

DOI: 10.19650/j.cnki.cjsi.J2413164

# 基于张量分解与宽度学习系统的 MMC 开关管开路故障诊断与定位\*

耿 想<sup>1</sup>, 何顺帆<sup>1</sup>, 朱容波<sup>2</sup>, 段启豪<sup>1</sup>, 田 微<sup>1</sup>

(1. 中南民族大学计算机科学学院 武汉 430074; 2. 华中农业大学信息学院 武汉 430070)

**摘 要:**模块化多电平换流器(MMC)是柔性直流输电系统的核心换流设备,因其采用大量子模块级联的拓扑结构,面临着开关器件数量庞大带来的可靠性挑战,其故障发生率较高。传统 MMC 开关管开路故障诊断方法存在需要额外传感器、阈值易受干扰等问题。故提出了一种基于张量特征提取和二维宽度学习系统的 MMC 开关管开路故障诊断与定位方法,实现了 MMC 开关管开路故障的快速高精度诊断与定位。该方法根据 MMC 结构,采用子模块电容电压数据构造三阶张量,提高了对 MMC 多通道信号的处理效率;通过 Tucker 分解将故障类型分类与故障位置识别任务进行拆分,并提取相应的张量特征,简化了机器学习难度;针对各子任务的张量特征,训练了对应的基于二维宽度学习系统的子分类器,该分类器利用双线性变换在减少参数的同时保留了特征的空间结构,最后综合各个子分类器的输出结果实现了故障诊断和定位。该方法无须额外传感器与经验阈值,同时极大减少了机器学习模型复杂度,从而提高故障诊断和定位的精度与效率,尤其在处理多故障时具有明显优势。仿真和实验表明故障诊断与定位时间 $<15$  ms,准确率高于 98.5%,验证了该方法的优越性与有效性。

**关键词:**模块化多电平换流器;开路故障诊断;张量分解;宽度学习系统

中图分类号: TH183.3 TM46 文献标识码: A 国家标准学科分类代码: 470.40

## Diagnosis and location of switch open-circuit faults in modular multilevel converter based on tensor decomposition and broad learning system

Geng Xiang<sup>1</sup>, He Shunfan<sup>1</sup>, Zhu Rongbo<sup>2</sup>, Duan Qihao<sup>1</sup>, Tian Wei<sup>1</sup>

(1. School of Computer Science, South-Central Minzu University, Wuhan 430074, China;

2. College of Informatics, Huazhong Agricultural University, Wuhan 430070, China)

**Abstract:** The modular multilevel converter (MMC) is a key power conversion component in flexible DC transmission and distribution systems. However, its cascaded submodule topology, which incorporates a large number of switching devices, presents reliability challenges and contributes to a higher failure rate. Traditional open-circuit fault diagnosis methods for MMC switching devices often rely on additional sensors and are susceptible to interference due to threshold sensitivity. To address these limitations, this paper introduces a novel open-circuit fault diagnosis and localization approach based on tensor feature extraction and a two-dimensional broad learning system (2D-BLS), enabling fast and highly accurate fault identification. The proposed method constructs a third-order tensor from submodule capacitor voltage data to efficiently handle multi-channel MMC signals. Through Tucker decomposition, the method separates fault-type classification from fault-location identification while extracting meaningful tensor features. Each subtask's tensor features are then processed using dedicated sub-classifiers built on the 2D-BLS framework. The 2D-BLS employs a bilinear transformation to maintain structural information while significantly reducing the number of parameters. The outputs of all sub-classifiers are subsequently fused to accomplish fault diagnosis and localization. This approach eliminates the need for additional sensors and empirical thresholds, reduces the model's class complexity, and enhances both diagnostic accuracy and computational efficiency. It is particularly well-suited for handling multiple open-circuit faults in switching devices. Simulation and experimental results confirm that the proposed method achieves a diagnosis and localization time of less than 15 ms with an accuracy exceeding

收稿日期: 2024-08-13 Received Date: 2024-08-13

\* 基金项目: 国家自然科学基金项目(61903384)、湖北省自然科学基金面上项目(2025AFB741)、湖北省科技计划项目(2024BAB070)资助

98.5%, demonstrating its effectiveness and superiority.

**Keywords:** modular multilevel converter; open-circuit fault diagnosis; tensor decomposition; broad learning system

## 0 引 言

换流器是智能电网必要的接口设备,其安全稳定运行是保障智能电网可靠性的基石之一。开关器件是换流器常见故障器件,故障率高、危害性大。开关器件故障可以分为短路故障和开路故障,其中短路故障特征明显,易采用常规的短路保护策略进行检测和处理<sup>[1]</sup>,而开路故障特征形式多样,对系统整体运行的影响较为隐蔽,还会引起二次故障。因此,换流器开关器件开路故障引起了广泛关注<sup>[2-6]</sup>。

模块化多电平换流器(modular multilevel converter, MMC)具有波形质量好,转换效率高,扩展性强等优势,目前已在高压直流输电、新能源发电并网等领域得到广泛应用<sup>[7-12]</sup>。MMC的稳定运行对提高电力系统的性能和可靠性具有重要意义。然而,因产生多个电平,MMC开关管数量较其他类型换流器大幅增加,使得其开关管开路故障诊断与定位更加困难。

现有的 MMC 子模块开关管开路故障诊断方法可分为基于硬件的方法、基于模型的方法和基于机器学习的方法。基于硬件的方法诊断迅速且计算量小,但需增设传感器,改变设备结构。Liu 等<sup>[13]</sup>通过开关函数的逻辑信号与检测单元结合实现故障诊断,但是该方法需在每个子模块中安装基于泄放电阻电路的检测单元,增加了额外硬件。基于模型的方法通常利用数学模型和设备状态信息对 MMC 进行建模,根据模型信息的阈值进行故障诊断与定位。Jin 等<sup>[14]</sup>通过将输出电流和环流与其估计值之间的误差与其阈值进行比较,对故障桥臂进行初步定位,然后对电容电压最高的子模块进行偏差分析和定位。Li 等<sup>[15]</sup>利用状态观测器对桥臂电流和输出电流进行状态估测,将估测值与子模块电容电压结合进行故障诊断。配电网谐波含量较高,并网点电压谐波会导致 MMC 输出电流畸变,影响诊断效果。Zhou 等<sup>[16]</sup>通过对正常和故障状态下的子模块电容电压进行相似度分析,实现故障诊断与定位,该方法使用子模块电容电压,且诊断时间较短。Zhou 等<sup>[17]</sup>利用单环理论进行故障诊断,该方法诊断数据源仅使用子模块电容电压,且适用于多个子模块故障,但是诊断时间较长。基于模型的方法不需要添加额外的硬件电路,但模型阈值的设置大多依赖人工经验,且诊断结果容易受到系统参数变化、设备工作状态和外界环境干扰等因素影响。

近年来,随着处理器性能不断提升,基于机器学习的方法逐渐成为研究热点。基于机器学习的方法不需要

额外传感器、不用建立复杂的数学模型,不依赖人工经验阈值,通常利用子模块电压、桥臂电流等 MMC 运行所需的电气信号数据进行故障诊断与定位,具有较强的实用性与经济性。Li 等<sup>[18]</sup>针对 MMC 的数据特点,采用了混合核函数的支持张量机模型处理张量子空间数据,实现了更高的分类精度,但该方法以桥臂为基本单元进行分析,无法确定故障子模块具体位置。Deng 等<sup>[19]</sup>基于滑动窗的特征关系进行故障特征提取,通过二维卷积神经网络进行故障诊断,但该方法需要人工设计特征且算法计算量较大。Hu 等<sup>[20]</sup>提出一种基于极端梯度提升算法的故障诊断方法,该方法对外界噪声和缺失数据具有很好的鲁棒性,但是算法复杂度高,占用的数据存储空间相对较大。Kiranyaz 等<sup>[21]</sup>提出了一种基于自适应一维卷积神经网络的故障诊断与定位方法,该方法将特征提取和分类融合为一个学习主体,提高了分类性能。但是,该方法将各个子模块电容电压和负载电流数据直接向量化作为网络的输入,将不同位置的不同种类故障作为类别输出,随着系统电压和功率等级的提高,MMC 子模块数量增加,该方法需要处理的数据量会快速增大,分类数增多,影响计算速度和拟合精度。杨贺雅等<sup>[22]</sup>提出了基于随机森林二分类器的故障诊断模型,仅采用电压数据的特征量判断每个子模块的工作状态。然而,该方法无法区分具体的故障类型。此外,该方法构造故障特性进行分类的基本单元是子模块,而不是 MMC 整体系统,需要重复对每个子模块进行计算。朱琴跃等<sup>[23]</sup>采用了基于短时傅里叶变换的故障特征提取方法,分别采用了基于深度置信网络的故障检测方法和基于卷积神经网络(convolutional neural network, CNN)的故障定位方法,但其模型结构复杂,计算量较大。MMC 子模块开关管开路故障具有故障类型和故障位置两个关键因素,MMC 结构的复杂性导致其开关管开路故障类别数量巨大。基于机器学习的方法面临的主要问题是模型分类数多,计算开销高,多故障问题分类难度大。

MMC 是多输入多输出系统,包含多路电气信号,具有物理含义明确的信号张量空间,其开关管开路故障通过电气信号畸变进行表达,故障类型与位置分别对应了特定类型信号的畸变模式与其在张量空间中的坐标区域。张量对高维数据具有很好的表示能力,利用张量方法对高维数据进行处理可以显著降低计算复杂度,提高计算效率,同时可以更好地维持数据的结构信息<sup>[24-27]</sup>。特别地,He 等<sup>[27]</sup>提出了一种基于张量分解的多通道电力信号大数据处理方法。宽度学习系统(broad learning system, BLS)是基于随机向量函数神经网络提出的一

种新的机器学习方法,作为深度学习的一种替代方法,改善了深度学习训练过程耗时的问题,运算速度快且模型简单<sup>[28]</sup>。

新方法采用张量方法提取多通道 MMC 故障电气信号特征,并利用二维宽度学习系统(2D-BLS)识别特征,实现 MMC 开关管开路故障诊断与定位,与传统方法相比具有的优势为:

1) 仅使用子模块电容电压信号,无须额外传感器且基于数据驱动,不需要设定经验阈值。

2) 利用数据的时序和位置关系进行张量构造,采用 Tucker 分解算法进行故障特征提取,将故障类型分类任务与故障位置识别任务进行拆分,极大的降低了机器学习难度,进而提高了故障分析的准确性。

3) 设计了 2D-BLS,更好地适配了特征数据的张量结构,有效减少了模型参数数量,降低了计算量,进而提高了故障分析的效率。

## 1 张量构造及特征提取方法

### 1.1 MMC 基本原理及开路故障特性分析

三相 MMC 电路拓扑结构如图 1 所示。MMC 电路采用三相六桥臂结构,每一相由上、下两个桥臂组成,每个桥臂由  $N$  个结构相同的半桥子模块(sub-module, SM)与一个桥臂电阻和电感组成。半桥 SM 由一个直流储能电容  $C_{SM}$ 、两个互补的开关管(一般为绝缘栅双极性晶体管, insulated gate bipolar transistor, IGBT)、两个续流二极管( $D_1, D_2$ ) 组成。交流侧电压、电流分别为  $u_j$  和  $i_j$ ,  $j = a, b, c$ , 直流侧电压、电流可表示为  $U_{dc}$  和  $I_{dc}$ 。  $j$  相上桥臂电压、电流分别为  $u_{uj}$  和  $i_{uj}$ ,  $j$  相下桥臂电压、电流分别为  $u_{lj}$  和  $i_{lj}$ 。  $i_{arm}$  为流入 SM 的电流,  $U_C$  为 SM 电容电压,  $L$  为桥臂电感,  $R$  为桥臂等效电阻。

SM 开关函数  $S$  可表示为:

$$S_{xji} = \begin{cases} 1, & T_1 \text{ 导通且 } T_2 \text{ 关闭} \\ 0, & T_1 \text{ 关闭且 } T_2 \text{ 导通} \end{cases} \quad (1)$$

正常运行时 MMC 各 SM 输出侧电压为:

$$U_{SMxji} = S_{xji} \times U_{Cxi} \quad (2)$$

式中:  $U_{SMxji}$  表示  $j$  相的桥臂  $x$  ( $x = u$  或  $l$ , 表示上桥臂或下桥臂) 中第  $i$  个 SM 输出电压;  $U_{Cxi}$  表示第  $i$  个 SM 电容电压;  $S_{xji}$  表示开关函数, 当  $S_{xji} = 1$  时, 上管 IGBT 导通, SM 投入运行, 此时 SM 输出电压等于电容电压; 当  $S_{xji} = 0$  时, 下管 IGBT 导通, SM 被旁路, 此时 SM 输出电压为 0。

SM 开关开路故障根据不同的故障点可以分为  $T_1$  开路故障和  $T_2$  开路故障, 2 种开路故障类型以及开路故障下 SM 内部运行情况如图 2 所示, SM 不同状态下的运行情况如表 1 所示。

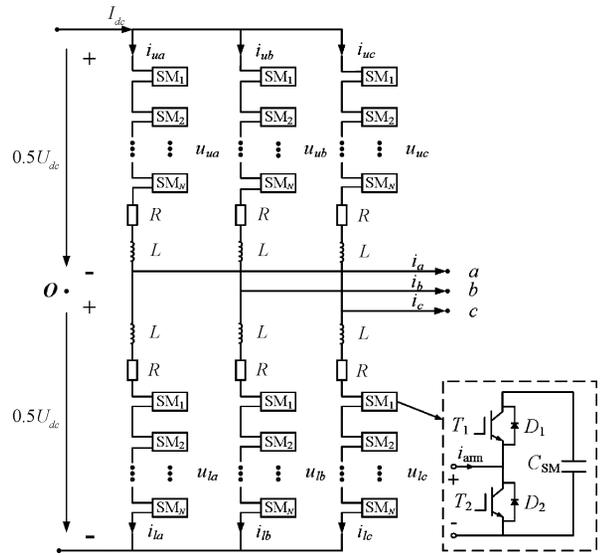


图 1 三相 MMC 电路拓扑结构

Fig. 1 Topology of the three-phase MMC circuit

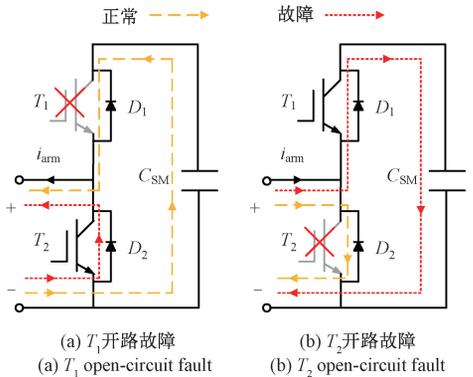


图 2 两种类型的 SM 开路故障

Fig. 2 Two types of SM open-circuit faults

根据电流  $i_{arm}$  状态和 SM 开关函数  $S_{xji}$ , 电流通路可以被分为 4 种。当 SM 中的  $T_1$  或者  $T_2$  发生开路故障时, 电流  $i_{arm}$  不能流过故障的 IGBT, 因此在开路故障发生后流经 SM 的电流路径和正常 SM 的电流路径有所不同。

当  $T_1$  发生开路故障时, 如图 2(a) 所示, 当  $i_{arm} < 0$  且开关状态  $S_{xji} = 1$  时, 电流  $i_{arm}$  由于  $T_1$  发生开路故障被迫流经  $D_2$  (图 2(a) 中点线所示),  $T_1$  开路故障切断了电容放电的路径 (图 2(a) 中虚线所示), 此时电容运行情况由放电转变为旁路, 故障 SM 电容电压将保持不变。

当  $T_2$  发生开路故障时, 如图 2(b) 所示, 当  $i_{arm} > 0$  且开关状态  $S_{xji} = 0$  时, 电流  $i_{arm}$  由于  $T_2$  发生开路故障被迫流经  $D_1$  (图 2(b) 中点线所示), 电流无法流经  $T_2$  使电容旁路 (图 2(b) 中虚线所示), 此时电容运行情况由旁路转变为充电, 该阶段电容电压持续升高。

表 1 不同状态下 SM 运行情况

Table 1 Operating conditions of SM under different states

状态	$i_{arm}$	$S_{xji}$	流经器件	$U_{SM_{xji}}$	电容运行情况
正常 SM	>0	1	$D_1$	$U_{C_{xji}}$	充电
		0	$T_2$	0	旁路
	<0	1	$T_1$	$U_{C_{xji}}$	放电
		0	$D_2$	0	旁路
$T_1$ 开路故障	>0	1	$D_1$	$U_{C_{xji}}$	充电
		0	$T_2$	0	旁路
	<0	1	$T_1 \rightarrow D_2$	$U_{C_{xji}} \rightarrow 0$	放电 $\rightarrow$ 旁路
		0	$D_2$	0	旁路
$T_2$ 开路故障	>0	1	$D_1$	$U_{C_{xji}}$	充电
		0	$T_2 \rightarrow D_1$	$0 \rightarrow U_{C_{xji}}$	旁路 $\rightarrow$ 充电
	<0	1	$T_1$	$U_{C_{xji}}$	放电
		0	$D_2$	0	旁路

$$(T \times_n U)_{i_1, \dots, j_n, \dots, i_N} = \sum_{i_n=1}^{I_n} T_{i_1, \dots, i_n, \dots, i_N} \cdot U_{j_n, i_n} \quad (3)$$

张量 Tucker 分解: 张量 Tucker 分解是奇异值分解 (singular value decomposition, SVD) 概念的多线性推广。Tucker 分解将高阶张量表示为一个核张量和每个张量模对应因子矩阵的乘积。对张量  $T \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$  进行 Tucker 分解, 则  $T$  可近似地表示为:

$$T \approx G \times_1 U^{(1)} \times_2 U^{(2)} \dots \times_N U^{(N)} \quad (4)$$

式中: 张量  $G \in \mathfrak{R}^{P_1 \times P_2 \times \dots \times P_N}$  为核张量,  $P_n < I_n$ 。以三阶张量  $T \in \mathbf{R}^{I_1 \times I_2 \times I_3}$  为例, 其 Tucker 分解结果如图 4 所示。

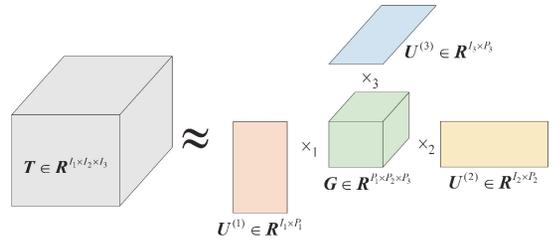


图 4 三阶张量的 Tucker 分解

Fig. 4 Tucker decomposition of 3-order tensor

### 1.2 张量理论基础

张量可视为向量和矩阵的高阶扩展, 它可以保持数据潜在的空间结构信息, 更好描述和表示高维数据。下面介绍相关张量理论基础。

张量的表示: 一个  $N$  阶张量可表示为  $T \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$ , 其中,  $I_n$  表示张量第  $n$  模的长度, 且  $n = 1, \dots, N$ 。张量  $T$  中的某个元素可以表示为  $T_{i_1 i_2 \dots i_N}$ 。

张量的模展开: 张量可以沿其任一模态展开为矩阵, 将张量  $T \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$  沿第  $n$  模展开时, 保持  $T$  中元素脚标为  $i_n$  的不变, 其他元素依次排列, 第  $n$  模展开得到的矩阵可表示为  $T_{(n)} \in \mathbf{R}^{I_n \times (I_1 \times \dots \times I_{n-1} \times I_{n+1} \times \dots \times I_N)}$ 。以三阶张量  $T \in \mathbf{R}^{3 \times 4 \times 5}$  为例, 其张量的模展开过程如图 3 所示。

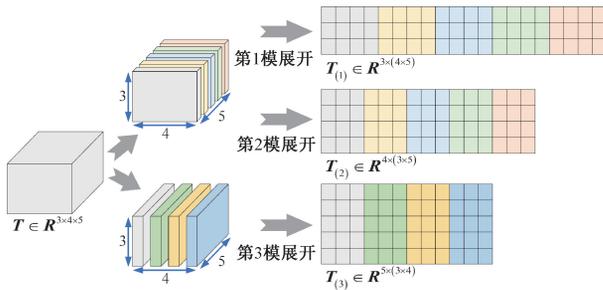


图 3 三阶张量模展开示例

Fig. 3 Example of 3-order tensor unfolding

张量的模态积: 张量  $T \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$  与矩阵  $U \in \mathbf{R}^{I_n \times J_n}$  的第  $n$  模的模态积可表示为  $T \times_n U$ , 其维度为  $I_1 \times \dots \times I_{n-1} \times J_n \times I_{n+1} \times \dots \times I_N$ , 定义为:

### 1.3 故障数据样本的张量构造

为了更好地对 MMC 高维故障信号数据进行描述, 构造张量型电气信号数据样本。在电压传感器获取电容电压数据后, 采用滑动时间窗口对数据进行分割处理。滑动窗口长度为一个周波, 每个窗口取得一个周波内所有 SM 的电容电压。将一次滑动截取的数据表示为三阶张量  $T \in \mathbf{R}^{I_1 \times I_2 \times I_3}$ , 作为一个样本, 滑动窗口截取数据及张量构造过程如图 5 所示。

该张量样本各模态具备不同的物理含义, 其中第 1 模代表桥臂位置, 第 2 模代表周波信号特征, 第 3 模代表子模块位置。

### 1.4 基于 Tucker 分解特征提取方法

MMC 子模块开关管故障诊断与定位的最终结果包含故障类型 (正常、 $T_1$  故障或  $T_2$  故障等) 与故障位置 (故障桥臂与故障模块)。结合 MMC 拓扑结构, 将故障诊断与定位任务拆分为故障类型识别子任务、故障桥臂识别子任务和故障模块识别子任务, 并针对各子任务分别提取特征。

对于样本集中的三阶张量对象  $T \in \mathbf{R}^{I_1 \times I_2 \times I_3}$ , 根据式 (4), 经 Tucker 分解后得到 3 个投影矩阵  $U^{(1)}$ 、 $U^{(2)}$ 、 $U^{(3)}$  与一个核张量  $G$ 。3 个投影矩阵分别代表其对应子任务的特征, 其中  $U^{(1)}$  代表故障桥臂位置特征,  $U^{(2)}$  表达了故障信号周波内的变化, 代表故障类型特征,  $U^{(3)}$  代表故障信号模块位置特。据此实现了故障类型、故障桥臂与故障模块对应特征的提取。

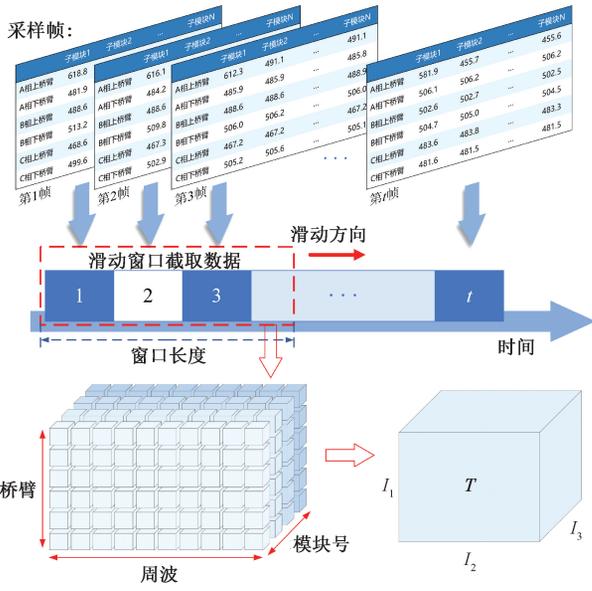


图5 张量构造过程

Fig. 5 Tensor construction process

Tucker 分解应用了高阶奇异值分解 (higher-order singular value decomposition, HOSVD) 方法实现,实现过程如算法 1 所示。

算法 1: MMC 多通道电器信号三阶张量的 HOSVD

输入:原张量  $T \in \mathbf{R}^{I_1 \times I_2 \times I_3}$ , 张量核维度  $P_1, P_2, P_3$ .

输出:张量核  $G \in \mathbf{R}^{P_1 \times P_2 \times P_3}$ , 一组模态矩阵  $U^{(1)}, U^{(2)}, U^{(3)}$ .

1. For  $d = 1, 2, 3$  do
2. 将  $T$  沿  $d$  模展开, 得  $T_{(d)}$ .
3. 对  $T_{(d)}$  进行 SVD,  $T_{(d)} = U^{(d)} \Sigma^{(d)} V^{(d)T}$ .
4. 将左奇异值矩阵  $U^{(d)}$  在第  $P_d$  列进行截断并保存.
5. 计算核心张量  $G = T \times_1 U^{(1)T} \times_2 U^{(2)T} \times_3 U^{(3)T}$ .

张量核各模态的维度  $P_d$  即为  $d$  模展开矩阵  $T_{(d)}$  进行 SVD 后保留的最大奇异值及对应奇异向量的个数。依据 HOSVD 计算过程中各模态保留能量信息的比例来确定  $P_d$ , 求解方法为:

- 1) 在全体样本集中随机选择  $N$  个张量样本, 作为  $T_i \in \mathbf{R}^{I_1 \times I_2 \times I_3}, i = 1, \dots, N$ .
- 2) 将每个样本  $T_i$  沿其各模展开, 得  $T_{i(d)}, d = 1, 2, 3$ .
- 3) 对  $T_{i(d)}$  进行 SVD, 分解得到奇异值矩阵  $\Sigma_i^{(d)} = \text{diag}(\sigma_{i1}^{(d)}, \sigma_{i2}^{(d)}, \dots, \sigma_{iM}^{(d)})$ , 矩阵中元素按从大到小排序, 其值越大代表其对应向量组重要性越高。
- 4) 设定保留能量信息的比例为 90%, 则样本  $T_i$  需要保留的最大奇异值个数  $P_{di}$  可由式 (5) 计算。

$$\arg \min_{P_{di}} \frac{\sum_{m=1}^{P_{di}} \sigma_{im}^{(d)2}}{M} \geq 90\% \quad (5)$$

5)  $P_d$  取  $\{P_{di}, i = 1, 2, \dots, N\}$  中的众数。

## 2 诊断模型

### 2.1 宽度学习系统原理

宽度学习系统 (BLS) 是基于随机向量函数神经网络提出的一种新的机器学习方法。BLS 以平面网络形式建立, 将原始输入的数据进行线性映射作为映射特征置于特征节点中, 再将特征节点进行广义扩展, 得到增强节点, 特征节点和增强节点共同构成 BLS 隐藏层。BLS 作为深度学习的一种替代方法, 改善了深度学习训练过程耗时的问题, 运算速度快且模型简单。BLS 结构如图 6 所示。

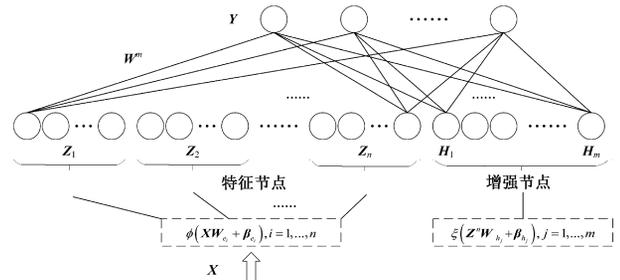


图6 宽度学习系统结构

Fig. 6 Architecture of the broad learning system

假设输入数据集  $X$  有  $N$  个样本, 每个样本有  $M$  个维度,  $Y$  表示  $X$  的标签,  $Y \in \mathbf{R}^{N \times C}$ 。对于  $n$  组特征映射, 用  $Z_i$  表示具有  $r$  个神经元的第  $i$  组特征节点, 有:

$$Z_i = \phi(XW_{e_i} + \beta_{e_i}), i = 1, \dots, n \quad (6)$$

式中:  $W_{e_i}$  和  $\beta_{e_i}$  为随机产生的权重和偏置;  $\phi(\cdot)$  为激活函数。将全部的  $n$  组特征节点拼接为  $Z^n = [Z_1, \dots, Z_n]$ , 用  $H_j$  表示第  $j$  组增强节点, 有:

$$H_j = \xi(Z^n W_{h_j} + \beta_{h_j}), j = 1, \dots, m \quad (7)$$

式中:  $W_{h_j}$  和  $\beta_{h_j}$  为随机产生的权重和偏置;  $\xi(\cdot)$  为非线性激活函数。将全部的  $m$  组增强节点拼接为  $H^m = [H_1, \dots, H_m]$ , 记  $A = [Z^n | H^m]$ 。则模型的输出矩阵表示为:

$$\hat{Y} = AW^m \quad (8)$$

式中:  $W^m$  是隐藏层到输出层的连接权重。权重  $W_{e_i}, W_{h_j}$  和偏置  $\beta_{e_i}, \beta_{h_j}$  在训练过程中固定不变, 模型训练过程中只学习  $W^m$ 。  $W^m$  可通过最小二乘估计求解, 其优化问题及解表示为:

$$\mathbf{W}^m = \underset{\mathbf{W}^m}{\operatorname{argmin}}: \|\hat{\mathbf{Y}} - \mathbf{Y}\|_2^2 + \lambda \|\mathbf{W}^m\|_2^2 = (\lambda \mathbf{I} + \mathbf{A}\mathbf{A}^T)^{-1} \mathbf{A}^T \mathbf{Y} \quad (9)$$

式中:  $\|\hat{\mathbf{Y}} - \mathbf{Y}\|_2^2$  用以最小化训练误差;  $\lambda$  为正则系数, 表示对权值平方和的进一步约束;  $\lambda \|\mathbf{W}^m\|_2^2$  用以防止模型发生过拟合。将  $\mathbf{A}$  的伪逆表示为:

$$\mathbf{A}^\dagger = \lim_{\lambda \rightarrow 0} (\lambda \mathbf{I} + \mathbf{A}\mathbf{A}^T)^{-1} \mathbf{A}^T \quad (10)$$

则式 (9) 可写为:

$$\mathbf{W}^m = \mathbf{A}^\dagger \mathbf{Y} \quad (11)$$

### 2.2 基于双线性变化的 2D-BLS

BLS 是面向向量型数据的分类器, 基于 Tucker 分解的特征提取方法将产生矩阵型特征数据集。为了更好地对矩阵型数据进行处理, 对 BLS 模型进行矩阵化二维扩展, 提出了 2D-BLS。

设输入数据为  $N$  个矩阵样本  $[\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N]$ , 其中, 每个样本有  $\mathbf{X}_i \in \mathbf{R}^{p \times q}$ 。在进行特征映射时采用双线性变换式。对于  $n$  组特征映射, 同样用  $\mathbf{Z}_i$  表示具有  $r$  个神经元的第  $i$  组特征节点, 有:

$$\mathbf{Z}_i = [\mathbf{z}_{i1}, \mathbf{z}_{i2}, \dots, \mathbf{z}_{in}], \quad i = 1, 2, \dots, n \quad (12)$$

$$\mathbf{z}_{ij} = \phi(\boldsymbol{\alpha}_{ij} + \boldsymbol{\beta}_{ei}) \quad (13)$$

式中:  $\boldsymbol{\alpha}_{ij} = [\alpha_{ij1}, \alpha_{ij2}, \dots, \alpha_{ijr}]$ ;  $\boldsymbol{\beta}_{ei} \in \mathbf{R}^r$  为随机产生的偏置, 有:

$$\alpha_{ijk} = \mathbf{U}_i[:, k]^T \cdot \mathbf{X}_j \cdot \mathbf{V}_i[:, k] \quad (14)$$

式中:  $\mathbf{U}_i \in \mathbf{R}^{p \times r}$  和  $\mathbf{V}_i \in \mathbf{R}^{q \times r}$  为随机产生的权重矩阵。增强节点仍以式 (7) 计算。通过双线性变换进行特征映射的 2D-BLS 模型结构如图 7 所示。

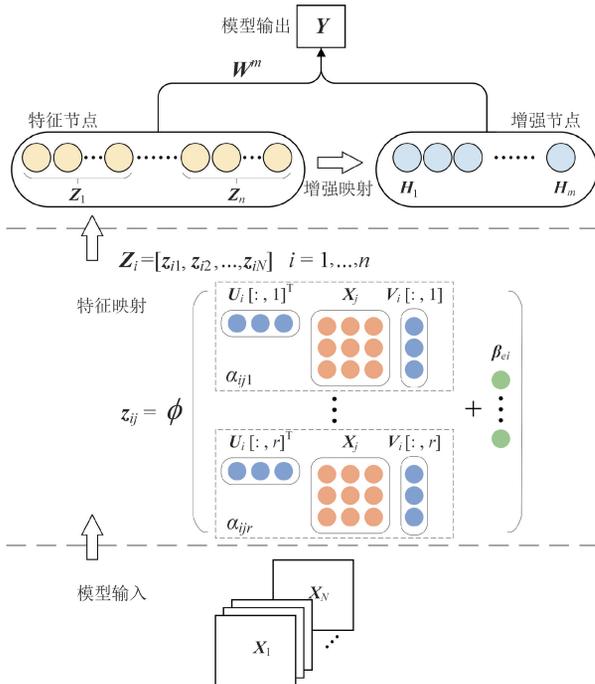


图7 二维宽度学习系统

Fig. 7 2D-broad learning system

2D-BLS 特征映射的输入权重矩阵为  $[\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_n]$  和  $[\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_n]$ , 仅由  $(p+q) \times r \times n$  个参数构成。而对于向量型 BLS, 则需要先将输入样本  $\mathbf{X}$  进行向量化, 特征映射所需参数数量为  $p \times q \times r \times n$ 。2D-BLS 可以直接对矩阵型数据进行分类, 无须对特征矩阵进行向量化, 保留了样本内部的结构信息, 同时减少了模型所需计算的参数数量, 降低了计算开销。

### 2.3 模型训练及故障诊断与定位方法

模型训练及故障诊断流程如图 8 所示。对于故障信号, 首先进行张量构造, 通过 Tucker 分解将故障类型分类与故障位置识别任务进行拆分, 并提取相应的张量特征, 得到故障桥臂特征、故障位置特征和故障类型特征的特征矩阵作为模型输入。划分数据集, 分别完成对应子分类器的模型训练和参数优化, 最后存储模型参数用于实时故障诊断。对实时信号进行故障诊断时, 首先通过故障类型分类器诊断是否发生故障, 当确定出现故障时, 再启动故障桥臂与故障模块分类器。综合 3 个子分类器输出从而实现故障诊断与定位。

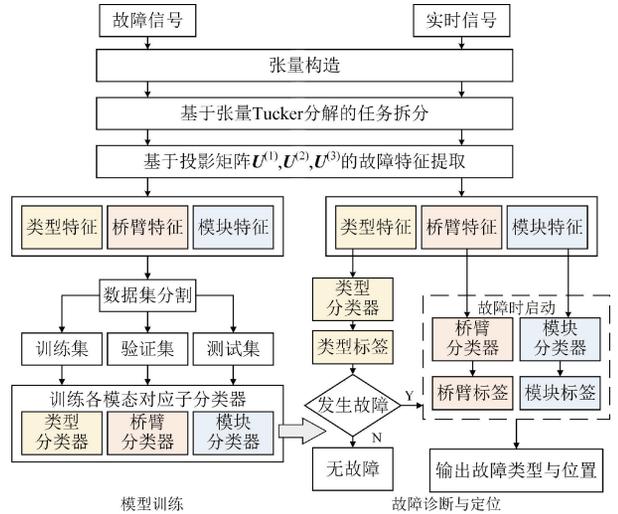


图8 模型训练及故障诊断流程

Fig. 8 Model training and fault diagnosis processes

MMC 故障类别数量等于故障类型数量与故障位置数量的乘积, 将故障诊断与定位任务拆分为故障类型识别子任务、故障桥臂识别子任务和故障模块识别子任务, 可以大幅降低模型类别数量, 提高特征区分度, 从而提高分类精度。在对实时信号进行故障诊断时, 仅当故障类型分类器检测到发生故障时, 才启动故障桥臂分类器和故障模块分类器进行定位, 该策略能够降低无故障状态下监测的计算量。

在评估模型时, 3 个子分类器及综合输出准确率计算如式 (15) 所示。

$$\left. \begin{aligned}
 Acc_{\text{故障类型}} &= \frac{\sum_{i=1}^{N_{\text{全部样本}}} \hat{a}_i == a_i}{N_{\text{全部样本}}} \\
 Acc_{\text{故障桥臂}} &= \frac{\sum_{i=1}^{N_{\text{故障样本}}} \hat{b}_i == b_i}{N_{\text{故障样本}}} \\
 Acc_{\text{故障模块}} &= \frac{\sum_{i=1}^{N_{\text{故障样本}}} \hat{c}_i == c_i}{N_{\text{故障样本}}} \\
 Acc_{\text{综合}} &= \frac{\sum_{i=1}^{N_{\text{全部样本}}} [\hat{a}_i, \hat{b}_i, \hat{c}_i] == [a_i, b_i, c_i]}{N_{\text{全部样本}}}
 \end{aligned} \right\} (15)$$

其中,  $a_i, b_i, c_i$  分别为第  $i$  个样本的故障类型标签、故障桥臂标签和故障模块标签。 $\hat{a}_i, \hat{b}_i, \hat{c}_i$  分别为第  $i$  个样本的故障类型标签、故障桥臂标签和故障模块标签的预测值。

#### 2.4 与现有诊断方法的对比

新方法与传统故障诊断方法的对比如表 2 所示, 具体优势为: 在诊断数据源上仅使用 MMC 系统运行所需的 SM 电容电压, 无需额外硬件; 基于数据驱动无需设置阈值; 通过张量分解算法进行了故障诊断与定位的任务拆分, 降低了故障类别数量从而提升了模型分类性能, 诊断时间短, 能适用于多个 SM 故障。

表 2 与现有诊断方法的对比

Table 2 Comparison with existing diagnostic methods

文献	类别	额外硬件	设置阈值	诊断数据源	时间	多个 SM 故障
[13]	基于硬件电路	需要	无需	光耦合器电压	<10 ms	可行
[14]	基于模型	无需	需要	输出电流、环流和 SM 电容电压	<10 ms	不可行
[15]	基于模型	无需	需要	桥臂、输出电流	<165 ms	不可行
[16]	基于模型	无需	需要	SM 电容电压	<15 ms	不可行
[17]	基于模型	无需	需要	SM 电容电压	<80 ms	可行
[19]	基于机器学习	无需	无需	系统全部电压、电流	<20 ms	不可行
[20]	基于机器学习	无需	无需	桥臂电流、SM 电容电压	<20 ms	不可行
[21]	基于机器学习	无需	无需	环流、负载电流和 SM 电容电压	<100 ms	不可行
[22]	基于机器学习	无需	无需	SM 电容电压	<60 ms	不可行
[23]	基于机器学习	无需	无需	桥臂电压	<50 ms	可行
新方法	基于机器学习	无需	无需	SM 电容电压	<15 ms	可行

表 3 MMC 系统仿真参数

Table 3 Simulation parameters of the MMC system

参数	数值
直流母线电压 /kV	11
交流侧电压 /kV	6.6
单桥臂子模块数	22
子模块电容 /mF	7
桥臂电感 /mH	13.5
交流侧侧电感 /mH	13.58

## 3 实验验证

### 3.1 仿真验证

在 MATLAB/Simulink 中搭建了 3 相 22 模块 MMC 模型, 具体参数如表 3 所示。作者主页提供了仿真数据集、训练模型和测试程序, 用于方法的复现与验证。逆变模式下, 通过在仿真模型的不同子模块上设置不同类型的开路故障, 采集了 1 057 组子模块电容电压数据序列, 数据采样率为 2 kHz。将滑动窗长设定为 40 个采样帧, 即 20 ms, 滑动步长设定为 5 个采样帧, 即为 2.5 ms, 数据经滑动窗分割后构造为三阶张量  $T \in \mathbf{R}^{6 \times 40 \times 22}$ , 总样本量为 12 684。

根据式 (5), 张量核大小为  $\mathbf{G} \in \mathbf{R}^{4 \times 4 \times 2}$ 。故障桥臂特征、故障类型特征和故障模块特征数据样本维度分别

为  $\mathbf{U}^{(1)} \in \mathbf{R}^{6 \times 4}$ 、 $\mathbf{U}^{(2)} \in \mathbf{R}^{40 \times 4}$  和  $\mathbf{U}^{(3)} \in \mathbf{R}^{22 \times 2}$ 。2D-BLS 处理以上 3 类矩阵型特征数据所需的参数数量与传统向量型算法所需的参数数量对比如表 4 所示。相对于向量型算法, 2D-BLS 有效减少了模型参数数量。

表 4 算法参数数量对比

Table 4 Comparison of algorithm parameter counts

特征数据维度	$U^{(1)} \in R^{6 \times 4}$	$U^{(2)} \in R^{40 \times 4}$	$U^{(3)} \in R^{22 \times 2}$
向量型算法	24	160	44
2D-BLS	10	44	24

仿真数据样本仅包含单模块故障的情况,根据故障子模块状态与位置设置故障标签,故障类型与标签编码对照如表 5 所示。MMC 故障类别数量等于故障类型数量与故障位置数量的乘积,且故障位置由故障桥臂和故障模块组合得到,该 MMC 仿真模型共具有故障类别 397 个,在进行任务拆分后,3 个子分类器类别数量分别为 4、6 和 22,有效减少了模型分类数。

表 5 仿真故障类型与标签编码对照表

Table 5 Correspondence between simulation fault types and label codes

任务拆分	故障类型/位置	标签编码
故障类型	无故障	1
	$T_1$	2
	$T_2$	3
	$T_1$ 和 $T_2$	4
故障桥臂	三相上下桥臂,6 种	1~6
故障模块	$SM_1 \sim SM_{22}$ ,22 种	1~22

不同投影矩阵在每个子分类器中的性能表现如表 6 所示。根据实验结果,Tucker 分解得到的 1 模投影矩阵  $U^{(1)}$ 、2 模投影矩阵  $U^{(2)}$  和 3 模投影矩阵  $U^{(3)}$  分别在故障诊断与定位的 3 个对应子任务,即故障桥臂识别任务、故障类型识别任务和故障模块识别任务中,均取得了最优结果,从而证实了特征提取方法的有效性。

表 6 各投影矩阵对各子任务的识别准确率

Table 6 Recognition accuracy of each projection matrix for each subtask (%)

投影矩阵	Acc <sub>故障桥臂</sub>	Acc <sub>故障类型</sub>	Acc <sub>故障模块</sub>
$U^{(1)}$	<b>99.83</b>	89.48	10.33
$U^{(2)}$	91.84	<b>99.72</b>	8.76
$U^{(3)}$	48.87	75.67	<b>99.68</b>

采用混淆矩阵分别分析了 3 个子分类器的测试结果,如图 9 所示。各类别的精确率和召回率均达到了较高水平,且混淆矩阵中的主对角线值显著高于非对角线值。模型的综合输出准确率达到 99.43%。模型的混淆集中在故障发生后的第 1~2 次检测中,该类被错误分类

数据的特点是,故障数据在滑动窗格中占比小,特征隐蔽。设定模型连续 4 次输出稳定后确诊,通过设置时延避免该类型错误。

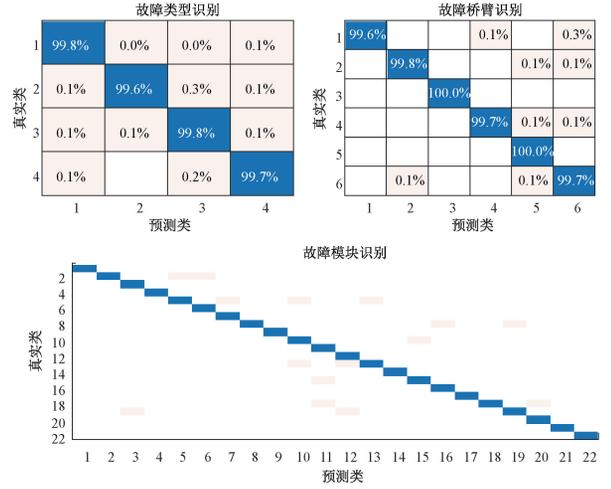


图 9 各子分类器测试结果的混淆矩阵

Fig.9 Confusion matrices of test results for each sub-classifier

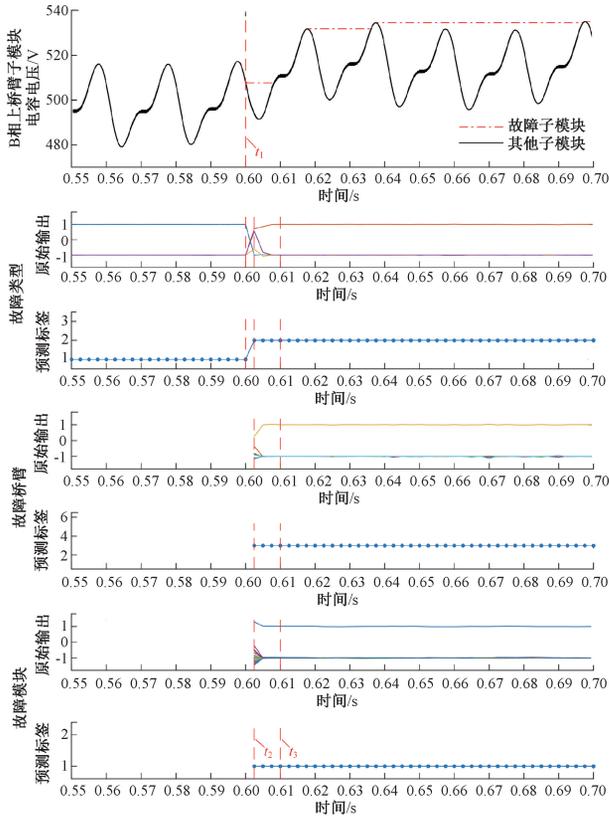
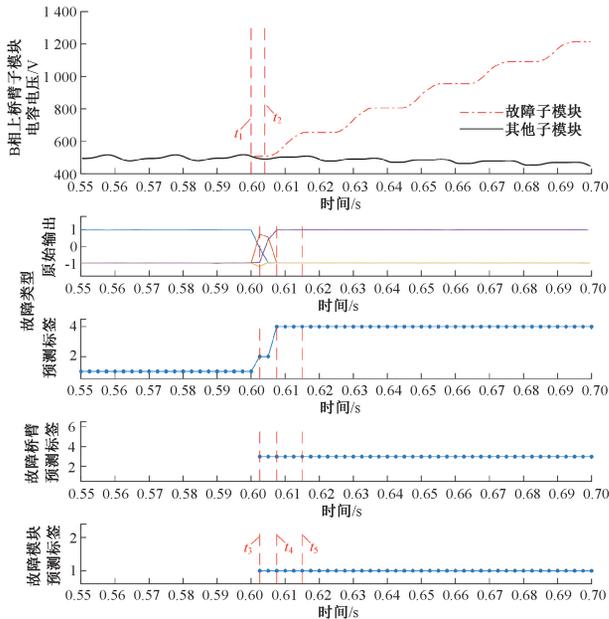
1) 单个子模块  $T_1$  开路故障

设定 B 相上桥臂  $SM_1$  发生  $T_1$  开路故障,诊断过程中故障桥臂各子模块电容电压波形及分类器输出如图 10 所示。在  $t_1 = 0.6$  s 时,  $SM_1$  发生  $T_1$  开路故障。在  $t_2 = 0.6025$  s 时,即数据截取窗格滑动一次后,故障类型分类器输出标签跳变为 2,表示出现  $T_1$  开路故障,此时故障桥臂和故障模块分类器启动,输出的故障桥臂标签为 3,故障模块标签为 1,表示故障位置是 B 相上桥臂  $SM_1$  子模块。在  $t_2$  时刻后,模型的输出标签保持不变。到  $t_3 = 0.61$  s 时,模型连续 4 次输出稳定,达到确诊条件,诊断时间为 10 ms。

由分类器输出值可见,在故障发生时,分类器输出存在一定波动。数据截取滑动窗格的窗长为 20 ms,步长为 2.5 ms,故障发生后首次截取数据时,故障数据在窗格中占比小,特征隐蔽,随后窗口滑动,故障特征显露,分类器输出恢复稳定。设计的确诊规则可以避免误诊的情况。

2) 单个子模块  $T_1$  和  $T_2$  开路故障

设定 B 相上桥臂  $SM_1$  在  $t_1 = 0.6$  s 时发生  $T_1$  开路故障,随后在  $t_2 = 0.604$  s 发生  $T_2$  开路故障,如图 11 所示。在  $t_3 = 0.6025$  s 时故障类型分类器输出标签跳变为 2,表示出现  $T_1$  开路故障,此时故障桥臂和故障模块分类器启动,输出表示故障位置是 B 相上桥臂  $SM_1$  子模块。在  $t_4 = 0.6075$  s 时,故障类型分类器输出标签跳变为 4,表示发生单个子模块  $T_1$  和  $T_2$  开路故障。在  $t_5 = 0.615$  s 时完成故障诊断与定位,从  $T_2$  开路故障发生到确定诊断结果用时 11 ms。

图10 单个子模块  $T_1$  开路故障诊断Fig. 10 Diagnosis of  $T_1$  open-circuit fault in a single SM图11 单个子模块  $T_1$  和  $T_2$  开路故障诊断Fig. 11 Diagnosis of  $T_1$  and  $T_2$  open-circuit faults in a single SM

### 3.2 实验验证

利用硬件在环 (hardware-in-loop, HIL) 平台搭建了三相6模块的MMC模型,如图12所示,模型具体参数如表7所示<sup>[29]</sup>。共采集了3265组子模块电容电压数据序列,数据采样率为2kHz。滑动窗长设定为40个采样帧,即20ms,滑动步长设定为5个采样帧,即为2.5ms,数分割后构造为三阶张量  $T \in \mathbf{R}^{6 \times 40 \times 6}$ ,总样本量为39180,根据式(5),张量核大小为  $G \in \mathbf{R}^{4 \times 4 \times 2}$ 。故障桥臂特征、故障类型特征和故障模块特征数据样本维度分别为  $U^{(1)} \in \mathbf{R}^{6 \times 4}$ 、 $U^{(2)} \in \mathbf{R}^{40 \times 4}$  和  $U^{(3)} \in \mathbf{R}^{6 \times 2}$ 。

NI PXIE硬件在环仿真器(HIL)

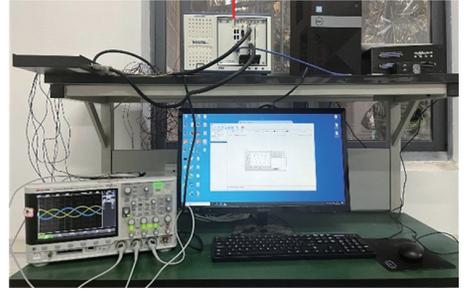


图12 硬件在环实验平台

Fig. 12 Hardware-in-loop experimental platform

表7 MMC系统实验参数

Table 7 Experimental parameters of the MMC system

参数	数值
直流母线电压/V	480
交流侧电压/V	135
单桥臂子模块数	6
子模块电容/mF	2
桥臂电感/mH	3
交流侧电感/mH	3

该组数据样本包含多故障的情况。根据故障子模块状态与位置设置故障标签,全部故障类别数量为  $1 + 3 \times C_{36}^1 + 4 \times C_{36}^2 = 2629$ 。在进行任务拆分后,其故障类型与标签对照如表8所示。3个子分类器的类别数量分别为8、21和42。更少的类别数量降低了模型复杂度,每个类别的训练样本数更多,有利于提高模型泛化能力,降低训练难度,提升分类性能。

深度神经网络 (deep neural network, DNN) 及其衍生算法在故障诊断中发挥了良好效果<sup>[30-31]</sup>,以多层感知机 (multilayer perceptron, MLP) 和 CNN 为对照模型,与 BLS 算法及 2D-BLS 进行对比分析。各模型在故障诊断任务中的测试准确率及模型训练时间如表9所示。

表 8 实验故障类型与标签编码对照表  
Table 8 Correspondence between experimental fault types and label codes

任务拆分	故障类型/位置	标签编码	
故障类型 (分类器 1)	无故障	1	
	单子模块 开关管故障	$T_1$	2
		$T_2$	3
	双子模块 开关管故障	$T_1$ 和 $T_2$	4
		$T_1$ 和 $T_1$	5
		$T_2$ 和 $T_2$	6
		$T_1$ 和 $T_2$	7
		$T_2$ 和 $T_1$	8
故障桥臂 (分类器 2)	单桥臂故障 三相上下桥臂 6 种	1~6	
	双桥臂故障 三相上下桥臂组合 $C_6^2 = 15$ 种	7~21	
故障模块 (分类器 3)	单子模块 开关管故障 6 种	1~6	
	双子模块 开关管故障 6 模块排列,可同编号 36 种	7~42	

表 9 测试性能对比

Table 9 Comparison of test performance

算法	准确率/%	训练时间/s
MLP	95.07	16 638.28
CNN	94.22	14 612.05
BLS	94.38	44.29
2D-BLS	98.69	27.72

由表 9 可知,BLS 相比深度学习算法极大的缩短了训练时间,在此基础上 2D-BLS 无须对矩阵型数据特征进行向量化,保留了数据结构信息,而且减少了模型参数数量,准确率更高,训练时间更短。

1) 同桥臂多个子模块开路故障

设定 B 相下桥臂  $SM_2$  在  $t_1 = 0.6$  s 时发  $T_2$  开路故障,随后同桥臂  $SM_1$  在  $t_2 = 0.606$  s 时发  $T_1$  开路故障,如图 13 所示。

在  $t_3 = 0.6025$  s 时故障类型分类器输出标签跳变为 3,表示出现  $T_2$  开路故障,此时故障桥臂和故障模块分类器启动,输出分别为 4 和 2,表示故障位置出现在 B 相上桥臂  $SM_2$ 。在  $t_4 = 0.61$  s 时,故障类型分类器输出跳变为 7,表示发生多子模块  $T_1$  和  $T_2$  开路故障,故障桥臂

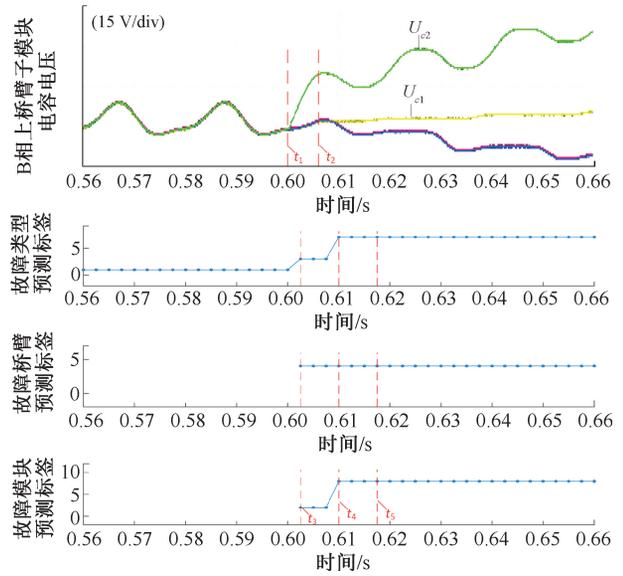


图 13 同桥臂双子模块开路故障诊断  
Fig. 13 Open-circuit fault diagnosis of double SM of same bridge arm

分类器输出不变,故障模块分类器输出跳变为 8,表示发生故障模块为  $SM_1$  和  $SM_2$ 。到  $t_5 = 0.6175$  s 时,3 个分类器连续 4 次输出相同的故障标签,完成故障诊断与定位,最终诊断结果为 B 相下桥臂  $SM_1$  发生  $T_1$  开路故障, $SM_2$  发生  $T_2$  开路故障,从第 2 个故障发生到完成最终诊断用时 11.5 ms。

在数据标注时,对于  $T_1$  和  $T_2$  双开路故障的情况,按照故障发生位置顺序赋予样本不同的标签,因此故障类型子分类器输出可以与故障桥臂和故障模块子分类器输出进行对应,从而区分不同故障位置的开路故障类型。

2) 不同桥臂多个子模块开路故障

设定 A 相上桥臂  $SM_1$  在  $t_1 = 0.6$  s 时发生  $T_2$  开路故障,随后 C 相上桥臂  $SM_2$  在  $t_2 = 0.6045$  s 时发生  $T_1$  开路故障,如图 14 所示。

在  $t_3 = 0.6025$  s 时故障类型分类器输出标签跳变为 3,表示出现  $T_2$  开路故障,此时故障桥臂和故障模块分类器启动,输出分别为 1 和 1,表示故障位置出现在 A 相上桥臂  $SM_1$ 。在  $t_4 = 0.6075$  s 时,故障类型分类器输出跳变为 8,表示发生多子模块  $T_2$  和  $T_1$  开路故障,故障桥臂分类器输出跳变为 10,表示发生故障桥臂为 A 相上桥臂和 C 相上桥臂,故障模块分类器输出跳变为 8,表示发生故障模块为  $SM_1$  和  $SM_2$ 。到  $t_5 = 0.615$  s 时,3 个分类器连续 4 次输出相同的故障标签,完成故障诊断与定位,从第 2 个故障发生到完成最终诊断用时 11 ms。

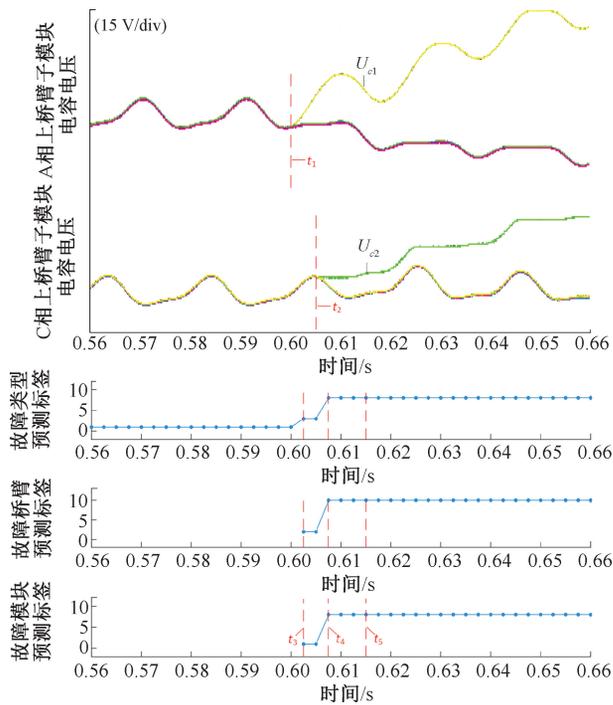


图 14 不同桥臂双子模块开路故障诊断

Fig. 14 Open-circuit fault diagnosis of double SM of different bridge arms

## 4 结 论

该研究提出了基于张量分解与宽度学习系统的 MMC 开关管开路故障诊断与定位方法。与传统方法相比,通过理论分析和实验验证,得到的结论为:

1) 针对 MMC 多通道数据处理效率不足的问题,提出了基于张量的特征提取方法,提高了故障诊断效率,诊断时间 < 15 ms。

2) 针对 MMC 故障诊断与定位模型复杂度高的问题,提出基于 Tucker 分解的任务拆分策略,并提取相应故障特征,大幅度降低了模型复杂度。

3) 针对张量特征维度高的问题,提出了 2D-BLS 特征识别模型,在降低模型参数数量的同时,保留了张量特征内部结构信息和相关性。

提出的故障诊断方法仅利用 MMC 运行所需的子模块电容电压,无需添加额外的硬件电路,且基于数据驱动无需设置阈值,最终准确率高于 98.5%。

## 参考文献

[ 1 ] CHOI U M, BLAABJERG F, LEE K B. Study and handling methods of power IGBT module failures in power electronic converter systems [ J ]. IEEE Transactions on Power Electronics, 2015, 30(5): 2517-2533.

[ 2 ] 熊亮雳, 刘曼佳, 何顺帆, 等. 用户侧储能两电平换流器开关管开路故障诊断 [ J ]. 高电压技术, 2024, 50(6): 2442-2451.  
XIONG L L, LIU M J, HE SH F, et al. Open circuit fault detection of two-level converter in user-side energy storage [ J ]. High Voltage Engineering, 2024, 50(6): 2442-2451.

[ 3 ] 朱耀东, 徐帅, 张建忠. 多电平变流器系统可靠性建模与分析 [ J ]. 仪器仪表学报, 2020, 41(3): 70-78.  
ZHU Y D, XU SH, ZHANG J ZH. Reliability modeling and analysis of multilevel converter systems [ J ]. Chinese Journal of Scientific Instrument, 2020, 41(3): 70-78.

[ 4 ] 唐圣学, 王维威, 马强, 等. 三电平逆变器 IGBT 器件接线故障在线诊断方法研究 [ J ]. 仪器仪表学报, 2020, 41(11): 19-30.  
TANG SH X, WANG W W, MA Q, et al. Research on on-line diagnosis method of IGBT device wiring faults in three-level inverter [ J ]. Chinese Journal of Scientific Instrument, 2020, 41(11): 19-30.

[ 5 ] JI X T, LIU D, XIONG P, et al. Multiple open-switch faults detection for grid connected inverter [ J ]. Sustainable Energy Technologies and Assessments, 2022, 54: 102765.

[ 6 ] HE SH F, TIAN W, ZHU R B, et al. Electrical signature analysis for open-circuit faults detection of inverter with various disturbances in distribution grid [ J ]. IEEE Transactions on Industrial Informatics, 2023, 19(7): 8351-8361.

[ 7 ] SHENG J, XIANG X, LI B L, et al. High-efficient operation for modular multilevel resonant DC-DC converters in medium voltage applications with wide input range and wide load condition [ J ]. IEEE Transactions on Power Electronics, 2023, 38(10): 12180-12194.

[ 8 ] ZHU Y CH, LI Y L, LI B T, et al. Internal energy distribution control based fault ride-through and postfault recovery strategy for offshore wind farms connected to DR-MMC HVDC under onshore AC grid faults [ J ]. IEEE Transactions on Sustainable Energy, 2025, 16(2): 1191-1205.

[ 9 ] 文劲宇, 张浩博, 向往, 等. 面向新型电力系统的柔性直流换流器统一控制架构 [ J ]. 中国电机工程学报, 2024, 44(18): 7068-7084.  
WEN J Y, ZHANG H B, XIANG W, et al. Unified high voltage direct current converter control dedicated for new power systems [ J ]. Proceedings of the CSEE, 2024, 44(18): 7068-7084.

[ 10 ] 徐鹏, 许超林, 肖科林, 等. 基于模糊滑模控制的 MMC 环流抑制研究 [ J ]. 电子测量技术, 2024,

- 47(22): 39-48.
- XU P, XU CH L, XIAO K L, et al. Research on circulating current suppression of MMC based on fuzzy sliding mode control[J]. *Electronic Measurement Technology*, 2024, 47(22): 39-48.
- [11] 程启明, 张梁, 程尹曼, 等. 不平衡电网下 MMC-UPFC 的反演-滑模控制策略[J]. *电子测量与仪器学报*, 2024, 38(6): 67-74.
- CHENG Q M, ZHANG L, CHENG Y M, et al. Backstepping-based sliding-mode control strategy of MMC-UPFC under unbalanced power grid[J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(6): 67-74.
- [12] PENG F Z, LIU CH CH, LI Y, et al. Envisioning the future renewable and resilient energy grids-A power grid revolution enabled by renewables, energy storage, and energy electronics [J]. *IEEE Journal of Emerging and Selected Topics in Industrial Electronics*, 2024, 5(1): 8-26.
- [13] LIU CH K, DENG F J, CAI X, et al. Submodule open-circuit fault detection for modular multilevel converters under light load condition with rearranged bleeding resistor circuit[J]. *IEEE Transactions on Power Electronics*, 2022, 37(4): 4600-4613.
- [14] JIN Y, XIAO Q, JIA H J, et al. A novel detection and localization approach of open-circuit switch fault for the grid-connected modular multilevel converter [J]. *IEEE Transactions on Industrial Electronics*, 2023, 70(1): 112-124.
- [15] LI B B, SHI SH L, WANG B, et al. Fault diagnosis and tolerant control of single IGBT open-circuit failure in modular multilevel converters[J]. *IEEE Transactions on Power Electronics*, 2016, 31(4): 3165-3176.
- [16] ZHOU D H, QIU H, YANG SH F, et al. Submodule voltage similarity-based open-circuit fault diagnosis for modular multilevel converters[J]. *IEEE Transactions on Power Electronics*, 2019, 34(8): 8008-8016.
- [17] ZHOU W H, SHENG J, LUO H Z, et al. Detection and localization of submodule open-circuit failures for modular multilevel converters with single ring theorem[J]. *IEEE Transactions on Power Electronics*, 2019, 34(4): 3729-3739.
- [18] LI C, LIU ZH X, ZHANG Y, et al. Diagnosis and location of the open-circuit fault in modular multilevel converters: An improved machine learning method[J]. *Neurocomputing*, 2019, 331: 58-66.
- [19] DENG F J, JIN M, LIU CH K, 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.
- [20] HU X, JIA H F, ZHANG Y D, et al. An open-circuit faults diagnosis method for MMC based on extreme gradient boosting [J]. *IEEE Transactions on Industrial Electronics*, 2023, 70(6): 6239-6249.
- [21] KIRANYAZ S, GASTLI A, BEN-BRAHIM L, et al. Real-time fault detection and identification for MMC using 1-D convolutional neural networks[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(11): 8760-8771.
- [22] 杨贺雅, 邢纹硕, 陈聪, 等. 基于随机森林二分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 H Y, XING W SH, CHEN C, 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.
- [23] 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 Q Y, YU Y CH, ZHAN Y W, et al. IGBT open-circuit fault diagnosis of modular multilevel converter submodule based on short-time Fourier transform and deep networks [J]. *Transactions of China Electrotechnical Society*, 2024, 39(12): 3840-3854.
- [24] 杨礼吉, 王家祺, 景丽萍, 等. 基于张量计算的卷积神经网络语义表示学习 [J]. *计算机学报*, 2023, 46(3): 568-578.
- YANG L J, WANG J Q, JING L P, et al. Semantic representation learning of convolutional neural network based on tensor computation [J]. *Chinese Journal of Computers*, 2023, 46(3): 568-578.
- [25] LU H, PLATANIOTIS K N, VENETSANOPOULOS A N. A survey of multilinear subspace learning for tensor data [J]. *Pattern Recognition*, 2011, 44(7): 1540-1551.
- [26] 建中华, 南静, 刘鑫, 等. 基于时空张量融合的人体骨架行为自适应识别方法[J]. *仪器仪表学报*, 2023, 44(6): 74-85.
- JIAN ZH H, NAN J, LIU X, et al. Adaptive recognition method of human skeleton action with spatial-temporal tensor fusion[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(6): 74-85.

- [27] HE SH F, GENG X, TIAN W, et al. Online compression of multichannel power waveform data in distribution grid with novel tensor method [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 6505011.
- [28] CHEN C L P, LIU ZH L. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 10-24.
- [29] WANG ZH, PENG L. Grouping capacitor voltage estimation and fault diagnosis with capacitance self-updating in modular multilevel converters [J]. IEEE Transactions on Power Electronics, 2020, 36(2): 1532-1543.
- [30] SHANTHAKUMAR S, SHAKILA S, SUNETH P, et al. Environmental sound classification using deep learning [J]. Instrumentation, 2020, 7(3): 15-22.
- [31] XIA M, DE SILVA C W. Gear transmission fault classification using deep neural networks and classifier level sensor fusion [J]. Instrumentation, 2019, 6(2): 101-109.

### 作者简介



**耿想**, 2018 年于武汉大学获得学士学位, 现为中南民族大学计算机科学学院硕士研究生, 研究方向为电力设备故障诊断。  
E-mail: 2022110296@mail.scuec.edu.cn

**Geng Xiang** received his B. Sc. degree from Wuhan University in 2018. Now he is a

master's candidate at the School of Computer Science, South-Central Minzu University. His research interest includes power equipment failure diagnosis.



**何顺帆** (通信作者), 2007 年于武汉轻工大学获得学士学位, 2010 年于武汉理工大学获得硕士学位, 2013 年于华中科技大学获得博士学位, 现为中南民族大学副教授, 主要研究方向为电力设备故障诊断。

E-mail: heshunfan@scuec.edu.cn

**He Shunfan** (Corresponding author) received his B. Sc. degree from Wuhan Polytechnic University in 2007, received his M. Sc. degree from Wuhan University of Technology in 2010, received his Ph. D. degree from Huazhong University of Science and Technology in 2013. Now he is an associate professor at South-Central Minzu University. His main research interest includes power equipment failure diagnosis.



**朱容波**, 分别在 2000 年和 2003 年于武汉理工大学获得学士、硕士学位, 2006 年于上海交通大学获得博士学位, 现为华中农业大学信息学院教授, 主要研究方向为人工智能物联网、边缘计算、大数据智能等。

E-mail: rbzhu@mail.hzau.edu.cn

**Zhu Rongbo** received his B. Sc. degree and M. Sc. degree from Wuhan University of Technology in 2000 and 2003, received his Ph. D. degree from Shanghai Jiao Tong University in 2006. Now he is a professor at the College of Informatics, Huazhong Agricultural University. His main research interests include artificial intelligence of things, edge computing, and big data intelligence.