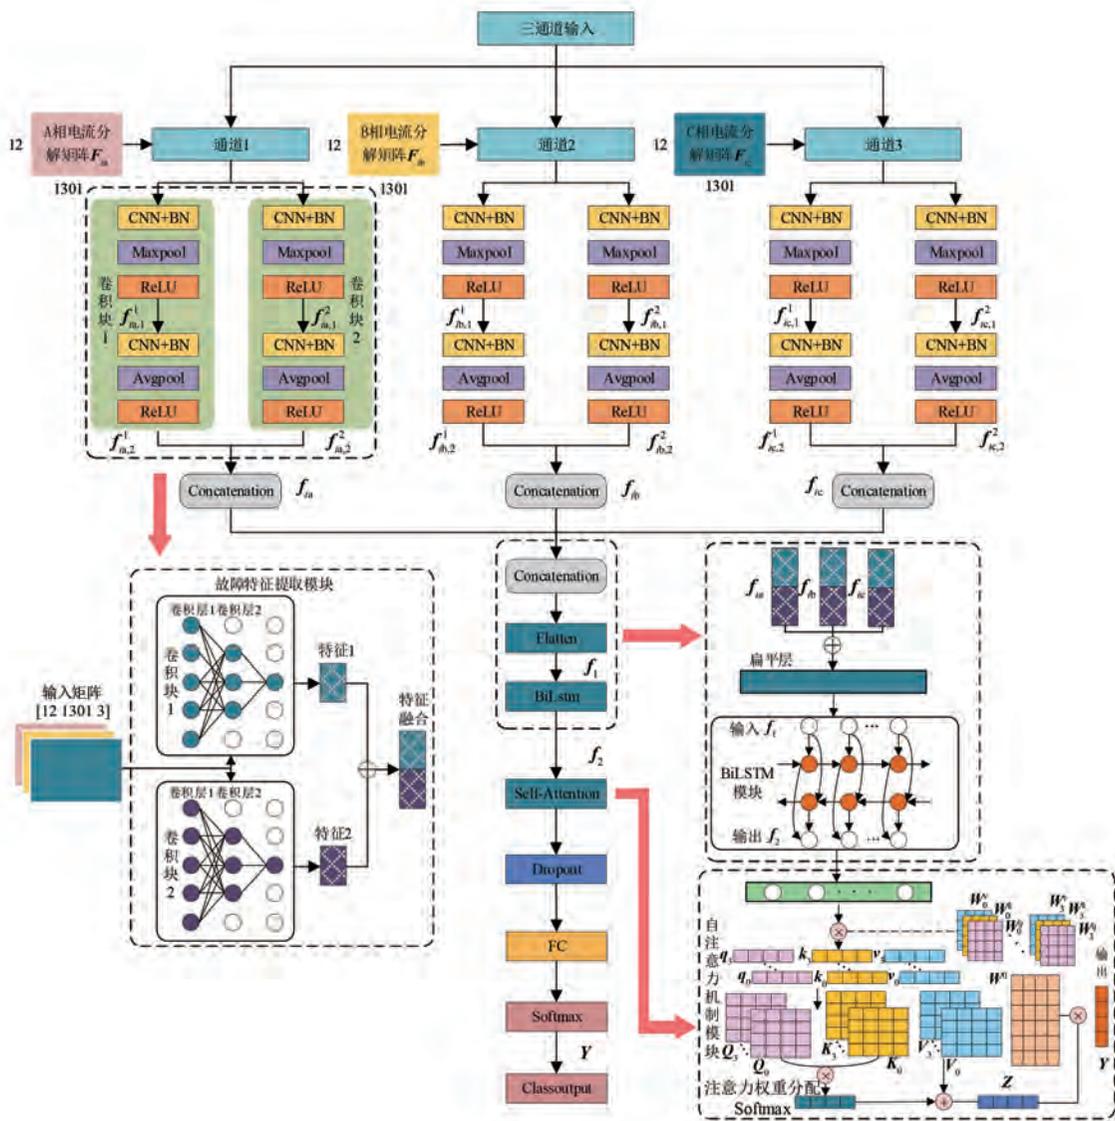


图 4 MCI-PCNN-BiLSTM-SA 模型结构
Fig. 4 MCI-PCNN-BiLSTM-SA model structure

为了充分提取逆变器故障特征,提高模型精度,选取三相电流数据作为模型输入特征量。为增强模型的特征提取能力,实现不同尺度的故障特征提取,设置 2 个支路的并行卷积结构,每个卷积块均有 2 层卷积层。为加快模型收敛速度,防止出现梯度消失和梯度爆炸,减少模型对超参数的敏感性,在卷积层后设置批量归一化层 (Batch Normalization, BN)。由于故障诊断模型输入维度较大,导致特征信息较多,且训练过程较慢,为减少冗余信息,保留经过卷积处理后的重要特征,降低模型计算量加快训练过程,在第 1 层卷积层后设置最大池化层,在第 2 层卷积层后设置平均池化层。通道 1 卷积计算过程如式 (21) 所示,通道 2、3 的计算过程与通道 1 相同。

$$\begin{cases} f_{ia,1}^{i,1} = \delta_r(\sum W_{ia,1}^{i,1} \times F_{ia} + b_{ia,1}^{i,1}) \\ f_{ia,2}^{i,1} = \delta_r(\sum W_{ia,2}^{i,1} \times f_{ia,1}^{i,1} + b_{ia,2}^{i,1}) \\ f_{ia,1}^{i,2} = \delta_r(\sum W_{ia,1}^{i,2} \times F_{ia} + b_{ia,1}^{i,2}) \\ f_{ia,2}^{i,2} = \delta_r(\sum W_{ia,2}^{i,2} \times f_{ia,1}^{i,2} + b_{ia,2}^{i,2}) \\ f_{ia} = f_{ia,1}^{i,2} \oplus f_{ia,2}^{i,2} \end{cases} \quad (21)$$

式中: F_{ia} 为 A 相电流输入矩阵; δ_r 为 Relu 激活函数; $W_{ia,1}^{i,1}$ 和 $W_{ia,2}^{i,1}$ 分别为卷积块 1 的第 1 层和第 2 层的第 i 个卷积核的权重矩阵; $W_{ia,1}^{i,2}$ 和 $W_{ia,2}^{i,2}$ 分别为卷积块 2 的第 1 层和第 2 层的第 i 个卷积核的权重矩阵; $b_{ia,1}^{i,1}$ 和 $b_{ia,2}^{i,1}$ 分别为卷积块 1 的第 1 层和第 2 层的第 i 个卷积核的偏置; $b_{ia,1}^{i,2}$ 和 $b_{ia,2}^{i,2}$ 分别为卷积块 2 的第 1 层和第 2 层的第 i 个卷积核的偏置; $f_{ia,1}^1$ 和 $f_{ia,2}^1$ 分别为卷积块 1 的第 1 层和第 2 层卷积输出特征; $f_{ia,1}^2$ 和 $f_{ia,2}^2$ 分别为卷积块 2 的第 1 层和第 2 层卷积输出特征; \oplus 为向量串联。

将两个卷积块提取到的特征矩阵进行串联得到输出特征矩阵 f_{ia} 。同理,通道 2、3 的输出特征矩阵为 f_{ib} 、 f_{ic} 。

将 3 个通道特征矩阵进行串联合并后,经过扁平层变换为 1 维长向量输入 BiLSTM 模块,通过正向和反向传播规律加强历史数据和未来数据的联系,提高网络的记忆能力,可以更好的挖掘数据的特征信息^[28],其计算过程如式 (22) 和式 (23) 所示:

$$f_1 = \text{flatten}(f_{ia} \oplus f_{ib} \oplus f_{ic}) \quad (22)$$

$$\begin{cases} h_t^{(1)} = \delta_t(W_x^{(1)} f_1 + W_h^{(1)} h_{t-1}^{(1)} + b^{(1)}) \\ h_t^{(2)} = \delta_t(W_x^{(2)} f_1 + W_h^{(2)} h_{t+1}^{(2)} + b^{(2)}) \\ f_2 = \delta_t(W_1 h_t^{(1)} + W_2 h_t^{(2)}) \end{cases} \quad (23)$$

式中: $\text{flatten}()$ 为扁平层; δ_t 为 tanh 激活函数; $h_{t-1}^{(1)}$ 为 $t-1$ 时刻的隐藏状态; $h_t^{(1)}$ 为 t 时刻前向隐藏层状态的输出; $h_{t+1}^{(2)}$ 为 $t+1$ 时刻的隐藏状态; $h_t^{(2)}$ 为 t 时刻后向隐藏层状态的输出; $W_x^{(1)}$ 和 $W_x^{(2)}$ 分别为输入层映射至前向隐藏层和后向隐藏层的权重矩阵; $W_h^{(1)}$ 和 $W_h^{(2)}$ 分别为前向隐藏层和后向隐藏层前一时刻输出映射至当前时刻的权重矩阵; $b^{(1)}$ 和 $b^{(2)}$ 分别为前向隐藏层和后向隐藏层的偏置; W_1 和 W_2 分别为前向隐藏层和后向隐藏层的输出映射至输出层的权重矩阵; f_2 表示输出层的输出。

BiLSTM 模块虽然能提取输入序列的时序特征,但无法确定时序特征中的重要信息,而 SA 机制通过将模型序列中的不同位置进行关联和交互,可以更全面地学习序列中的依赖关系,确定时序特征中的重要信息^[29]。因此本文引入 SA 机制,与 BiLSTM 网络相结合,提高模型提取重要特征的能力。将 BiLSTM 模块的输出向量 f_2 作为 SA 机制模块的输入,其计算过程如式 (24) 所示:

$$\begin{cases} Q_i = \sum f_2 \times W_i^Q \\ K_i = \sum f_2 \times W_i^K, i \in (0, 1, 2, 3) \\ V_i = \sum f_2 \times W_i^V \\ Z = \sum \text{softmax}\left(\frac{Q_i \times K_i^T}{\sqrt{d_k}}\right) V_i \\ Y = Z \times W^0 \end{cases} \quad (24)$$

式中: Q_i 、 K_i 和 V_i 分别为第 i 个查询矩阵、键矩阵和值矩阵; Z 为注意力矩阵; Y 为最终输出矩阵; W_i^Q 、 W_i^K 和 W_i^V 为权重矩阵; d_k 为特征维度; W^0 为初始化矩阵。

随机初始化 4 组权重矩阵 W_i^Q 、 W_i^K 和 W_i^V ($i = 0, 1, 2, 3$), 将 BiLSTM 模块的输出向量 f_2 与这 4 组权重矩阵相乘,得到 4 组 Q_i 、 K_i 和 V_i ; 将矩阵 Q_i 与 K_i 做内积通过 softmax 函数进行归一化得到注意力权重分配,随后将其与矩阵 V_i 相乘并进行加权求和,得到注意力矩阵 Z ; 最后用 Z 与初始化矩阵 W^0 相乘,得到最终输出 Y 。

4 故障诊断流程

基于双模式分解、多通道输入的 MCI-PCNN-BiLSTM-SA 逆变器故障诊断流程如图 5 所示, 具体如下。

(1) 数据采集: 为了验证本文所提方法的可行性, 根据图 2 所示 VSC-STATCOM 原理图, 使用 Matlab/Simulink 搭建故障仿真模型, 采集

22 种不同工作状态下的数据。对于每种故障类型设置故障起始时间为 1.1 s, 在一个 20 ms 的周期内, 以 2 ms 的步长设置 10 种时间偏移量, 即可得到 10 种故障发生时间, 其计算式如式 (25) 所示:

$$\begin{cases} t_i = 1.1 + \Delta_i, i = 1, 2, \dots, 10 \\ \Delta_i = (i - 1) \times 0.002, i = 1, 2, \dots, 10 \end{cases} \quad (25)$$

式中: t_i 为故障发生时间; Δ_i 为时间偏移量。

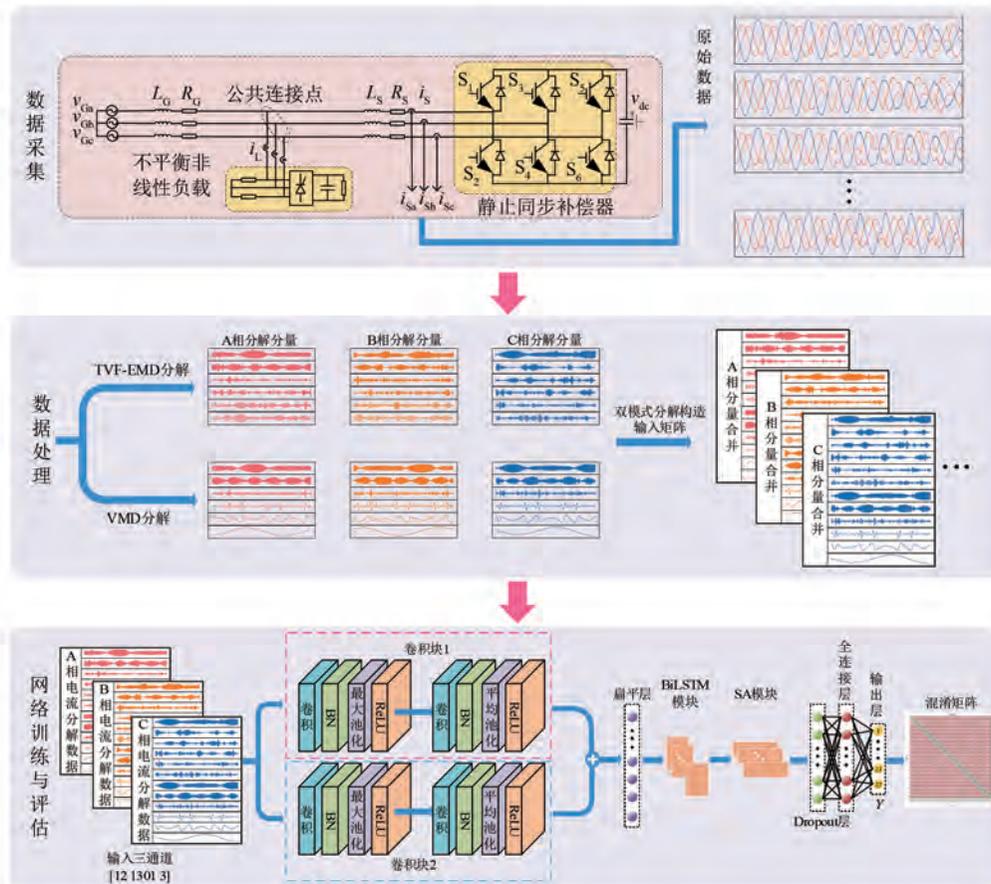


图 5 故障诊断流程

Fig. 5 Fault diagnosis process

每种故障设置 10 种故障发生时间, 模拟不同故障发生时间下 10 种负载运行的三相电流数据, 即每种故障可得到 100 个样本, 22 种不同故障类型共计 2 200 个样本。为了保证生成的故障样本能够有效反映 IGBT 的故障信息, 确保故障诊断的精度, 要求采样频率应至少为开关频率的 2 倍以上, 该模型的开关频率为 10 kHz。此外为了保证有足够故障特征的前提下尽可能减少冗余信息, 从而减少模型计算量, 采样频率也不应过大。最终设置采样频率为 50 kHz, 采集故障点前 0.3

个周期以及后 1 个周期的三相电流数据, 共 1 301 个采样点。

(2) 数据处理: 为提高模型精度, 充分提取故障特征, 考虑利用三相电流值作为 3 个指标, 构造输入为 A、B、C 三相电流数据的三通道故障诊断模型。此外相比于单一模式分解, 双模式分解可以克服单一模式分解方法的缺陷, 实现不同数学机理分解方法之间的规律互补^[30], 因此本文使用 VMD 和 TVF-EMD 对三相电流数据进行分解, 得到不同频率下特征更加明显的子序列, 降低原始

故障信号复杂度,为模型提供合适的输入样本。将由 VMD 分解得到的 6 个子序列和 TVF-EMD 分解得到的 6 个子序列合并,构成原始特征矩阵

F_{ia} 、 F_{ib} 和 F_{ic} 。以 S_1 发生开路故障为例,A 相电流经双模式分解后的结果如图 6 所示,最终得到模型输入特征矩阵为 $[12\ 1\ 301\ 3]$ 。

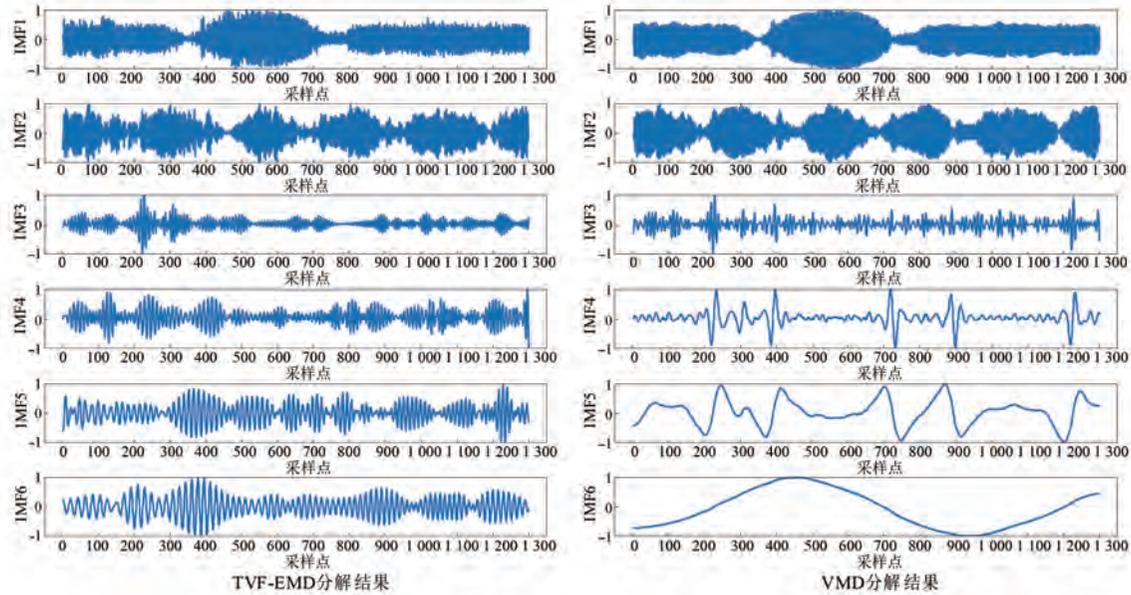


图 6 双模式分解结果

Fig. 6 Dual-mode decomposition results

其次为了使数据处于同一量纲,消除某些局部数据变化较大的影响,突出样本的重要特征,提高模型精度,加快收敛速度,需要对数据进行归一化处理,根据式(26)将分解后的每个子序列数值归一化至 $[-1, 1]$ 区间内。

$$F_{i*}^j = \frac{F_{i*}^j - F_{i*}^{j \cdot \min}}{F_{i*}^{j \cdot \max} - F_{i*}^{j \cdot \min}} \quad (26)$$

式中: F_{i*}^j 和 F_{i*}^j 分别为 * 相分解后第 j 个子序列原始值和归一化后数值; $F_{i*}^{j \cdot \max}$ 和 $F_{i*}^{j \cdot \min}$ 分别为 * 相分解后第 j 个子序列中的最大值和最小值。

(3) 设置标签:VSC-STATCOM 中逆变器主电路由 6 个桥臂组成,编号从上到下依次为 S_1 、 S_2 、 S_3 、 S_4 、 S_5 和 S_6 。考虑单管、双管故障及正常运行状态,共计 22 种工作状态,对应样本标签如表 2 所示。该标签将作为故障诊断模型训练阶段的标准输出。

(4) 训练网络:输入网络的数据样本包括分解归一化后的三相电流数据及样本标签,将 80% 的数据样本划分为训练集,随后将 20% 的数据样本划分为测试集,评估模型性能。

(5) 测试网络:将测试集输入到训练好的模型中,通过比较预测标签与真实标签即可得到该

模型的诊断精度。

表 2 故障类别标签

Tab. 2 Fault category labels

故障模式	样本标签	故障模式	样本标签
无故障	0	S_1 、 S_6 开路	16
S_1	1	S_2 、 S_3 开路	23
S_2	2	S_2 、 S_4 开路	24
S_3	3	S_2 、 S_5 开路	25
S_4	4	S_2 、 S_6 开路	26
S_5	5	S_3 、 S_4 开路	34
S_6	6	S_3 、 S_5 开路	35
S_1 、 S_2 开路	12	S_3 、 S_6 开路	36
S_1 、 S_3 开路	13	S_4 、 S_5 开路	45
S_1 、 S_4 开路	14	S_4 、 S_6 开路	46
S_1 、 S_5 开路	15	S_5 、 S_6 开路	56

5 仿真分析

5.1 模型参数设置

本文提出的 MCI-PCNN-BiLSTM-SA 故障诊断模型,主要包括 PCNN 特征提取模块、BiLSTM 模块和 SA 机制模块。

对于 PCNN 特征提取模块,选择合理的卷积核尺寸能够有效地提取不同尺度下的故障特征,更好地挖掘输入数据的局部细节和相关规律,从

而提高诊断精度;BiLSTM 模块的神经元个数将会直接影响网络的表达能力及拟合程度;引入 SA 机制可以有效提取时序特征中的重要信息进一步提高网络精度。为减小结果的偶然性,选取 10 次仿真结果的平均识别率作为最终的诊断精度。故障诊断模型训练参数设置如下:求解器选择 adam;初始学习率为 0.001,经 50 轮后学习率下降为 0.000 1;批量大小设为 128;最大迭代次数为 100;SA 模块的注意力头和维度分别为 4 和 128。仿真结果如表 3 所示。

由表 3 可知,当 BiLSTM 神经元数为 100,卷积块 1 和卷积块 2 的卷积核大小分别为 3×3 和 4×4 时模型识别精度为 99.48%,相比卷积核为 2×2 和 3×3 、 4×4 和 5×5 以及 5×5 和 6×6 的模型,识别精度分别提高了 0.55%、0.74% 和 2.21%。由此可见,若卷积核选取较小,虽然能提取到某些细节特征,但是会出现特征信息提取不足导致识别精度降低;而卷积核选取过大又会导致某些局部特征丢失,模型识别精度不高。

在卷积核大小为 3×3 和 4×4 下,BiLSTM 神经元数为 100 时模型识别精度为 99.48%,而神经元数为 50 和 150 时,识别精度分别为 98.14% 和

98.77%。结果表明,BiLSTM 神经元数较少时,模型难以挖掘数据内在的复杂关系和重要依赖关系,导致识别精度降低;当 BiLSTM 神经元数较多时,又出现过拟合现象,导致测试精度较低。

综上,确定卷积块 1 和卷积块 2 的卷积核尺寸分别为 3×3 和 4×4 ,BiLSTM 神经元数为 100,以此搭建最优的故障诊断模型。

表 3 不同网络结构及参数下的精度对比

Tab. 3 Accuracy comparison under different network architectures and parameters

卷积核尺寸		BiLSTM 神经元数	精度/%
卷积块 1	卷积块 2		
2×2	3×3	100	98.93
3×3	4×4	100	99.48
4×4	5×5	100	98.74
5×5	6×6	100	97.27
3×3	4×4	50	98.14
3×3	4×4	100	99.48
3×3	4×4	150	98.77

5.2 不同分解方法对比

为进一步验证本文所提双模式分解方法的优越性,建立双模式和单模式分解的故障诊断模型进行对比,模型识别准确率如表 4 所示。

表 4 不同分解模式下识别准确率对比

Tab. 4 Comparison of recognition accuracy under different decomposition modes

故障类型	识别准确率											
	VMD				TVF-EMD				VMD+TVF-EMD			
	无噪声	30 dB	20 dB	10 dB	无噪声	30 dB	20 dB	10 dB	无噪声	30 dB	20 dB	10 dB
无故障	95	95	95	95.5	98.5	98.5	98.5	99	98.5	98.5	98.5	99.5
S ₁ 开路	96.5	97	97	93	98	98	98	97	99.5	99.5	99.5	98.5
S ₂ 开路	97.5	97.5	97.5	97	95	94	96	97.5	98.5	98.5	98.5	98
S ₃ 开路	99	99	99	96.5	95.5	96	95.5	95	100	100	100	99.5
S ₄ 开路	100	100	99.5	98	99	99	99	100	100	100	100	100
S ₅ 开路	97.5	97.5	97.5	96.5	96.5	96.5	96.5	98	99	99	99	98.5
S ₆ 开路	97.5	97.5	98.5	98	97	97	97	98	99.5	99.5	100	100
S ₁ 、S ₂ 开路	100	100	99.5	98.5	100	100	100	99	100	100	100	99.5
S ₁ 、S ₃ 开路	100	100	99.5	86.5	97	97	96	92.5	100	100	99.5	90.5
S ₁ 、S ₄ 开路	99	99	98.5	92.5	83	93	93	91	98.5	98.5	97.5	93.5
S ₁ 、S ₅ 开路	96	96	96	91.5	93	93	92.5	89	100	100	100	95
S ₁ 、S ₆ 开路	98	98.5	99	89.5	97	97	97	92	99.5	99.5	99.5	96.5
S ₂ 、S ₃ 开路	97.5	96.5	96.5	93	93.5	93.5	93	83.5	99.5	100	99.5	96.5
S ₂ 、S ₄ 开路	99.5	99.5	99	97.5	99.5	99	99	94	99	99	99	95.5
S ₂ 、S ₅ 开路	99	99	99	94	94.5	94.5	94.5	90	100	100	99.5	96.5
S ₂ 、S ₆ 开路	96.5	96.5	97.5	89	96	96	96	89.5	99	99	99	97.5
S ₃ 、S ₄ 开路	100	100	100	91	100	100	99.5	98.5	100	100	100	96.5
S ₃ 、S ₅ 开路	97.5	97.5	97	85.5	98.5	98.5	98.5	93	99.5	99.5	98	87.5
S ₃ 、S ₆ 开路	99	99	98.5	87	96.5	96.5	96.5	90.5	99.5	99.5	99	91
S ₄ 、S ₅ 开路	97.5	96.5	95.5	81.5	93	93	92.5	81	99.5	99.5	99	89.5
S ₄ 、S ₆ 开路	97	97	96	82	95.5	95.5	94	85	99.5	99	98.5	87
S ₅ 、S ₆ 开路	100	100	99.5	97.5	99	99	99	96	100	100	100	96.5
平均	98.16	98.11	97.95	92.32	96.16	96.57	96.43	93.14	99.48	99.48	99.25	95.59

由表 4 可知,对于不同故障类型,单模式分解中,在无噪声、30 dB 和 20 dB 噪声情况下 VMD 的平均识别率分别比 TVF-EMD 高 2%、1.54% 和 1.52%,在 10 dB 噪声情况下 VMD 的平均识别率比 TVF-EMD 低 0.82%;而 TVF-EMD 在 30 dB 和 20 dB 噪声情况下平均识别率比无噪声情况下高 0.41% 和 0.27%。这说明不同分解算法对不同信号类型处理和特征提取能力不同,VMD 在无噪声和噪声较低的情况下表现效果较好,TVF-EMD 则在噪声较高的情况下表现较好。

本文将两种不同数学机理的分解算法相结合,在无噪声、30 dB 和 20 dB 噪声下平均识别率均能达到 99.25% 以上,表明双模式分解方法在信噪比较低的情况下能够有效提取故障信号特征,从而提高模型识别率;在 10 dB 高噪声情况下双

模式分解方法识别率为 95.59%,进一步表明双模式分解方法在高噪声情况下具有较强的抗干扰能力。

为进一步验证双模式分解方法具有特征互补能力,使用 t 分布随机邻域嵌入算法提取模型输出特征,以此实现故障特征可视化,如图 7 所示。图 7(a)和图 7(b)分别为 VMD 和 TVF-EMD 下模型最终输出的可视化,可以看出各故障区域之间相距较近,某些不同故障特征还出现了混叠现象,故障诊断可靠性不高;图 7(c)为双模式分解下模型最终输出的可视化,双模式分解下各故障区域之间相距较远,界限明显,同一故障聚集度较高,说明双模式分解方法能够将不同数学机理的分解算法的优势相结合,实现特征互补,提高故障诊断的精度和可靠性。

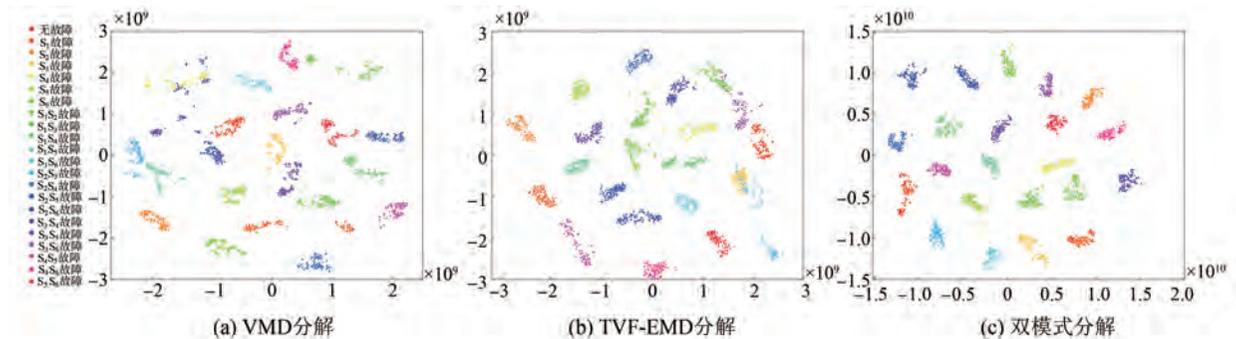


图 7 不同分解方法下模型的输出特征可视化

Fig. 7 Visualisation of model output features for different decomposition methods

5.3 不同模型结果对比

为验证本文模型的优越性,建立双模式分解下 3 通道输入的 PCNN、PCNN-SA、PCNN-BiLSM 模型与本文模型进行对比分析,模型识别准确率如表 5 所示。

表 5 不同模型的识别准确率对比

Tab. 5 Comparison of recognition accuracy of different models %

模型名称	识别准确率	
	无噪声	10 dB
PCNN	96.93	92.01
PCNN-SA	97.39	94.55
PCNN-BiLSTM	99.09	94.57
本文模型	99.48	95.59

PCNN 采用传统的并行卷积神经网络,两个并行支路分别提取信号的不同特征,之后进行特征融合,最终由全连接层输出分类结果。相对于

PCNN,PCNN-SA 引入 SA 机制,在卷积模块提取特征并进行特征融合后对重要特征信息进行提取,在 10 dB 噪声下识别率比 PCNN 提高了 2.54%,表明引入 SA 机制能够提高模型的抗干扰性。相对于 PCNN,PCNN-BiLSTM 引入 BiLSTM 模块,通过正向和反向传播规律加强历史数据和未来数据的联系,在 10 dB 噪声下识别率与 PCNN-SA 相近,但在无噪声情况下识别率高达 99.09%,表明引入 BiLSTM 模块可以有效挖掘数据的特征信息,提升网络的性能。本文所提的 MCI-PCNN-BiLSTM-SA 模型在 10 dB 噪声下,识别准确率分别比 PCNN、PCNN-SA 和 PCNN-BiLSTM 高 3.58%、1.04%、和 1.02%,且在无噪声下识别准确率高达 99.48%。

图 8 为不同模型输出特征可视化对比。图 8 (a)为 PCNN 模型的输出特征可视化,各故障特

征分布混乱,难以区分;图 8(b)为 PCNN-BiLSTM 模型的输出特征可视化,不同故障特征呈现聚集现象,但各故障特征之间相距较近,出现部分特征重叠;图 8(c)为 PCNN-SA 模型的输出特征可视化,不同故障特征聚类效果与图 8(b)类似;图 8(d)为本文模型的输出特征可视化,不同故障区

域之间存在明显的间隔,同一种故障类型的聚集程度较高,聚类效果明显优于前 3 种模型。仿真结果表明,将 PCNN、BiLSTM 网络和 SA 机制相结合能够实现不同网络的优势互补,加强数据联系捕捉故障信号特征,提取重要信息,从而提高学习和识别能力。

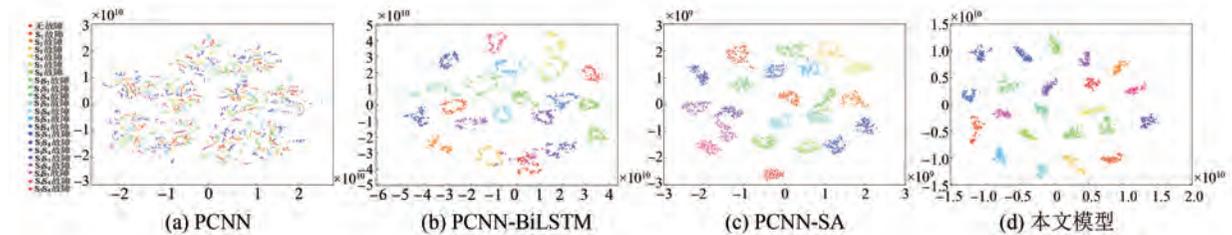


图 8 不同模型的输出特征可视化

Fig. 8 Visualization of output features for different models

6 结语

本文提出一种基于双模式分解的 MCI-PCNN-BiLSTM-SA 故障诊断模型,结合不同网络的优势,实现对 VSC-STATCOM 中 IGBT 故障位置的有效诊断,在高噪声情况下也有较高的识别率。主要结论如下:

(1) 使用 TVF-EMD 和 VMD 双模式分解方法对三相电流信号进行分解,得到不同频率下更能反映原始信号变化规律的模态分量,有效抑制了模态混叠与噪声影响,降低了原始信号复杂性对故障诊断精度的影响。

(2) 利用经双模式分解后的三相电流作为输入数据,构造三通道输入网络,充分结合了故障时三相电流之间的规律特征,通过 PCNN 和 BiLSTM 模块,提取输入数据的空间特征和时序特征;随后融合 SA 机制,对时序特征中的重要信息进行捕捉和学习,在高噪声情况下有效提高了故障诊断精度。

(3) 本文仅考虑了某桥臂仅有一个 IGBT 时的故障识别问题,针对多个三相桥级联或桥臂由多管串并联的 VSC-STATCOM 中的 IGBT 故障识别原理类似,后续研究将做进一步分析。

参考文献

[1] 张智刚,康重庆. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报, 2022, 42(8): 2806-2819.

ZHANG Z G, KANG C Q. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future [J]. Proceeding of the CSEE, 2022, 42(8): 2806-2819.

[2] 谢小荣,贺静波,毛航银,等. “双高”电力系统稳定性的新问题及分类探讨[J]. 中国电机工程学报, 2021, 41(2): 461-475.

XIE X R, HE J B, MAO H Y, et al. New issues and classification of power system stability with high shares of renewables and power electronics [J]. Proceeding of the CSEE, 2021, 41(2): 461-475.

[3] 刘威,季振东,孙毅超,等. 基于双频功率回路的星形级联 H 桥 STATCOM 不平衡补偿研究[J]. 中国电机工程学报, 2023, 43(9): 3527-3538.

LIU W, JI Z D, SUN Y C, et al. Research on unbalance current compensation of star-connected cascaded H-bridge STATCOM based on dual-frequency power loop [J]. Proceeding of the CSEE, 2023, 43(9): 3527-3538.

[4] 唐轶,王扬,赵红璐,等. STATCOM 主回路开关器件故障诊断[J]. 电力系统保护与控制, 2017, 45(19): 55-62.

TANG Y, WANG Y, ZHAO H L, et al. Fault diagnosis of main circuit switching device in STATCOM [J]. Power System Protection and Control, 2017, 45(19): 55-62.

[5] GAO Z, CECATI C, DING X S. 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] 马铭遥, 凌峰, 孙雅蓉, 等. 三相电压型逆变器智能化故障诊断方法综述[J]. 中国电机工程学报, 2020, 40(23): 7683-7699.
- MA M Y, LING F, SUN Y R, et al. Review of intelligent fault diagnosis methods for three-phase voltage-mode inverters [J]. Proceeding of the CSEE, 2020, 40(23): 7683-7699
- [7] XIA Y, XU Y, GOU B. A data-driven method for IGBT open-circuit fault diagnosis based on hybrid ensemble learning and sliding-window classification [J]. IEEE Transactions on Industrial Informatics, 2019, 16(8): 5223-5233.
- [8] 李兵, 崔介兵, 何怡刚, 等. 基于能量谱熵及小波神经网络的有源中性点钳位三电平逆变器故障诊断[J]. 电工技术学报, 2020, 35(10): 2216-2225.
- LI B, CUI J B, HE Y G, et al. Fault diagnosis of active neutral point clamped three-level inverter based on energy spectrum entropy and wavelet neural network [J]. Transactions of China Electrotechnical Society, 2020, 35(10): 2216-2225.
- [9] 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/OL]. 电气工程学报, 2023-07-31. <http://kns.cnki.net/kcms/detail/10.1289.TM.20230729.1700.004.html>.
- QIAN C Y, WU H, CHEN H R. Open-circuit fault diagnostics method for IGBT of inverter based on EMD-BPNN [J]. Journal of Electrical Engineering, 2023-07-31. <http://kns.cnki.net/kcms/detail/10.1289.TM.20230729.1700.004.html>.
- [10] 赵苗苗, 陈小强, 王英, 等. 基于小波包熵及双重优化神经网络的牵引逆变器开路故障诊断[J]. 铁道科学与工程学报, 2022, 19(4): 1101-1110.
- ZHAO M M, CHEN X Q, WANG Y, et al. Open-circuit fault diagnosis of traction inverter based on wavelet packet entropy and double-optimized neural network [J]. Journal of Railway Science and Engineering, 2022, 19(4): 1101-1110.
- [11] 陈石, 张兴敢. 基于小波包能量熵和随机森林的级联 H 桥多电平逆变器故障诊断[J]. 南京大学学报(自然科学), 2020, 56(2): 284-289.
- CHEN S, ZHANG X G. Fault diagnosis for cascaded H-bridge multilevel inverter based on wavelet packet energy entropy and random forest [J]. Journal of Nanjing University (Natural Sciences), 2020, 56(2): 284-289.
- [12] 李凯迪, 伍珣, 赵俊栋, 等. 基于 KPCA-Bayes 的三相逆变器多功率管开路故障诊断研究[J]. 铁道科学与工程学报, 2022, 19(12): 3818-3826.
- LI K D, WU X, ZHAO J D, et al. A KPCA-Bayes based diagnosis method for multiple open-circuit faults of three-phase inverters [J]. Journal of Railway Science and Engineering, 2022, 19(12): 3818-3826.
- [13] 刘闯, 寇磊, 蔡国伟, 等. 基于人工智能的电力电子变换器开路故障诊断研究综述[J]. 电网技术, 2020, 44(08): 2957-2970.
- LIU C, KOU L, CAI G W, et al. Review for AI-based open-circuit faults diagnosis methods in power electronics converters [J]. Power System Technology, 2020, 44(8): 2957-2970.
- [14] WANG X Y, YANG B, LIU Q, et al. Diagnosis for IGBT open-circuit faults in photovoltaic inverters: A compressed sensing and CNN based method [C]// 2021 IEEE 19th International Conference on Industrial Informatics, Palma de Mallorca, 2021.
- [15] 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 Y J, DONG Z, YAO F, 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.
- [16] 商蕾, 武美君, 高海波, 等. 基于三通道 2D-CNN 的逆变器功率管开路故障诊断方法[J]. 船海工程, 2020, 49(1): 78-82.
- SHANG L, WU M J, GAO H B, et al. A diagnostic technique for open-switch fault of inverters based on three-channel 2D-CNN [J]. Ship & Ocean Engineering, 2020, 49(1): 78-82.
- [17] 孟良, 苏元浩, 许同乐, 等. 并行卷积神经网络的风电机组故障诊断方法[J]. 太阳能学报, 2023, 44(5): 449-456.
- MENG L, SU Y H, XU T L, et al. Wind turbine fault diagnosis method based on parallel convolutional neural network [J]. Acta Energetica Solaris Sinica, 2023, 44(5): 449-456.
- [18] 沈银, 席燕辉, 陈子璇. 基于多通道卷积双向长短时记忆网络的输电线故障分类[J]. 电力系统保护与控制, 2022, 50(3): 114-120.

- SHEN Y, XI Y H, CHEN Z X. Transmission line fault classification based on MCCNN-BiLSTM [J]. *Power System Protection and Control*, 2022, 50(3): 114-120.
- [19] SI Y P, WANG R J, ZHANG S Q, et al. Fault diagnosis based on attention collaborative LSTM networks for NPC three-level [J]. *Inverters IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-16.
- [20] 毕贵红, 赵鑫, 李璐, 等. 双模式分解 CNN-LSTM 集成的短期风速预测模型[J]. *太阳能学报*, 2023, 44(3): 191-197.
- BI G H, ZHAO X, LI L, et al. Dual-mode decomposition CNN-LSTM integrated short-term wind speed forecasting model [J]. *Acta Energetica Sinica*, 2023, 44(3): 191-197.
- [21] 殷豪, 欧祖宏, 陈德, 等. 基于二次模式分解和级联式深度学习的超短期风电功率预测[J]. *电网技术*, 2020, 44(2): 445-453.
- YIN H, OU Z H, CHEN D, et al. Ultra-short-term wind power prediction based on two-layer mode decomposition and cascaded deep learning [J]. *Power System Technology*, 2020, 44(2): 445-453.
- [22] 王海峰, 吴新振, 卢子广, 等. 基于 STATCOM 的自激异步发电机小干扰稳定控制[J]. *中国电机工程学报*, 2017, 37(14): 4052-4059.
- WANG H F, WU X Z, LU Z G, et al. Small disturbance stability control of self-excited induction generators based on STATCOM [J]. *Proceeding of the CSEE*, 2017, 37(14): 4052-4059.
- [23] 王焯, 牟宪民, 齐琛. 三相电流源型 STATCOM 的无锁相环控制策略[J]. *电力系统保护与控制*, 2015, 43(14): 131-136.
- WANG Y, MU X M, QI C. A control strategy of three-phase current source converter based STATCOM without PLL [J]. *Power System Protection and Control*, 2015, 43(14): 131-136.
- [24] 徐小健, 于飞. 基于输出电压轨迹的三相逆变器开关管开路故障诊断[J]. *中国电机工程学报*, 2024, 44(3): 1106-1117.
- XU X J, YU F. A fault diagnosis method based on output voltage patterns for switch open-circuit fault of three-phase inverters [J]. *Proceeding of the CSEE*, 2024, 44(3): 1106-1117.
- [25] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [26] 张婉莹, 何耀耀, 杨善林. 基于 TVFEMD-SE 和 YJQRG 的短期风电功率多步概率密度预测[J]. *系统工程理论与实践*, 2022, 42(8): 2225-2242.
- ZHANG W Y, HE Y Y, YANG S L. Multi-step probability density prediction of short-term wind power based on TVFEMD-SE and YJQRG [J]. *System Engineering Theory and Practice*, 2022, 42(8): 2225-2242.
- [27] LI H, LI Z, MO W. A time varying filter approach for empirical mode decomposition [J]. *Signal Processing*, 2017, 138: 146-158.
- [28] 毕贵红, 黄泽, 赵四洪, 等. 基于混合分解和 PCG-BiLSTM 的风速短期预测[J]. *太阳能学报*, 2024, 45(1): 159-170.
- BI G H, HUANG Z, ZHAO S H, et al. Short-term prediction of wind speed based on hybrid decomposition and PCG-BiLSTM [J]. *Acta Energetica Sinica*, 2024, 45(1): 159-170.
- [29] 赵雅婷, 景超, 张兴忠. 基于多重注意力的双通道超短期风电功率预测[J]. *电网技术*, 2023, 47(7): 2887-2897.
- ZHAO Y T, JING C, ZHANG X Z. Dual-channel ultra-short-term wind power prediction based on multi-attention [J]. *Power System Technology*, 2023, 47(7): 2887-2897.
- [30] 毕贵红, 赵鑫, 陈臣鹏, 等. 基于多通道输入和 PCNN-BiLSTM 的光伏发电功率超短期预测[J]. *电网技术*, 2022, 46(9): 3463-3476.
- BI G H, ZHAO X, CHEN C P, et al. Ultra-short-term prediction of photovoltaic power generation based on multi-channel input and PCNN-BiLSTM [J]. *Power System Technology*, 2022, 46(9): 3463-3476.

收稿日期:2024-01-09

收到修改稿日期:2024-03-27

作者简介:

孔凡文(1999-),男,硕士研究生,研究方向为人工智能在电力系统中的应用,1205118679@qq.com;

*通信作者:毕贵红(1968-),男,博士,教授,研究方向为新能源系统建模、优化与智能数据分析等, KM_BGH@163.com。

Fault Diagnosis Model of VSC-STATCOM Inverter Based on Dual-Mode Decomposition Multi-Channel Input

KONG Fanwen¹, BI Guihong^{1*}, ZHAO Sihong¹, WANG Xiangwei², CHEN Dongjing¹,
ZHANG Jingchao¹, CHEN Shilong¹

(1. School of Electric Power Engineering, Kunming University of Science and Technology,
Kunming 650500, China;

2. Yunnan Power Grid Company Kunming Power Supply Bureau Power Control Center,
Kunming 650041, China)

Key words: inverter fault diagnosis; dual-mode decomposition; multi-channel input; parallel convolutional neural network; self-attention

Under the background of carbon peaking and carbon neutrality goals, high proportion of renewable energy and high proportion of power electronic equipment have gradually become an important trend in the development of new power systems. At the same time, with the large-scale new energy grid connection, the wide application of power electronics technology and the continuous addition of various nonlinear loads, the deterioration of power quality is becoming increasingly serious. As an important part of reactive power compensation technology, static synchronous compensator (STATCOM) plays an important role in improving the power quality of power grid. As a power switching element in STATCOM, insulated gate bipolar transistor (IGBT) is prone to single-switch and double-switch open-circuit faults in practical applications. Timely detection and judgment of IGBT faults is the premise to ensure the safe and reliable operation of STATCOM, which is of great significance to the voltage stability of the power system and the improvement of power supply quality.

In this paper, an inverter fault diagnosis method based on the combination of dual-mode decomposition, multi-channel input (MIC), parallel convolutional neural network (PCNN), bi-directional long and short-term memory (BiLSTM) neural network and self-attention (SA) mechanism is proposed. The fault diagnosis process is as follows: Firstly, the fault simulation model is built by Matlab/Simulink, and the three-phase current data under 22 different working conditions are collected. The three-phase current signals are decomposed by time-varying filter empirical mode decomposition and variational mode decomposition, and the multi-scale components of each phase are merged to construct the corresponding characteristic matrix. Subsequently, the proposed combination model is used to learn and identify the feature matrix. The spatial and temporal features of the fault are extracted by PCNN and BiLSTM neural network, and the weight or correlation between different positions is dynamically calculated by the SA mechanism to capture the important information in the features.