

DOI: 10.19783/j.cnki.pspc.240505

# 基于电容电压预测误差优化的 MMC 多管开路故障诊断策略

杨兴武<sup>1</sup>, 卢愿<sup>1</sup>, 徐浩文<sup>2</sup>, 王江<sup>3</sup>, 孟致丞<sup>1</sup>, 王雅妮<sup>1</sup>

(1. 上海电力大学电气工程学院, 上海 200090; 2. 国网黑龙江省电力有限公司齐齐哈尔供电公司, 黑龙江 齐齐哈尔 161000; 3. 国网陕西省电力有限公司宝鸡供电公司, 陕西 宝鸡 721000)

**摘要:** 由于模块化多电平变换器(modular multilevel converters, MMC)实际模型中采样误差、电路参数不准确等因素, 现有故障诊断策略存在鲁棒性差、阈值难选取等难题。为解决上述问题, 提出了一种基于电容电压预测误差优化的 MMC 多管开路故障诊断策略。该策略将逐段误差优化后的电容电压、输出电流和环流作为故障诊断显性特征, 利用结构简单、适应力强的一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)作为新的故障定位方案, 实现 MMC 高精度开路故障诊断。所提方法无需增加额外传感器, 在故障子模块电容电压变化的初始阶段即可实现子模块多管故障的快速准确定位。相较于现有基于电容电压的诊断策略, 该方法极大地降低了系统参数误差, 保证了故障诊断网络的鲁棒性。最后, 仿真和实验验证了所提故障诊断策略的有效性。

**关键词:** 模块化多电平换流器; 误差优化; 1D-CNN; 开路故障

## Multiple IGBT open-circuit fault diagnosis strategy for an MMC based on capacitor voltage prediction error optimization

YANG Xingwu<sup>1</sup>, LU Yuan<sup>1</sup>, XU Haowen<sup>2</sup>, WANG Jiang<sup>3</sup>, MENG Zhicheng<sup>1</sup>, WANG Yani<sup>1</sup>

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China;  
2. Qiqihar Power Supply Company, State Grid Heilongjiang Electric Power Co., Ltd., Qiqihar 161000, China;  
3. Baoji Power Supply Company, State Grid Shaanxi Electric Power Co., Ltd., Baoji 721000, China)

**Abstract:** Because of sampling errors and circuit parameter inaccuracies in an actual modular multilevel converter (MMC) model, existing fault diagnosis strategies suffer from poor robustness and difficulty in threshold selection. To solve these problems, this paper proposes a multi-IGBT open circuit fault diagnosis strategy based on capacitor voltage prediction sampling optimization. Here the capacitive voltage, output current and circulating current after segmental error optimization are used as dominant characteristics of fault diagnosis, and a one-dimensional convolutional neural network (1D-CNN) with simple structure and strong adaptability is used as a new fault location scheme to realize high-precision MMC open-circuit fault diagnosis. The proposed method can quickly and accurately locate multi-IGBT faults of the submodule at the initial stage of the capacitor voltage variation without adding additional sensors. Compared with existing diagnosis strategies based on capacitance voltage, this method significantly reduces system parameter errors and enhances the robustness of the fault diagnosis network. Finally, simulations and experiments verify the effectiveness of the proposed fault diagnosis strategy.

This work is supported by the Shanghai Science and Technology Committee Foundation (No. 23010501200).

**Key words:** modular multilevel converter (MMC); error optimization; 1D-CNN; open-circuit fault

## 0 引言

模块化多电平换流器(modular multilevel converter,

MMC)具有波形质量好、可扩展性强、谐波性能好等优点, 广泛应用于中高压大功率场合<sup>[1-6]</sup>。随着电压及功率等级的攀升, MMC 中子模块数量不断增加。相关研究表明, 21%的系统故障由功率管器件绝缘栅双极型晶体管(insulated gate bipolar transistors, IGBT)引起<sup>[6]</sup>。功率器件故障可分为短路故障和开路

基金项目: 上海市科技计划项目资助(23010501200); 国家自然科学基金项目资助(52207025)

故障。短路故障时电流激增明显，采用栅极驱动器即可快速实施系统保护。而开路故障的表现形式更为复杂，且其破坏性更为隐蔽，若不及时实施有效的故障诊断方法，可能会对设备造成二次损坏，甚至导致系统故障停机<sup>[7]</sup>。因此，研究快速准确的开路故障诊断策略对 MMC 可靠运行至关重要。

目前针对 MMC 子模块开路故障诊断策略已有大量研究基础，根据处理方式可分为硬件法<sup>[8-11]</sup>、模型法<sup>[12-17]</sup>和人工智能法<sup>[18-23]</sup>。在硬件法中，文献[8-11]通过改变传感器数量或位置、设计独立硬件检测电路来诊断子模块开路故障。该类方法具有诊断速度快、计算量小的优点。但在中高压领域，额外的器件增加了系统成本和硬件复杂度。为避免增加额外硬件装置，国内外专家提出了基于 MMC 电路模型的方法，文献[11-17]主要依靠 MMC 数学模型的状态信号来检测和定位故障子模块。该方法无需额外的硬件电路，成本较低，但易受参数的采样偏差和系统环境噪音等因素的影响，需人为设置阈值来滤除噪声干扰。

基于人工智能的故障诊断方法具有更高的精度和更好的抗干扰能力。但存在故障特征不明显、数据成本大的问题，限制了故障的快速准确定位。文献[20]提出一种基于随机森林的 MMC 开路故障诊断策略。该方法通过采样原始电压和电流数据来实现高精度的故障检测和识别。但故障诊断需要大量各类电压或电流数据段，故障诊断时间较长。文献[21]提出一种基于极限梯度增强的开路故障诊断策略。该方法将实时电容电压和电流数据组成的数据段输入训练好的多分类模型进行故障诊断，对外部噪声和缺失数据具有良好的鲁棒性。但模型训练过程依赖于对缺失数据集的处理和繁琐的数学计算，模型训练成本较高。类似的问题在文献[22-23]中均有体现。

综上所述，针对模块化多电平变换器(modular multilevel converters, MMC)实际模型中存在的采样误差、电路参数不准确和强干扰等难题，通过降低系统参数误差来拟合更为精确的故障诊断特征，采用简单的算法实现故障发生初期的开路故障诊断，成为未来研究发展的一个突破点。

本文提出一种基于电容电压预测误差优化的 MMC 多管开路故障诊断策略。该方法利用逐段误差优化后的电容电压、输出电流和环流作为故障诊断显性特征。采用结构简单、适应力强的一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)作为新的故障定位方案，从而实现高精度、实时的子模块多管故障诊断。优化后的故障特征显性化程度极高，可有效降低 1D-CNN 对

数据的需求。在解决多阈值模型难选取的同时，也减少了神经网络的训练成本。此外，本文所提方法无需额外增加传感器，在故障子模块电容电压变化的初始阶段即可快速实现子模块多管故障的准确定位和故障类型判断。相较于现有基于电容电压的诊断策略，该方法极大地降低了系统参数误差和模型预测控制算法误差，保证了故障诊断网络的鲁棒性。最后，通过仿真和实验平台验证了所提故障诊断策略的有效性。

## 1 MMC 拓扑及电容电压误差分析

### 1.1 MMC 拓扑结构

图 1 为 MMC 单相拓扑结构图，MMC 每相单元由上下两个桥臂组成，其中每个桥臂由  $N$  个相同的半桥子模块和一个桥臂电感  $L$  串联而成。每个半桥子模块可视为一个独立端口网络，由  $S_1$  和  $S_2$  两个互补 IGBT、 $D_1$  和  $D_2$  两个续流二极管及直流储能电容  $C$  构成。

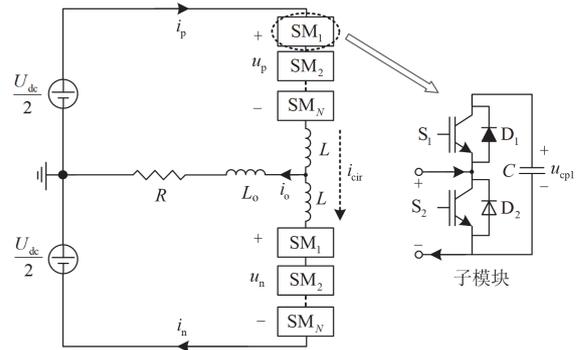


图 1 单相 MMC 电路拓扑结构

Fig. 1 Single-phase MMC circuit topology

MMC 子模块正常工作条件下有两种状态：投入状态和旁路状态，子模块开关函数定义如式(1)所示。

$$S_{xi} = \begin{cases} 1, & S_1 \text{ 导通且 } S_2 \text{ 关闭} \\ 0, & S_1 \text{ 关闭且 } S_2 \text{ 导通} \end{cases} \quad (1)$$

上下桥臂的输出电压可表示为

$$u_x = \sum_{i=1}^N S_{xi} u_{cxi} \quad (2)$$

式中： $S_{xi}$  表示开关函数； $u_{cxi}$  为开关函数和子模块电容电压(下标“x”代表 p 或 n，其中 p 和 n 分别为上臂和下臂；下标“i”为上臂或下臂的第 i 个 SM)。当  $S_{xi} = 1$  时，子模块处于投入状态。当  $S_{xi} = 0$  时，子模块处于旁路状态。

根据图 1，基于基尔霍夫定律可得

$$Ri_p + L \frac{di_p}{dt} = \frac{U_{dc}}{2} - L_o \frac{di_o}{dt} - Ri_o - u_p \quad (3)$$

$$Ri_n + L \frac{di_n}{dt} = \frac{U_{dc}}{2} + L_o \frac{di_o}{dt} + Ri_o - u_n \quad (4)$$

式中:  $i_p$  和  $i_n$  分别为上、下桥臂电流;  $u_p$  和  $u_n$  分别为上、下桥臂电压;  $U_{dc}$  为直流侧电压;  $R$  和  $L_o$  分别为网侧电阻和电感;  $i_o$  为交流侧输出电流。

上桥臂电流  $i_p$  和下桥臂电流  $i_n$  可表示为

$$i_{p(n)} = i_{cir} \pm \frac{i_o}{2} \quad (5)$$

式中,  $i_{cir}$  为环流。

## 1.2 子模块电容电压误差分析

以单相 MMC 为例, 分析子模块电容电压模型预测的误差。基于 MMC 桥臂电流实际值, 电容电压方程可表示为

$$C \frac{du_{cxi}}{dt} = S_{xi} i_x \quad (6)$$

对式(6)进行离散化, 可得  $t + T_s$  时刻子模块电容电压预测值为

$$u_{cxi\_p}(k+1) = u_{cxi\_p}(k) + \frac{1}{C} T_s S_{xi} i_x(k) \quad (7)$$

式中:  $T_s$  为系统采样频率;  $u_{cxi\_p}(k+1)$  和  $u_{cxi\_p}(k)$  分别为  $k+1$ 、 $k$  时刻子模块电容电压预测值。

考虑系统模型参数不准确和采样误差的影响, 式(7)可进一步优化为

$$u_{cxi\_p}(k+1) = u_{cxi\_p}(k) + \frac{1}{C} T_s S_{xi} i_x(k) + \lambda_1 (u_{cxi\_m}(k) - u_{cxi\_p}(k)) \quad (8)$$

式中:  $\lambda_1$  为滚动优化系数;  $u_{cxi\_m}(k)$  为  $k$  时刻子模块电容电压实际值;  $\lambda_1 (u_{cxi\_m}(k) - u_{cxi\_p}(k))$  为误差校正项。电容电压模型预测时产生估计误差的主要因素有以下几种<sup>[24-26]</sup>。

- 1) 模型受到强干扰时电容电压的测量误差。
- 2) 被测电容电压值存在的时间延迟。
- 3) 模型系统中存在的采样误差。

4) 模型参数不准确。

基于上述分析, 实际系统模型中存在采样误差、电路参数不准确和强干扰等因素, 会导致子模块电容电压预测值与实际值出现偏差, 从而影响到故障诊断的结果和时间。

## 2 基于电容电压逐段拟合的误差优化

针对实际系统模型中存在采样误差、模型参数不准确和强干扰难题, 本文提出一种基于电容电压逐段拟合的误差优化方法。

### 2.1 子模块故障特性分析

当子模块发生开路故障时, 开关开路故障可分为两类:  $S_1$  故障和  $S_2$  故障。

当子模块发生  $S_1$  故障时, 电容电流路径如图 2 所示。当  $S_{xi} = 1$  且  $i_{arm} < 0$  时, 桥臂电流  $i_{arm}$  被迫流经二极管  $D_2$  将电容  $C$  旁路, 输出电压为 0。故障子模块无放电过程, 子模块电容电压大于正常运行时的电容电压。

当子模块发生  $S_2$  故障时, 电容电流路径如图 3 所示。当  $S_{xi} = 0$  且  $i_{arm} > 0$  时, 处于旁路状态的子模块通过二极管  $D_1$  被错误投入电路中进行充电, 输出电压为电容电压。故障子模块处于充电状态, 子模块电容电压大于正常运行时电容电压。

通过上述分析, 子模块发生  $S_1$  故障时输出电压降低, 子模块发生  $S_2$  故障时输出电压上升。基于式(3)一式(5)可得, 故障子模块输出电流和循环电流会随着故障子模块输出电压的变化发生相应变化, 归纳如表 1 所示。基于输出电流和环流的数学模型可直接体现 MMC 故障发生的桥臂位置和子模块故障类型<sup>[27]</sup>。因此本文采用输出电流和环流来进行故障检测, 再基于电容电压来进行子模块故障定位, 以提高故障诊断的准确性。

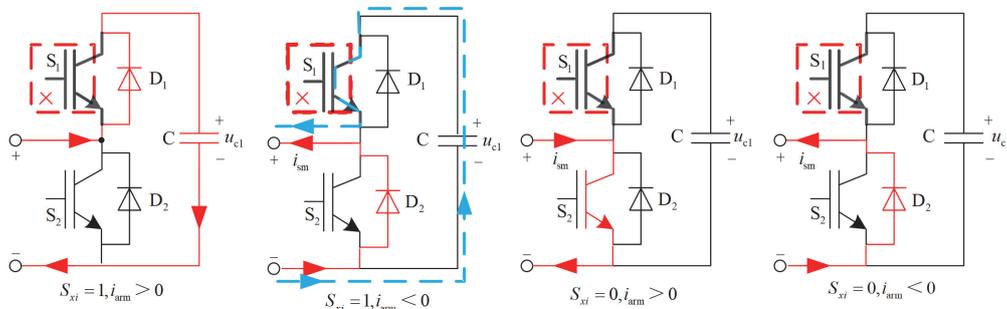


图 2  $S_1$  故障下的子模块电流路径

Fig. 2 SM current path under  $S_1$  fault

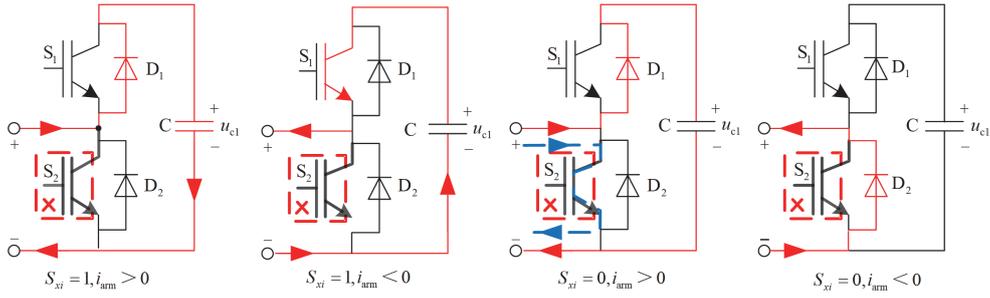
图3  $S_2$  故障下的子模块电流路径Fig. 3 SM current path under  $S_2$  fault

表1 两种故障类型下的故障特征

Table 1 Fault characteristics of two types of faults

故障臂	故障开关	电容电压	输出电流	环流
上桥臂	$S_1$ 故障	升高	升高	升高
上桥臂	$S_2$ 故障	升高	降低	降低
下桥臂	$S_1$ 故障	升高	降低	升高
下桥臂	$S_2$ 故障	升高	升高	降低

## 2.2 子模块故障特征逐段拟合的误差优化

由于系统特征方程的连续性，前一时刻的预测误差会不断累积至当前时刻，导致子模块电容电压预测值与实际值的偏差不断增大，进而影响 MMC 动态性能。本文所提方法利用电容电压采样值前 5 个周期的预测值与实际值之差进行多项式拟合，以减少干扰的影响。

$$\Delta y(k - T_s) = u_{\text{cxi\_p}}(k - T_s) - u_{\text{cxi\_m}}(k - T_s) \quad (9)$$

$$V_{\text{arg}}(k) = \arg \min_{a_0, a_1, \dots, a_m} \sum_{i=0}^N (h(t) - \Delta y(k - T_s))^2 \quad (10)$$

式中： $\Delta y(k - T_s)$  为优化前预测值与实际值之差； $u_{\text{cxi\_p}}(k - T_s)$  和  $u_{\text{cxi\_m}}(k - T_s)$  分别为  $k - T_s$  时刻子模块电容电压预测值和实际值； $h(t)$  为基于时间的分段函数； $a_m$  为设定的分段周期 ( $m = 5$ )； $V_{\text{arg}}(k)$  为误差逐段拟合后的修正值； $N$  为半桥子模块个数。

将拟合得到的校正值作为补充的误差量添加至电容电压预测方程中，如式(11)所示。

$$u_{\text{cxi\_p}}^*(k + 1) = u_{\text{cxi\_p}}^*(k) + V_{\text{arg}}(k) \quad (11)$$

式中， $u_{\text{cxi\_p}}^*(k + 1)$  和  $u_{\text{cxi\_p}}^*(k)$  分别表示误差优化后  $k + 1$  和  $k$  时刻子模块电容电压预测值。

基于电容电压逐段拟合的误差优化模型，可有效推广至系统输出电流预测值  $i_{\text{o\_pre}}$  和环流预测值  $i_{\text{cir\_pre}}$  的准确计算。结合式(3)、式(4)可得输出电流预测值  $i_{\text{o\_pre}}(k)$  的离散化方程为

$$i_{\text{o\_pre}}(k) = A[u_{\text{p\_pre}}^*(k - 1) - u_{\text{n\_pre}}^*(k - 1) - 2u_{\text{g}}(k - 1)] + B i_{\text{o\_pre}}(k - 1) \quad (12)$$

$$A = T_s / (L + 2L_o) \quad (13)$$

$$B = 1 - [2R \cdot T_s / (2L_o + L)] \quad (14)$$

式中： $u_{\text{g}}(k - 1)$  为  $k - 1$  时刻实际交流电网电压； $u_{\text{p\_pre}}^*(k - 1)$  和  $u_{\text{n\_pre}}^*(k - 1)$  分别为  $k - 1$  时刻上下桥臂输出电压预测值； $i_{\text{o\_pre}}(k - 1)$  为  $k - 1$  时刻系统输出电流预测值。

同理， $k$  时刻的环流预测值  $i_{\text{cir\_pre}}$  可表为

$$i_{\text{cir\_pre}}(k) = C[U_{\text{dc}} - (u_{\text{p\_pre}}^*(k - 1) - u_{\text{n\_pre}}^*(k - 1))] + D i_{\text{cir}}(k - 1) \quad (15)$$

$$C = T_s / 2L, D = 1 - T_s / L \quad (16)$$

式中， $i_{\text{cir}}(k - 1)$  是  $k - 1$  时刻测量的实际环流值。

基于当前时刻测量的输出电流  $i_{\text{o}}(k)$  和环流  $i_{\text{cir}}(k)$ ，测量值和预测值之间的误差可定义为

$$\begin{cases} i_{\text{o\_error}}(k) = i_{\text{o}}(k) - i_{\text{o\_pre}}(k) \\ i_{\text{cir\_error}}(k) = i_{\text{cir}}(k) - i_{\text{cir\_pre}}(k) \end{cases} \quad (17)$$

式中， $i_{\text{o\_error}}(k)$  和  $i_{\text{cir\_error}}(k)$  分别为  $k$  时刻的输出电流误差和环流误差。

上述方法基于子模块故障特征多个周期逐段拟合来获取校正值，在最大程度上减少了拟合过程中的过拟合和欠拟合现象，保证了本文所用特征参数和系统模型的准确性。相比于文献[28]仅采用前一周期的误差值对预测值进行优化，具有更强的稳定性和抗干扰能力，且无需引入滚动优化系数和滑模观测器，即可达到更好的模型预测效果。

## 2.3 与现有电容电压故障诊断方法比较

表 2 展示了本文所提故障诊断策略与现有的基于电容电压故障定位的典型方法的比较。子模块电容电压的故障诊断方法大体可分为 4 类：1) 采样实际值并通过推导阈值模型进行诊断；2) 对实际值进行预测，利用预测值与实际值之差作为诊断依据；3) 与概率方法相结合，采用各个子模块电容电压的相关系数进行判定；4) 基于算法整定依次投入最易发生故障的子模块进行故障检测。现有基于电容电

压的方法根据所设阈值来进行故障诊断, 方法实现简单, 但参数的采样偏差会影响到故障诊断的时间和结果。

图 4 展示了采用本文所提电容电压逐段误差优化方法的子模块 1 电容电压误差优化波形图。在 MMC 正常工作时, 优化后的子模块电容电压预测值和实际值误差极小。在 MMC 发生子模块故障后, 优化后的子模块电容电压预测值相较于优化前的电容电压预测值故障特征更为明显, 在故障初期即可快速实现子模块故障定位判断。

表 2 本文方法与现有基于电容电压的故障定位方法比较

Table 2 Comparison of the proposed method with existing capacitor voltage-based fault location methods

方法	故障诊断策略	诊断时间	策略特点
文献[10]	额外增加传感器测量子模块电容电压	约 0.3 ms	速度快, 成本高
文献[12-14]	子模块电压实际值与设定阈值模型	约 40 ms	结构简单, 速度慢, 阈值难设
文献[15]	子模块电压与概率方法结合	约 20 ms	成本低, 速度中等, 只能应对单开关故障
文献[16]	子模块电压与排序平衡算法结合	约 1 ms	速度快, 成本中等, 阈值难设
本文方法	经误差优化的预测模型与 1D-CNN 结合	约 10 ms	成本低, 速度较快, 无需设定阈值

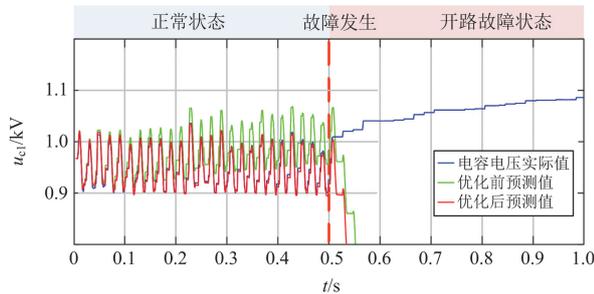


图 4 子模块 1 电容电压误差优化

Fig. 4 Optimization of capacitor voltage error of SM<sub>1</sub>

此外, 本文所提方法无需额外增加传感器即可在一个工频周期内快速实现 S<sub>1</sub>(S<sub>2</sub>) 故障的准确定位。以子模块 1 发生单管故障为例, 基于子模块电容电压实际值, 电容电压微增量值  $u_{inc\_m}(k)$  估算如式(18)所示。

$$u_{inc\_m}(k) = \frac{u_c(k) - u_c(k-1)}{dt} \quad (18)$$

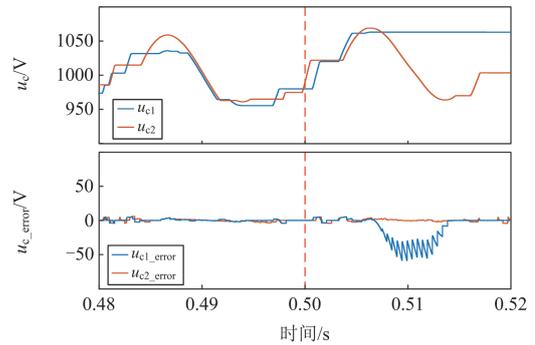
式中,  $u_c(k)$  和  $u_c(k-1)$  分别表示  $k$  时刻和  $k-1$  时刻传感器采集到的子模块电容电压值。

基于第 2.2 节误差优化的子模块电容电压预测模型, 子模块电容电压微增量预测值  $u_{inc\_pre}(k)$  和子模块电容电压微增量误差  $u_{c\_error}(k)$  可分别表示为

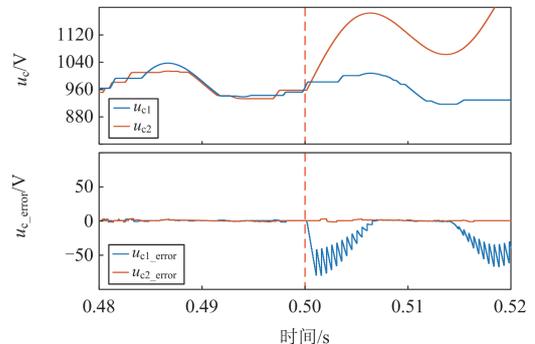
$$u_{inc\_pre}(k) = \frac{u_{c\_p}^*(k) - u_{c\_p}^*(k-1)}{dt} \quad (19)$$

$$u_{c\_error}(k) = u_{inc\_m}(k) - u_{inc\_pre}(k) \quad (20)$$

式中,  $u_{c\_p}^*(k)$ 、 $u_{c\_p}^*(k-1)$  分别为误差优化后  $k$  时刻和  $k-1$  时刻子模块电容电压的预测值(式中下标“xi”省略)。正常运行时子模块电容电压微增量误差在理想状态下为 0, 发生 S<sub>1</sub>(S<sub>2</sub>) 开路故障的子模块误差值远高于正常子模块。开路故障特征波形如图 5 所示。  $u_{c1\_error}$ 、 $u_{c2\_error}$  分别为 SM<sub>1</sub> 和 SM<sub>2</sub> 的电容电压微增量误差;  $u_{c1}$ 、 $u_{c2}$  分别为 SM<sub>1</sub> 和 SM<sub>2</sub> 的实际电容电压。



(a) 子模块 1 S<sub>1</sub> 开路故障



(b) 子模块 1 S<sub>2</sub> 开路故障

图 5 开路故障特征波形

Fig. 5 Open-circuit fault characteristic waveform

上述分析可知, 本文所提方法在一个工频周期内即可快速实现 S<sub>1</sub>(S<sub>2</sub>) 故障的准确定位。且相较于现有电容电压的故障诊断策略, 该方法具有极高的参数精确度, 能有效解决现在基于电容电压故障诊断方法存在的鲁棒性差的问题, 无需额外传感器即可快速实现子模块故障诊断。

### 3 基于 1D-CNN 的故障诊断策略

针对当前 MMC 的开路故障诊断方法所存在的阈值难选取、计算过程复杂等难题, 本文基于上述

误差优化后的电容电压、输出电流和环流故障特征,采用结构简单、适应力强的一维卷积神经网络(1D-CNN)作为新的故障定位方案,实现了子模块高精度、实时的故障诊断。

### 3.1 故障数据处理

为充分利用 MMC 控制可用采样数据,利用滚动统计法去捕捉辅助特征每个时间点数据的趋势和变化。滚动序列长度  $L=1/(T_s f_o)$ ,  $f_o$  为输出电压频率。 $k$  时刻的电容电压滚动规则如图 6 所示。

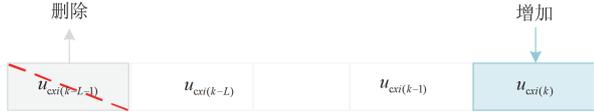


图 6 电容电压迭代滚动规则

Fig. 6 Iteration rolling rule of capacitor voltage

滚动统计法可在故障特征序列构建时,保留电容电压数据,仅需电容电压数据计算当前时刻预测的输出电流误差数据、环流误差数据和电容电压微增量数据,极大地简化了特征提取的计算量。

### 3.2 基于 1D-CNN 的故障诊断策略

1D-CNN 适用于时间序列的特征提取与识别,对小数据集的分类性能良好。因此本文利用 1D-CNN 实现子模块多管故障的准确定位和故障类型判断。

1D-CNN 核心结构由卷积层、激活层、池化层和全连接层组成。在卷积层中,一个时间段内的输入量被神经元提取为特征映射,将其与多个滤波器进行卷积得到局部特征内核。卷积特征映射计算如式(21)所示。

$$\mathbf{x}_j^l = \mathbf{b}_j^l + \sum_{i=1}^{N_{l-1}} \text{Conv1D}(\mathbf{w}_{ik}^{l-1}, \mathbf{R}_i^{l-1}) \quad (21)$$

式中:  $\mathbf{x}_j^l$  为卷积层特征映射值;  $\mathbf{b}_j^l$  为神经元偏置;  $\mathbf{R}_i^{l-1}$  为神经元的输出;  $\mathbf{w}_{ik}^{l-1}$  为卷积权重;  $N_{l-1}$  为总数据集; 1D 代表一维网络; 其中上标“ $l$ ”为卷积层数,下标“ $j$ ”为第  $j$  个神经元。

在卷积层与激活层之间引入 LeakyReLU 激活函数,以防止两层之间的线性关系,如式(22)所示。

$$\text{LeakyReLU} = \begin{cases} ax, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (22)$$

激活函数的输出边界不局限于 -1 和 1 之间,在加快网络训练速度的同时,也避免了局部神经元无效的问题。

在池化层中,选择最大池化法将数据分成多个区域,每个区域选取最大值,最大池化阵  $\mathbf{P}$  为

$$\mathbf{P} = \max_e \{ \mathbf{A}^H \} \quad (23)$$

式中:  $e$  为最大池化面积;  $\mathbf{A}$  为神经元组成的特征

矩阵;  $H$  为特征图宽度。

全连接层将经过多次卷积池化后的特征映射展开为一维向量作为输入,输出向量由式(24)计算。

$$\mathbf{y}^l = f \left( \sum_{i=1}^{N_{l-1}} \text{conv1D}(\mathbf{w}_{ik}^{l-1}, \mathbf{x}^{l-1}) + \mathbf{b}^l \right) \quad (24)$$

式中:  $\mathbf{y}^l$  为第  $l$  层的输出;  $\mathbf{b}^l$  为偏置项;  $\mathbf{x}^{l-1}$  为第  $l-1$  层的输出值;  $f$  为激活函数。

通过全连接层计算后,使用 softmax 分类器实现分类任务。分类过程如式(25)所示。

$$O_i = \left[ \sum_{i=1}^k \exp(\mathbf{W}_i \mathbf{x} + \mathbf{b}_i) \right]^{-1} \begin{bmatrix} \exp(\mathbf{W}_1 \mathbf{x} + \mathbf{b}_1) \\ \exp(\mathbf{W}_2 \mathbf{x} + \mathbf{b}_2) \\ \vdots \\ \exp(\mathbf{W}_i \mathbf{x} + \mathbf{b}_i) \end{bmatrix} \quad (25)$$

式中:  $O_i$  为分类器计算出的每个神经元输出的概率值;  $\mathbf{W}_i$ 、 $\mathbf{b}_i$  分别为第  $i$  次分类对应的权值矩阵和偏移量矩阵。

基于上述方法,本文的故障诊断策略首先基于健康与故障状态下的特征样本,通过交替的卷积层与池化层提取故障特征,对不同故障类型的定位网络逐一进行有监督的预训练。然后将归一化后的样本输入到 Softmax 中进行测试得到故障标签,并对测试样本给出具体故障诊断结果,故障定位流程如图 7 所示。

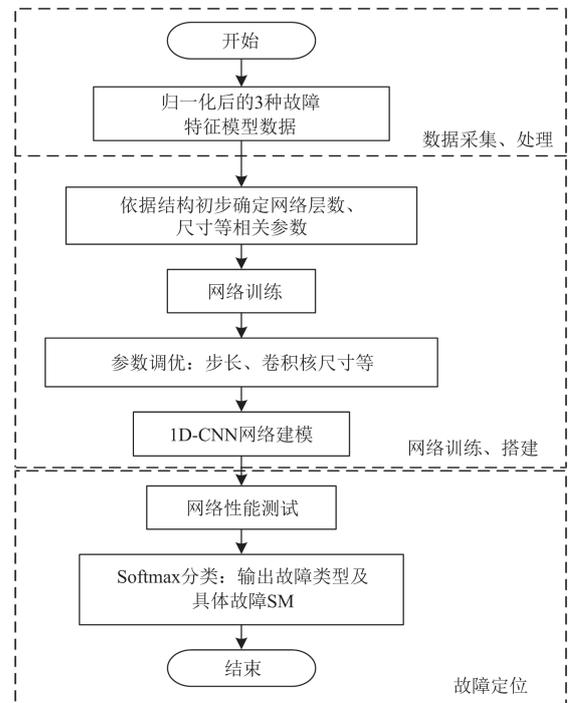


图 7 基于 1D-CNN 的故障诊断流程图

Fig. 7 Fault diagnosis flowchart based on 1D-CNN

具体的实现步骤如下所述。

1) 基于 MMC 仿真模型, 模拟各类型 SM 故障情况, 采集健康与故障数据。

2) 将采集的数据进行归一化处理为  $X_1$ 、 $X_2$ 、 $X_3$ 、 $Y$ 。其中  $X_1$ 、 $X_2$ 、 $X_3$  分别为 3 种 SM 故障特征值,  $Y$  为对应的故障状态。

3) 依据 LeNet-5 结构选择 1D-CNN 网络卷积层数、池化层数、输入通道数及过滤节点数。

4) 训练样本集数据, 在兼顾速度与准确率的基础上, 对网络进行参数调优: 卷积步长、卷积核尺寸等。

5) 输入未知故障特征值样本, 代入步骤 4) 构建的 1D-CNN 网络, 输出故障诊断值。

### 4 仿真验证

为了验证所提方法的有效性, 在 Matlab/Simulink 中进行仿真验证, 参数如表 3 所示。

表 3 MMC 仿真参数

Table 3 MMC parameters for simulation

参数	数值
直流母线电压/kV	10
模块数	10
电容电压/kV	1
子模块电容/mF	3.5
桥臂电感/mH	10
网侧电感/mH	10
网侧电阻/ $\Omega$	0.001
电网电压/kV	4

#### 4.1 稳态与电流阶跃时的鲁棒性分析

为验证所提方法的鲁棒性, 对稳态和输出侧电流阶跃状态的鲁棒性问题进行仿真验证。在图 8 和图 9 中, 分别设定在 0.5 s 时交流侧电流  $i_o$  从 270 A 增至 330 A 和  $i_o$  从 330 A 减至 270 A 两种工况。

如图 8 所示, 在工况改变过程中, 子模块电容电压波动小于 10%, 输出电流与环流在状态变化时发生阶跃, 但电容电压变化率特征量稳定在 0 V 附近。图 9 所示在工况改变过程中, 子模块电容电压波动小于 10%, 输出电流与环流在切换时波动较大, 但持续时间仅 1 ms, 且电容电压变化率特征量仍稳定在 0 V 附近。

由上述仿真可知, 本文所提方法在稳态和输出电流阶跃条件下都具有鲁棒性, 故障诊断策略在工况改变时并不会引起子模块故障诊断的误判。

#### 4.2 多个子模块同时发生 $S_1$ 故障

设置在 10.5 s 时, 上桥臂  $SM_1$  和  $SM_2$  同时发生  $S_1$  故障, 桥臂电流波形、子模块电容电压和故障特征值如图 10 所示。

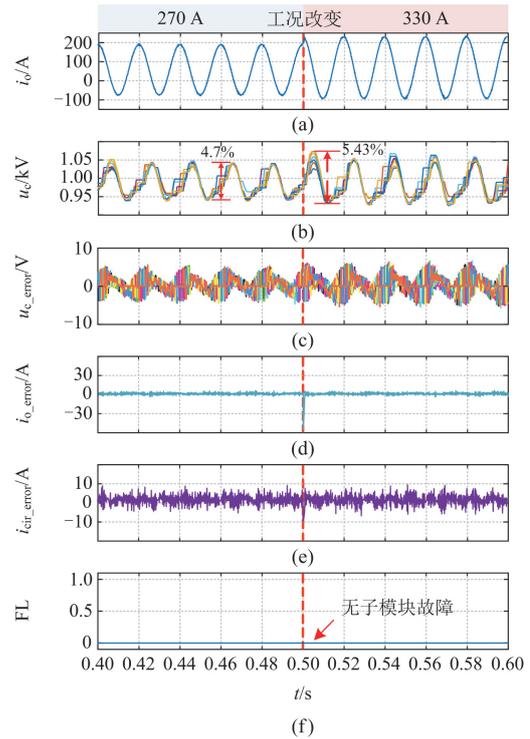


图 8 交流侧电流从 270 A 切换到 330 A 故障特征变化  
Fig. 8 Change in fault characteristics when switching AC side current from 270 A to 330 A

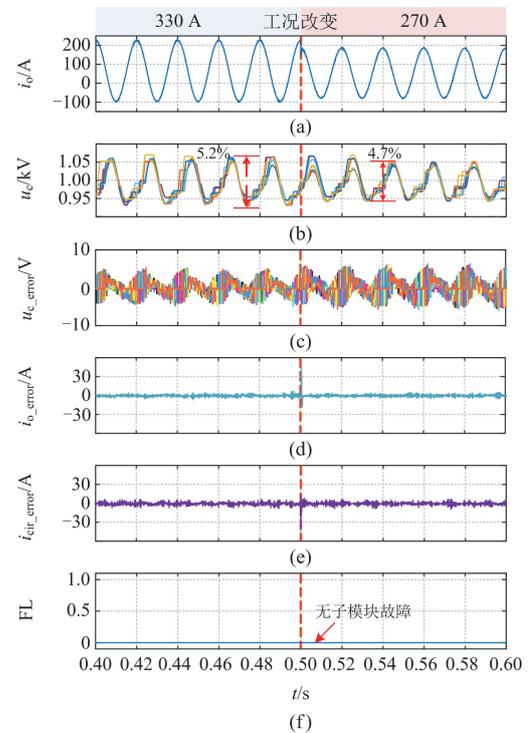


图 9 交流侧电流从 330 A 切换到 270 A 故障特征变化  
Fig. 9 Change in fault characteristics when switching AC side current from 330 A to 270 A

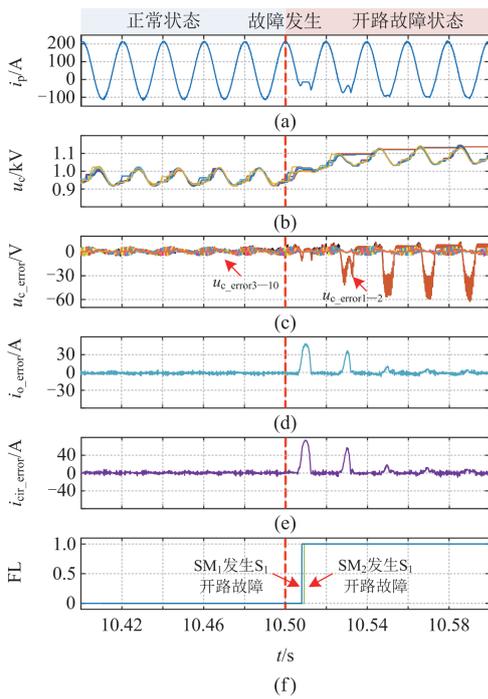


图 10 SM<sub>1</sub> 和 SM<sub>2</sub> 同时发生 S<sub>1</sub> 开路故障

Fig. 10 S<sub>1</sub> open-circuit faults of SM<sub>1</sub> and SM<sub>2</sub> at the same time

在故障发生后，随着桥臂电流由正变为负，处于投入状态的 SM<sub>1</sub> 和 SM<sub>2</sub> 无法通过上管 IGBT 正常放电，故障子模块电容电压微增量严重偏离正常值。同时输出电流实际值高于预测值，环流实际值高于预测值。故障诊断结果为上桥臂 SM<sub>1</sub> 和 SM<sub>2</sub> 同时发生 S<sub>1</sub> 开路故障，故障诊断时长为 9.6 ms。

图 11 为经传统误差反馈滚动优化后的开路故障特征仿真结果，令 SM<sub>1</sub>、SM<sub>2</sub> 在 10.5 s 时上管 IGBT 同时发生开路故障。由于在正常运行时误差随时间不断累积，导致正常状态下的 3 种特征量偏差过大，故障发生后特征不明显，1D-CNN 无法识别故障情况，发生误判。

对比图 10、图 11 仿真结果可知，故障特征模型采用本文所提逐段拟合的误差优化方法后，相比于传统方法，可在 MMC 系统持续运行时保证故障诊断策略的有效性。且该方法对于余下故障情况同样适用，不再赘述。

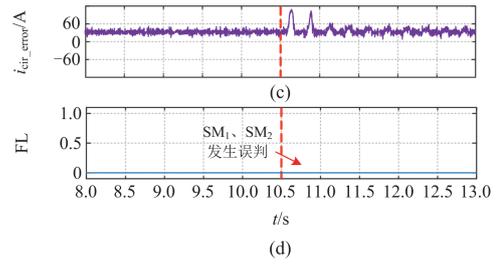
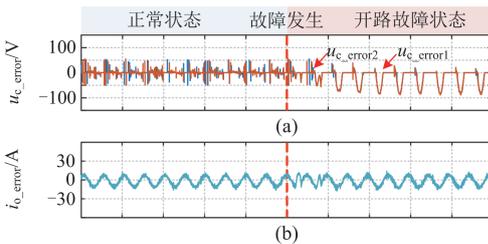


图 11 传统误差优化方法下 SM<sub>1</sub> 和 SM<sub>2</sub> 同时发生 S<sub>1</sub> 开路故障

Fig. 11 S<sub>1</sub> faults of SM<sub>1</sub> and SM<sub>2</sub> at the same time with traditional error optimization method

#### 4.2 多个子模块同时发生 S<sub>2</sub> 开路故障

设置在 0.5 s 时，上桥臂 SM<sub>1</sub> 和 SM<sub>2</sub> 同时发生 S<sub>2</sub> 开路故障，桥臂电流、子模块电容电压和故障特征值如图 12 所示。

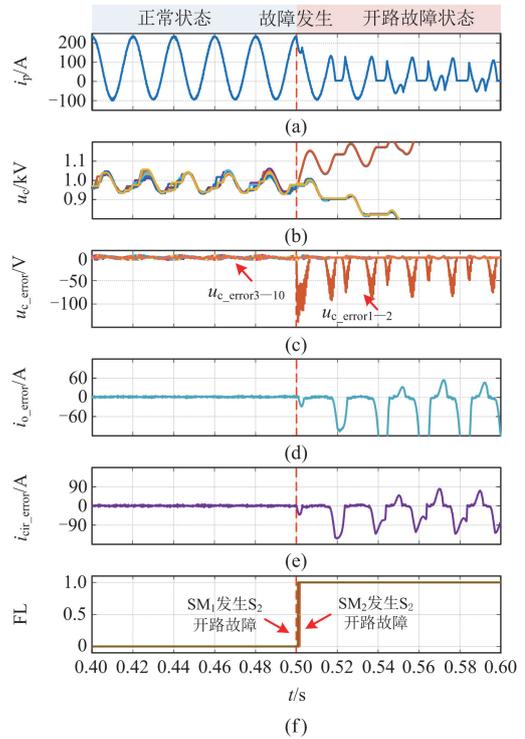


图 12 SM<sub>1</sub> 和 SM<sub>2</sub> 同时发生 S<sub>2</sub> 开路故障

Fig. 12 S<sub>2</sub> open-circuit faults of SM<sub>1</sub> and SM<sub>2</sub> at the same time

故障发生后，SM<sub>1</sub> 和 SM<sub>2</sub> 均应处于旁路状态，由于 S<sub>2</sub> 开路故障导致桥臂电流分别通过二极管 D<sub>1</sub>、D<sub>2</sub> 对 SM<sub>1</sub>、SM<sub>2</sub> 进行充电，电容电压陡增，故障子模块电容电压微增量严重偏离正常值。同时输出电流实际值低于预测值，环流实际值低于预测值。由图 12(f)可知，故障诊断结果为上桥臂 SM<sub>1</sub> 和 SM<sub>2</sub> 同时发生 S<sub>2</sub> 开路故障，故障诊断时长为 0.62 ms。

## 5 实验验证

为了验证本文所提故障诊断方法的有效性, 本文基于 StarSim 实时在环实验平台, 搭建了单相 10 模块的 MMC 模型如图 13 所示, 实验参数如表 3 所示。

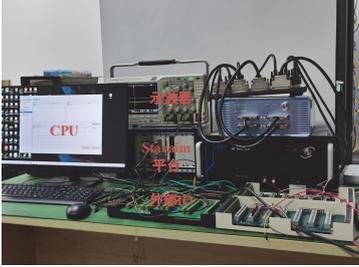
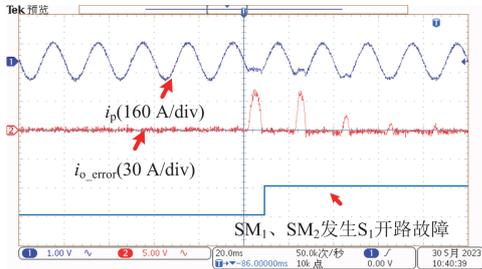


图 13 硬件在环平台

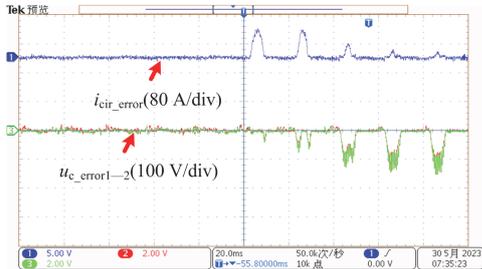
Fig. 13 Hardware in the loop platform

### 5.1 $SM_1$ 和 $SM_2$ 同时发生 $S_1$ 故障

图 14 为  $SM_1$  和  $SM_2$  同时发生  $S_1$  开路故障的实验波形。在故障发生后, 随着桥臂电流由正变负, 处于投入状态的  $SM_1$  和  $SM_2$  无法通过上管 IGBT 正常放电。故障子模块电容电压微增量严重偏离正常值。同时输出电流实际值高于预测值, 环流实际值高于预测值。故障诊断结果为上桥臂  $SM_1$  和  $SM_2$  同时发生  $S_1$  故障, 故障诊断时长为 9.7 ms。



(a)



(b)

图 14  $SM_1$  和  $SM_2$  同时发生  $S_1$  开路故障

Fig. 14  $S_1$  open-circuit faults of  $SM_1$  and  $SM_2$  at the same time

图 15 为基于传统误差反馈滚动优化的情况下,  $SM_1$  和  $SM_2$  同时发生  $S_1$  开路故障。由图 15 可知,

使用传统误差反馈滚动优化方法不能令 MMC 系统在运行时保持稳定, 输出电流误差特征不明显, 环流误差特征随系统运行稳态值逐渐增大, 电压微增量特征产生振荡, 该方法在故障发生前 0.042 s 和 0.006 s 时分别对  $SM_1$  和  $SM_2$  的故障状态产生了误判。实验验证基于传统误差反馈滚动优化方法不足以实现高精度的故障诊断, 而本文所提误差优化的故障诊断方法具有一定的优越性。

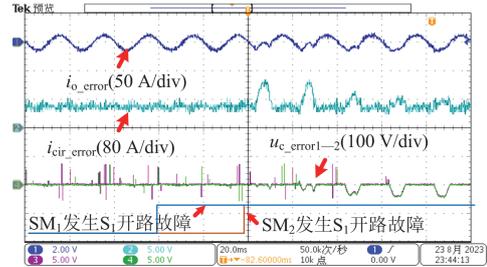
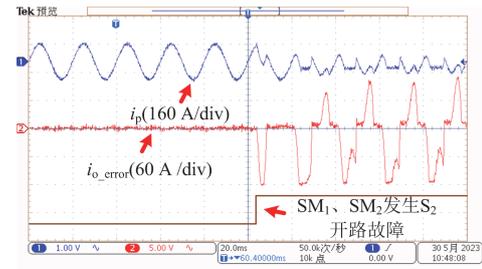


图 15 传统误差优化法下  $SM_1$  和  $SM_2$  同时发生  $S_1$  故障

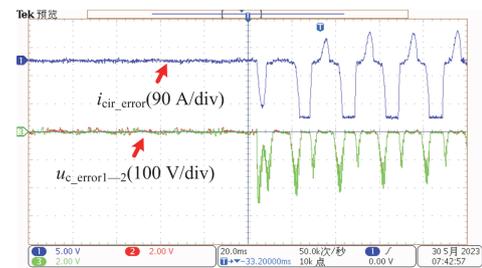
Fig. 15  $S_1$  faults of  $SM_1$  and  $SM_2$  at the same time with traditional error optimization method

### 5.2 $SM_1$ 和 $SM_2$ 同时发生 $S_2$ 开路故障

图 16 为  $SM_1$  和  $SM_2$  同时发生  $S_2$  开路故障实验波形。故障发生后,  $SM_1$  和  $SM_2$  均应处于旁路状态, 由于  $S_2$  开路故障导致桥臂电流被迫通过二极管  $D_1$  对  $SM_1$ 、 $SM_2$  进行充电, 电容电压陡增, 故障子模块电容电压微增量严重偏离正常值。同时输出电流实际值低于预测值, 环流实际值低于预测值。故障



(a)



(b)

图 16  $SM_1$  和  $SM_2$  同时发生  $S_2$  开路故障

Fig. 16  $S_2$  open-circuit faults of  $SM_1$  and  $SM_2$  at the same time

诊断结果为上桥臂  $SM_1$  和  $SM_2$  同时发生  $S_2$  开路故障，故障诊断时长为 2.9 ms。

### 5.3 $SM_1$ 和 $SM_1$ 同时发生 $S_1$ 和 $S_2$ 开路故障

图 17 为  $SM_1$  和  $SM_2$  同时发生  $S_1$  和  $S_2$  开路故障的实验波形。故障发生后的起始阶段桥臂电流为负，处于放电状态的  $SM_1$  通过二极管  $D_2$  被错误旁路，造成故障子模块电容电压微增量严重偏离其余正常子模块，同时输出电流实际值高于预测值，环流实际值高于预测值。当桥臂电流为正后，由于下管 IGBT 的故障导致桥臂电流通过二极管  $D_1$  对子模块 2 进行充电，电容电压陡增。故障子模块电容电压微增量严重偏离其余正常子模块，同时输出电流实际值低于预测值，环流实际值低于预测值。由故障诊断输出可知， $SM_1$  发生  $S_1$  开路故障的诊断时长为 4.3 ms， $SM_2$  发生  $S_2$  开路故障的诊断时长为 9.4 ms。

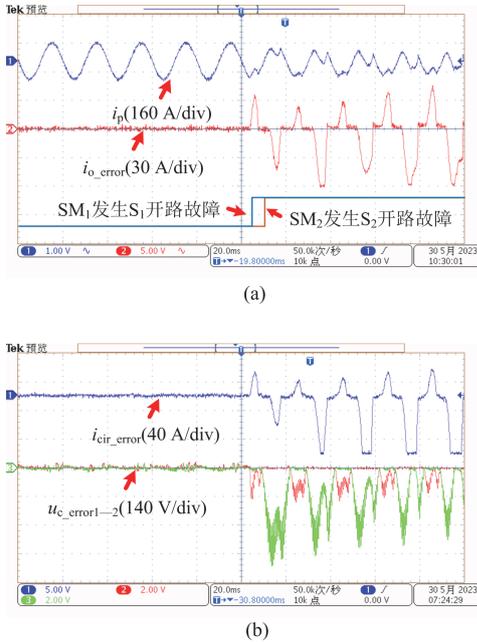


图 17  $SM_1$  和  $SM_2$  同时发生  $S_1$  和  $S_2$  开路故障

Fig. 17  $S_1$  fault of  $SM_1$  and  $S_2$  fault of  $SM_2$  at the same time

### 5.4 $SM_1$ 、 $SM_2$ 和 $SM_3$ 同时发生 $S_1$ 和 $S_2$ 开路故障

图 18 为  $SM_1$  和  $SM_2$  同时发生  $S_1$  开路故障， $SM_3$  发生  $S_2$  开路故障的实验波形。故障发生后处于放电状态的  $SM_1$  通过二极管  $D_2$  被错误旁路，造成故障子模块 1 和子模块 2 电容电压微增量严重偏离其余正常子模块，同时输出电流实际值高于预测值，环流实际值高于预测值。当桥臂电流为正后，由于下管 IGBT 的故障导致桥臂电流通过二极管  $D_1$  对子模块 3 进行充电，电容电压陡增。故障子模块电容电压微增量严重偏离其余正常子模块，同时输出电

流实际值低于预测值，环流实际值低于预测值。由故障诊断输出可知， $SM_1$  和  $SM_2$  发生  $S_1$  开路故障的诊断时长为 1.2 ms， $SM_3$  发生  $S_2$  开路故障的诊断时长为 6.9 ms。

由实验结果可知，在故障子模块电容电压变化的初始阶段，所提故障特征值变化明显，在一个工频周期内即可快速实现子模块多管故障的准确定位和故障类型判断。各个子模块间相互独立，互不影响。且本文所提误差优化方法降低了系统参数误差和模型预测控制算法误差的影响，保证了故障诊断网络的鲁棒性。

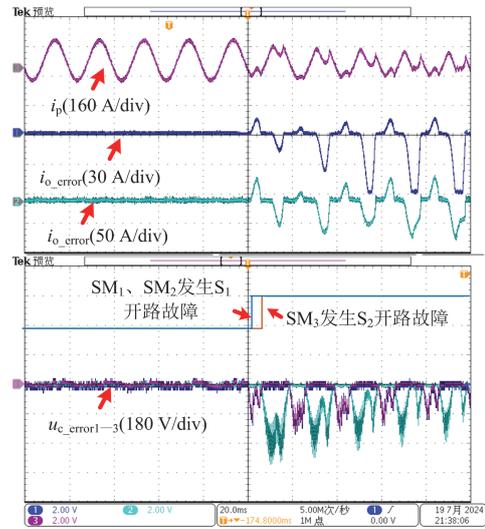


图 18  $SM_1$ 、 $SM_2$  和  $SM_3$  同时发生  $S_1$  和  $S_2$  开路故障

Fig. 18  $S_1$  fault of  $SM_1$  and  $SM_2$  and  $S_2$  fault of  $SM_3$  at the same time

## 6 结论

针对 MMC 实际模型故障诊断所存在的鲁棒性差、阈值难选取的问题，本文提出一种电容电压预测误差优化的 MMC 多管开路故障诊断策略。利用逐段误差优化后的电容电压、输出电流和环流作为故障诊断特征。采用无模型、结构简单的一维神经网络(1D-CNN)作为新的故障定位方案，该策略优点如下。

- 1) 所提电容电压逐段拟合方法显著降低了系统参数误差和模型预测控制算法误差的影响，保证了故障诊断的鲁棒性和抗干扰能力。
- 2) 误差优化后的子模块电容电压预测值相较于优化前的电容电压预测值故障特征更为明显，在故障初期即可快速实现子模块的故障定位。
- 3) 1D-CNN 神经网络具有无模型、结构简单的优点，规避了传统定位算法存在的阈值难选取、计

算复杂的问题。

4) 所提故障诊断策略无需添加额外传感器, 适用于不同类型下单个、多个子模块故障诊断。

### 参考文献

- [1] 陈新岗, 张金京, 马志鹏, 等. 基于 MMC 的光伏直流升压并网系统故障分析及限流控制策略[J]. 电力系统保护与控制, 2023, 51(22): 145-154.  
CHEN Xingang, ZHANG Jinjing, MA Zhipeng, et al. MMC-based fault analysis and current-limiting control strategy for a photovoltaic DC boost grid-connected system[J]. Power System Protection and Control, 2023, 51(22): 145-154.
- [2] 田阳, 桑一岩, 盛佳敏. 基于扩张状态观测器的并网 MMC 无源滑模控制方法[J]. 上海电力大学学报, 2024, 40(3): 242-250.  
TIAN Yang, SANG Yiyan, SHENG Jiamin. Extended state observer based passivity-based sliding mode control of grid-connected MMC[J]. Journal of Shanghai University of Electric Power, 2024, 40(3): 242-250.
- [3] 贺宇阳, 马千里, 于飞, 等. 基于 CRS-LMD 和 SVD 的 MMC-HVDC 线路故障测距方法[J]. 电力系统保护与控制, 2024, 52(1): 121-132.  
HE Yuyang, MA Qianli, YU Fei, et al. Fault location of an MMC-HVDC line based on CRS-LMD and SVD[J]. Power System Protection and Control, 2024, 52(1): 121-132.
- [4] 王少林, 王刚, 陈琦, 等. 考虑线路电阻影响的 MMC-MTDC 自适应下垂控制[J]. 电力系统保护与控制, 2022, 50(10): 40-47.  
WANG Shaolin, WANG Gang, CHEN Qi, et al. An adaptive droop control method considering the influence of line resistance for MMC-MTDC[J]. Power System Protection and Control, 2022, 50(10): 40-47.
- [5] 于吉, 尹项根, 赖锦木, 等. 电网不对称故障下 MMC 自适应相功率均衡控制策略[J]. 电力系统保护与控制, 2024, 52(1): 1-12.  
YU Ji, YIN Xianggen, LAI Jinmu, et al. Adaptive leg-balancing control strategy of an MMC in an asymmetric AC grid fault[J]. Power System Protection and Control, 2024, 52(1): 1-12.
- [6] 唐英杰, 张哲任, 徐政. 基于有源型 M3C 矩阵变换器的海上风电低频送出方案[J]. 电力系统自动化, 2022, 46(8): 113-122.  
TANG Yingjie, ZHANG Zheren, XU Zheng. Low-frequency transmission scheme for offshore wind power based on active modular multilevel matrix converter[J]. Automation of Electric Power Systems, 2022, 46(8): 113-122.
- [7] LIU Chengkai, DENG Fujin, CAI Xu, 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.
- [8] PICAS R, ZARAGOZA J, POU J, et al. Reliable modular multilevel converter fault detection with redundant voltage sensor[J]. IEEE Transactions on Power Electronics, 2017, 32(1): 39-51.
- [9] YANG Shunfeng, TANG Yi, WANG Peng. Seamless fault-tolerant operation of a modular multilevel converter with switch open-circuit fault diagnosis in a distributed control architecture[J]. IEEE Transactions on Power Electronics, 2018, 33(8): 7058-7070.
- [10] ZHANG Jianzhong, HU Xing, XU Shuai, et al. Fault diagnosis and monitoring of modular multilevel converter with fast response of voltage sensors[J]. IEEE Transactions on Industrial Electronics, 2020, 67(6): 5071-5080.
- [11] 刘宗沛, 吕世轩, 郑丽君, 等. MMC 子模块开关器件开路故障诊断策略[J]. 南方电网技术, 2024, 18(6): 10-19.  
LIU Zongpei, LÜ Shixuan, ZHENG Lijun, et al. Diagnosis strategy for open circuit faults of MMC sub-module switching device[J]. Southern Power System Technology, 2024, 18(6): 10-19
- [12] 徐坤山, 谢少军. 基于增量预测模型的 MMC 子模块功率管开路故障检测方法[J]. 中国电机工程学报, 2018, 38(21): 6420-6429, 6504.  
XU Kunshan, XIE Shaojun. Diagnosis method for submodule failures in modular multilevel converter based on incremental predictive model[J]. Proceedings of the CSEE, 2018, 38(21): 6420-6429, 6504.
- [13] 张正发, 李可军, 王卓迪, 等. 兼具开路故障诊断能力的 MMC 电容电压测量方法[J]. 电力系统自动化, 2017, 41(7): 114-119, 167.  
ZHANG Zhengfa, LI Kejun, WANG Zhuodi, et al. Measuring method of MMC capacitor voltage with diagnostic ability of open-circuit fault[J]. Automation of Electric Power Systems, 2017, 41(7): 114-119, 167.
- [14] GENG Zhi, HAN Minxiao, KHAN Z W, et al. Detection and localization strategy for switch open-circuit fault in modular multilevel converters[J]. IEEE Transactions on Power Delivery, 2020, 35(6): 2630-2640.
- [15] ZHOU Dehong, QIU Huan, YANG Shunfeng, 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.
- [16] CHEN Xingxing, LIU Jinjun, DENG Zhifeng, et al. A

- diagnosis strategy for multiple IGBT open-circuit faults of modular multilevel converters[J]. IEEE Transactions on Power Electronics, 2021, 36(1): 191-203.
- [17] 李群, 林金娇, 邓富金, 等. 基于龙伯格观测器的 MMC 子模块故障检测方法[J]. 电力工程技术, 2023, 42(2): 58-66.  
LI Qun, LIN Jinjiao, DENG Fujin, et al. Fault detection method for modular multilevel converters based on Luenberger observer[J]. Electric Power Engineering Technology, 2023, 42(2): 58-66.
- [18] YANG Qichen, QIN Jiangchao, SAEEDIFARD M. Analysis, detection and location of open-switch submodule failures in a modular multilevel converter[J]. IEEE Transactions on Power Delivery, 2016, 31(1): 155-164.
- [19] 张彼德, 洪锡文, 刘俊, 等. 基于无监督学习的 MMC 子模块开路故障诊断方法[J]. 电力系统保护与控制, 2021, 49(12): 98-105.  
ZHANG Bide, HONG Xiwen, LIU Jun, et al. Diagnosis method for sub-module open-circuit fault in modular multilevel converter based on unsupervised learning[J]. Power System Protection and Control, 2021, 49(12): 98-105.
- [20] 杨贺雅, 邢纹硕, 向鑫, 等. 基于随机森林二分类器的模块化多电平换流器子模块开路故障检测方法[J]. 中国电机工程学报, 2023, 43(10): 3916-3928.  
YANG Heya, XING Wenshuo, XIANG Xin, 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.
- [21] HU Xue, JIA Hefei, ZHANG Yuedong, 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.
- [22] DENG Fujin, JIN Ming, LIU Chengkai, et al. Switch open-circuit fault localization strategy for MMCs using sliding-time window based features extraction algorithm[J]. IEEE Transactions on Industrial Electronics, 2021, 68(10): 10193-10206.
- [23] TONG Lupeng, CHEN Yu, XU Tianqi, et al. Fault diagnosis for modular multilevel converter (MMC) based on deep learning: an edge implementation using binary neural network[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2023, 11(6): 5553-5568.
- [24] LIU Zehao, XIAO Lan, WANG Qin, et al. Open-circuit fault diagnosis for MMC based on event-triggered and capacitor current state observation[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022, 69(2): 534-538.
- [25] 徐坤山, 谢少军, 袁小峰, 等. 模块化多电平换流器子模块故障快速诊断方法[J]. 电力系统自动化, 2017, 41(18): 103-110.  
XU Kunshan, XIE Shaojun, YUAN Xiaofeng, et al. Rapid diagnostic method for submodule failure in modular multilevel converter[J]. Automation of Electric Power Systems, 2017, 41(18): 103-110.
- [26] SHAO Shuai, WATSON A J, CLARE J C, et al. Robustness analysis and experimental validation of a fault detection and isolation method for the modular multilevel converter[J]. IEEE Transactions on Power Electronic, 2016, 31(5): 3794-3805.
- [27] JIN Yu, XIAO Qian, JIA Hongjie, et al. A novel detection and localization approach of open-circuit switch fault for the grid-connected modular multilevel converter[J]. IEEE Transactions on Power Electronic, 2016, 31(5): 3794-3805.
- [28] 徐坤山, 谢少军. 基于增量预测模型的 MMC 子模块功率管开路故障检测方法[J]. 中国电机工程学报, 2018, 38(21): 6420-6429, 6504.  
XU Kunshan, XIE Shaojun. Diagnosis method for submodule failures in modular multilevel converter based on incremental predictive model[J]. Proceedings of the CSEE, 2018, 38(21): 6420-6429, 6504.

收稿日期: 2024-04-25; 修回日期: 2024-07-31

作者简介:

杨兴武(1981—), 男, 通信作者, 博士, 教授, 研究方向为功率变换器高性能控制及新能源并网技术; E-mail: yangxingwu@shiep.edu.cn

卢愿(1999—), 女, 硕士研究生, 研究方向为柔性直流输电变换器控制与可靠性; E-mail: luyuan990726@163.com

徐浩文(1999—), 男, 硕士研究生, 研究生方向为柔性直流输电变换器的故障诊断。E-mail: xuhaowen990521@163.com

(编辑 魏小丽)