

基于CNN-GRU深度学习的模块化多电平矩阵变换器故障诊断

朱晋¹, 程启明¹, 程尹曼²

(1. 上海电力大学自动化工程学院, 上海200090; 2. 上海电力公司市北供电分公司, 上海200041)

摘要: 模块化多电平矩阵变换器(modular multilevel matrix converter, M3C)是一种用于海上风力发电的低频电力传输AC-AC变换器。为了提高M3C工作的可靠性和稳定性, 对其子模块中IGBT(insulated gate bipolar transistor)的开路故障需要高效准确的诊断方法, 为此提出了基于卷积神经网络(convolutional neural network, CNN)和门控循环单元(gated loop unit, GRU)相结合的深度学习故障诊断方法。在对M3C子模块运行工况分析基础上对原始故障数据进行小波包分析, 并通过时序图像转换将其中高频分量转化为二维故障图片作为深度学习的训练及验证数据集, 经过CNN对高维数据的特征提取, 再通过GRU对数据进行优化训练, 实现了对M3C故障类别的诊断识别。所提方法相比传统方法具有更加准确、快速的故障诊断能力。

关键词: 模块化多电平矩阵变换器; 小波包分析; 卷积神经网络; 门控循环单元; 故障诊断

Fault Diagnosis of Modular Multilevel Matrix Converter Based on CNN-GRU Deep Learning

ZHU Jin¹, CHENG Qiming¹, CHENG Yinman²

(1. School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China; 2. North Power Supply Branch of Shanghai Electric Power Company, Shanghai 200041, China)

Abstract: Modular multilevel matrix converter (M3C) is a low-frequency power transmission AC-AC converter used for offshore wind power generation. In order to improve the reliability and stability of M3C operation, it is necessary to have an efficient and accurate diagnosis method for the open circuit fault of IGBT in its submodules. Therefore, a deep learning fault diagnosis method based on the combination of convolutional neural network (CNN) and gated loop unit (GRU) is proposed. On the basis of analyzing the operating conditions of M3C submodule, wavelet packet analysis is performed on the original fault data, the high-frequency components of which are converted into two-dimensional fault images through temporal image conversion as the training and validation dataset for deep learning, and the features of the high-dimensional data are extracted by CNN, and then the data is optimized and trained by GRU, so as to realize the diagnosis identification of the M3C fault categories. Compared to traditional methods, this method has more accurate and fast fault diagnosis capabilities.

Key words: modular multilevel matrix converter; wavelet packet analysis; convolutional neural network; gate recurrent unit; fault diagnosis

0 引言

模块化多电平矩阵变换器(modular multilevel matrix converter, M3C)作为近年来关注度较高的一

种逆变器拓扑结构不同于被广泛研究的模块化多电平变换器(modular multilevel converter, M2C), M3C主要用于实现交流到交流功率转换, 目前应用场合主要包含变速电机驱动、低频电力传输、海上

基金项目: 国家自然科学基金资助项目(62303301);上海市电站自动化技术重点实验室资助项目(13DZ2273800)。

Foundation item: Supported by the National Natural Science Foundation of China (62303301); the Project of Shanghai Key Laboratory of Power Station Automation Technology (13DZ2273800).

风能转换和抽水蓄能电站等^[1]。基于本身的应用前景, M3C 运行的可靠性成了保障的首要问题, M3C 中子模块的故障诊断是这个问题的核心, 子模块故障会使变换器偏离理想工作状态, 不利于整个系统的长时间运行, 故针对 M3C 子模块的故障诊断具有重要意义。子模块中故障率最高的组件就是绝缘栅双极型晶体管(insulated gate bipolar transistor, IGBT), 这一点导致 M2C 和 M3C 在故障元器件上存在交集, 但是由于 M3C 中 IGBT 数量远超 MMC, 故如何在实现精准识别故障的同时提高识别的效率是本文研究的重点。

目前针对复杂的 M3C 变换器主要有 3 种故障诊断方法, 分别基于硬件、基于模型和基于人工智能算法。其中基于硬件的故障诊断方法可以利用电压传感器直接对故障电压信号采样并进行故障诊断和定位^[3-7]。此类方法主要通过故障子模块产生的畸变电压信号对故障 IGBT 进行诊断与定位, 但基于传感器的诊断方法易受采样噪声和采样误差积累效应的影响而面临诊断准确率不高的问题。

基于模型的故障诊断方法通常利用变换器的数学模型和状态信息对 IGBT 故障进行诊断与定位, 其中主要集中于状态观测器方法的应用^[8-12]。此类诊断方法需在变换器的数学模型基础上进行设计, 且大都在 M2C 模型的基础上进行^[13], 如果在结构更为复杂的 M3C 模型上进行, 需要考虑的参数成倍增加, 干扰信息和计算量也会成倍增加, 且此类方法中如果不设置参量阈值, 易发生误诊断现象, 故此方法在 M3C 模型上很难适用。

基于智能算法的故障诊断方法有下面一些研究。文献[14]使用自动编码器得到深度特征值并结合分类器对模块化变换器子模块进行故障诊断, 这种方法通过一维时间序列对信号进行处理, 在关键步骤容易丢失信息, 从而影响诊断准确率。文献[15]对轴承的故障信号进行小波分解从而得到低频高频分量, 并以二维灰度图形作为卷积神经网络(convolutional neural network, CNN)的输入。文献[16]通过压缩小波变换转换成二维时频图作为优化 CNN 的输入。文献[17]通过利用深度可分离卷积来减少模型的参数量, 从而减少 CNN 计算量并提高诊断效果。但在处理结构复杂、参数众多的 M3C 问题上时单纯依赖 CNN 深度学习框架, 存在难以兼顾诊断准确率和诊断效率的问题。

通过长短期记忆神经网络(long short-term memory, LSTM)进行故障诊断需要较多训练参数, 且模型收敛速度较慢, 门控循环单元(gate recurrent unit, GRU)作为 LSTM 在计算量方面的改良网络在不损失诊断率的前提下可有效缩短模型的训练时间。但是单独使用 GRU 网络会丢失数据在高维空间中的联系, 故需要结合其他有相关能力的网络来提高对特征数据联系的挖掘能力。

基于此, 本文通过结合 CNN 与 GRU 的深度学习技术可以大幅改善 M3C 的故障诊断, 特别是当样本量大、模型之间的相似程度较高、分类数量较多的情况下可获得较为精确的结果, 而且具备较强的及时性, 通过实际应用验证了这一技术的可靠性。

1 模块化多电平矩阵变换器结构和子模块故障分析

1.1 模块化多电平矩阵变换器的拓扑结构

M3C 的拓扑结构如图 1 所示, 由 9 个桥臂连接输入和输出系统组成, $m_x(x=a, b, c)$ 为 a、b、c 三相输入; $g_y(y=r, s, t)$ 为 a、b、c 三相输出; L_{qb} 为桥臂电感, 每个桥臂内包含数个全桥子模块(sub module, SM); u_{xy} 为 xy 桥臂上 H 桥子模块输出电压; u_{cxy} 为 M3C 的 xy 桥臂总电容电压; i_{xy} 为 xy 桥臂上电流; SM_{xyk} 为 xy 桥臂上第 k 个 H 桥子模块, 其中 $x=a, b, c, y=r, s, t, k$ 为桥臂内子模块数量。本文建立了一个由 5 个子模块组成的桥臂拓扑结构, 桥臂内子模块拓扑结构见图 2; 子模块为全桥子模块结构, 见图 3, 内含有反向并联二极管, 使子模块故障发生时能够以二极管支路继续可靠运行。图 3 中, S1—S4 为 4 个 IGBT 管加上反并联二极管, U_{sm} 为子模块 SM 电压, U_c 为子模块 SM 的直流电容 C 上两端电压。

针对 M3C 故障诊断实用性研究的情况, 本文选用载波移相调制策略和 PI 控制方法以保障故障诊断的稳定性。

1.2 子模块故障分析

图 4 显示了 4 种类型的单 IGBT 开路每个 SM 中可能出现的故障。鉴于短路故障对电路危害较大且已有成熟的解决方案, 故本文不予考虑, 仅讨论 SM 中 IGBT 开路故障。且单个 IGBT 的故障可能不会牵连其他 IGBT 导致其故障, 这是一个相对独立的事




图 1 M3C 拓扑结构

Fig. 1 M3C topology structure




图 2 M3C 桥臂拓扑结构

Fig. 2 Topology structure of M3C bridge arm




图 3 全桥子模块内部结构

Fig. 3 Internal structure of the full bridge sub-module

件。因此, 多个 IGBT 在短时间内同时发生故障的概率极低, 故本文只讨论单一 IGBT 故障的情况。

当其中一个 IGBT 开路, 电流通路就会转换到反并联二极管, 在 S2、S4 的开关状态与 S1、S3 互补的前提下, 定义以 $S_H=(S1, S3)$ 来表示子模块的工作状态, i 为桥臂电流, 以 U_c 为参考值, 并且结合桥臂电流方向以及故障开关位置列出表 1。表 1 中的数字 1、0 分别表示关断、导通。

此外, 通过分析故障后 SM 的充电和放电状态, 任何 IGBT 的故障都会导致电容电压的上升趋势, 这可以用作定位故障 SM 的符号^[1]。然而, 与半桥 SM 不同, 无论哪个 IGBT 在全桥 SM 中出现故障,




图 4 全桥子模块故障模式

Fig. 4 Failure mode of the full-bridge sub-module

表 1 子模块 IGBT 开路故障工况

Tab. 1 IGBT open circuit fault conditions of sub-modules

子模块故障情况	正常	S1 故障	S2 故障	S3 故障	S4 故障
$S_H=(0,0), i>0$	0	0	U_c	0	0
$S_H=(0,1), i>0$	$-U_c$	$-U_c$	0	0	$-U_c$
$S_H=(1,0), i>0$	U_c	U_c	U_c	U_c	U_c
$S_H=(1,1), i>0$	0	0	0	U_c	0
$S_H=(0,0), i<0$	0	0	0	0	$-U_c$
$S_H=(0,1), i<0$	$-U_c$	$-U_c$	$-U_c$	$-U_c$	$-U_c$
$S_H=(1,0), i<0$	U_c	0	U_c	U_c	0
$S_H=(1,1), i<0$	0	$-U_c$	0	0	0

充电和放电电容器的路径仍然同时存在。因此, 发生故障的 SM 的电压不会严重偏离其额定值。当不同子模块发生开路故障时会引起电容在充电和放电两种模式中异常切换, 这种异常过程会导致输出端电流波形发生变化。然而这种变化的程度往往是细微的, 并且结合实际生产情况, 选取信号时将电流波形的三相信号均纳入故障特征提取过程是更利于故障特征识别的, 在后续实验验证过程中会分析不同故障情况下电流信号的区别以及故障数据集的形式。

2 基于 CNN-GRU 深度学习的故障诊断方法

基于 CNN-GRU 深度学习的故障诊断方法主要

流程包括：采集故障数据信号；小波包将信号分解取其高频分量；通过时序图像转换将高频信号转为二维故障图片；进行故障数据的预处理最后通过 CNN-GRU 深度学习方法分类训练及测试。整个处理流程如图 5 所示。




图 5 基于 CNN-GRU 深度学习的 M3C 故障诊断流程

Fig. 5 M3C fault diagnosis process based on CNN-GRU deep learning

本文提出的 M3C 故障诊断流程如下。

1) 进行 M3C 变换器的仿真，并通过断开对应调制信号来实现故障仿真，采集原始故障数据；

2) 使用小波包分析技术从故障波形中抽取低频与高频组分，以获得具备较强区分度的高频系数，然后利用时间序列图像处理技术，将这些系数以 8:1:1 的比例分割，构建出可供机器学习分析的数据模型，最后进行验证；

3) 建立以 CNN 为特征提取层，以 GRU 为训练分类层的深度学习网络，从而实现对故障数据的处理和分类；

4) 最终以迭代稳定后得到的故障诊断准确率以及达到稳定所需的迭代时间这 2 个参数来判定深度学习诊断效果的好坏。

2.1 小波包分解

在信号分析处理领域中，小波变换和小波包变换对非平稳非线性的电力电子信号分析有着显著优势，与小波变换相比，小波包变换^[18]在合理选取小波基与分解层数的条件下分解原始信号的高频和低频信息的相同条件下对高频信号进行更精细的分解，高频信号分解结果的分辨率更高，能够更有效地对电力电子信号进行分析。

图 6 为 3 层小波包分解 (wavelet packet decomposition, WPD) 的树状结构拓扑。图 6 中每个树杈的左侧为低频分量，对应的右侧为高频分量。经过小波包变换分离出的信号中高频信号更能表现出故障特征，故本文均选取位于第 3 层的 (3, 5)、(3, 7) 高频信号进行后续分析。




图 6 小波包分解结构

Fig. 6 Wavelet packet decomposition structure

2.2 时间序列图像转换

当深度学习使用一维时间序列作为研究目标时，由于其具有一定的复杂性，因此，本文采用卷积神经网络 CNN 作为其前置层，并引入格莱姆角积分矩阵 (Gramian angular summation field, GASF)^[19]来有效地转换一维数据到二维图像，进一步发挥卷积神经网络的高维度卷积能力，有效地解决了一维时间序列的训练问题，并有效地改善了深度学习的性能。通过剔除人工筛查的故障信息大大增强了故障诊断的准确率。

给定一个一维序列 $[x_1, x_2, \dots, x_n]$ ，对其进行归一化，满足区间 $[-1, 1]$ ，公式如下。

$$\tilde{x}_i = [x_i - \max(X) + (x_i - \min(X)) / [\max(X) - \min(X)]] \quad (1)$$

$$\tilde{X} = [\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n] \quad (2)$$

通过归一化处理本文可以将时间序列 X 转换成极坐标系的形式。

$$\begin{cases} \phi_i = \arccos \tilde{x}_i, & -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r_i = t_i / N, & t_i \in N \end{cases} \quad (2)$$

式中： ϕ_i 、 r_i 分别为极坐标系的极角、极径； t_i 为时间标记； N 为极坐标系跨度的正则化常数，将区间

$[-1, 1]$ 分为 N 等份。定义格莱姆角求和矩阵 (GASF) 如下:

$$M_{\text{GASF}} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_N) \\ \cos(\phi_1 + \phi_2) & \cdots & \cos(\phi_2 + \phi_N) \\ \vdots & \ddots & \vdots \\ \cos(\phi_N + \phi_2) & \cdots & \cos(\phi_N + \phi_N) \end{bmatrix}$$

$$= \tilde{X}' \cdot \tilde{X} - \sqrt{I - \tilde{X}'^2} \cdot \sqrt{I - \tilde{X}^2} \quad (3)$$

式中: $\tilde{X}'$ 为 $\tilde{X}$ 的转置; I 为单位向量 $[1, 1, \dots, 1]$ 。

2.3 卷积神经网络

卷积神经网络 (CNN) 作为一种人工神经网络在深度学习领域得到广泛应用, 其输入对象为多维向量组, 采用感受野与权重分配的模式。其中, CNN 通过卷积运算抽取原始数据的特征, 并对其进行内部联系的探索; CNN 具有局部连接、权值共享和池化操作等特性, 缩小了网络的复杂度和训练参数; 此外, CNN 的全连接层还会将抽取的特征参数进行归类。本文将 CNN 与 GRU 结合分工完成对故障数据的分类处理, CNN 作为整个深度学习的前端网络层主要将故障图片进行卷积池化处理, 从而在高维空间分解出能够被 GRU 识别的故障特征张量, 然后将特征张量传递给 GRU 进行分类训练。

2.4 门控循环单元神经网络

门控循环单元 (GRU) 是长短期记忆 (LSTM) 神经网络在计算量方面的改良网络, 更新门替代了原有的遗忘门和输入门, 引入隐藏状态与神经元状态相结合, 原本存在于 CNN 中的“梯度消失”问题得以缓解, 在不影响诊断准确率的前提下能够有效减少训练参数以提高训练效率^[20]。

LSTM 长短时记忆网络如图 7 所示, 由图 7 可见, LSTM 通过引入了 3 个门来控制信息的传递, 分别是遗忘门 f_t 、输入门 i_t 和输出门 o_t (下标 t 表示当前时刻)。3 个门的作用分别为:

- 1) 遗忘门控制上一时刻 $t-1$ 的内部状态需要遗忘多少信息;
- 2) 输入门控制当前时刻 t 的候选状态有多少信息需要保存;
- 3) 输出门控制当前时刻 t 的内部状态有多少信息需要输出给外部状态。




图 7 LSTM 长短时记忆网络

Fig. 7 Long short term memory network of LSTM

$$\begin{cases} i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \\ f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \\ g_t = \tanh(W_{gx}x_t + W_{gh}h_{t-1} + b_g) \\ o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \\ c_t = f_t \otimes c_{t-1} + i_t \otimes g_t \\ h_t = o_t \otimes \tanh(c_t) \end{cases} \quad (5)$$

式中: t 为当前时刻; i_t 为输入门; f_t 为遗忘门; g_t 为细胞单元; o_t 为输出门; c_t 为细胞状态; h_t 为隐藏状态; x_t 为当前时刻输入信息; W_{pq} 为 p 与 q 连接的权重, p 与 q 的取值为 f、i、o、x、g、h, 分别表示遗忘门、输入门、输出门、输入信息、细胞单元、隐藏状态; b_s 为控制门 s 的偏置参数; σ 为 sigmoid 函数, 得到一个在 0~1 范围的门控信号; $\tanh$ 为激活函数。

GRU 单元结构如图 8 所示, GRU 将遗忘门和输入门整合, 称之为“更新门(update gate)” z_t , 同时配以一个“重置门(reset gate)” r_t 。更新门控制当前状态 h_t 需要从上一时刻状态 h_{t-1} 中保留多少信息以及需要从候选状态中接受多少信息。重置门用来控制候选状态的计算是否依赖上一时刻的 h_{t-1} 。

$$\begin{cases} r_t = \sigma(W_{rx}x_t + W_{rh}h_{t-1} + b_r) \\ z_t = \sigma(W_{zx}x_t + W_{zh}h_{t-1} + b_z) \\ n_t = \tanh(W_{nx}x_t + W_{nh}h_{t-1} + b_n) \\ h_t = (1 - z_t)n_t + z_th_{t-1} \end{cases} \quad (6)$$

式中: r_t 为重置门; z_t 为更新门; n_t 为新门; 下标 r 、 z 、 n 分别为重置门、更新门、新门。

从式 (6) 可以看出, GRU 以更新门 z_t 可以同时完成遗忘和记忆两种功能, 比 LSTM 参数量直观减少了 3/4, 故计算量和运算时间也就缩小了 1/4。并且 GRU 直接使用更新门来控制输入和遗忘的平衡, 相较于 LSTM 更简洁。

本文提出将 CNN 与 GRU 结合组建深度学习框架, 其中的 GRU 部分结构如图 9 所示。




图 8 GRU 门控单元结构

Fig. 8 Structure of GRU gating unit




图 9 3层 GRU 网络结构

Fig. 9 Three-layer GRU network structure

2.5 粒子群优化 GRU 超参数设置

GRU 网络在使用前需确定其中学习率、迭代次数以及网络层数等超参数，为了更好地优化这些参数，采用粒子群算法 (particle swarm optimization, PSO) 对其进行优化^[21]，具体步骤如下。

1) 对 PSO 进行初始化，设置粒子群数量为 120，迭代次数为 60，搜索维度 $d=6$ ，通过迭代更新寻找最优解；

2) 对粒子群的位置和速度进行初始化设置，随机生成第 i 个粒子的位置为 $X_i = (l, m, h)$ ， l 为初始学习率，区间为 $[0.001, 0.1]$ ； m 为 GRU 算法的迭代次数，区间为 $[10, 200]$ ； h 为 GRU 网络层数，区间为 $[2, 5]$ ；

3) 选定适应度函数如下。

$$f(y) = \frac{1}{B} \sum_{i=1}^B (y(i) - y'(i))^2 \quad (7)$$

式中： $y(i)$ 为实际结果； $y'(i)$ 为预测结果； $f(y)$ 为适应度函数； B 为 y 的数量。

4) 在每一次迭代中对粒子群的位置和速度进行更新，粒子 o 在 D 维空间的位置 s_o 和速度 v_o 公式如下。

$$\begin{cases} s_o = (s_{o,1}, s_{o,2}, \dots, s_{o,D}) \\ v_o = (v_{o,1}, v_{o,2}, \dots, v_{o,D}) \end{cases} \quad (8)$$

式中： D 为粒子 o 的空间维度； $s_{o,D}$ 、 $v_{o,D}$ 分别为粒子 o 在第 D 维的位置和速度。

粒子速度更新公式为：

$$v_{o,d}^{h+1} = \bar{\omega} v_{o,d}^h + c_1 \eta (P_{o,d}^h - s_{o,d}^h) + c_2 \eta (G_d^h - s_{o,d}^h) \quad (9)$$

位置更新公式为：

$$s_{o,d}^{h+1} = s_{o,d}^h + v_{o,d}^{h+1} \quad (10)$$

式中： $o=1, 2, \dots, O$ ； h 为迭代数量； $\bar{\omega}$ 为惯性因子； $v_{o,d}^h$ 为粒子 o 在第 h 次迭代中在 d 维的速度； c_1 、 c_2 为学习因子； η 为 $[0, 1]$ 之间的随机数； $P_{o,d}^h$ 为第 h 次迭代中粒子 o 在 d 维的位置； $s_{o,d}^h$ 为第 h 次迭代的 o 在 d 维的当前位置； G_d^h 为第 h 次迭代中在 d 维的全局极值的位置。

通过反复迭代后得到关于初始学习率 l 、GRU 算法的迭代次数 m 、GRU 网络层数 h 这 3 个使得 GRU 网络能够发挥最好性能的超参数。

3 M3C 子模块故障诊断仿真实验

本实验基于如下环境进行：Intel i7-8750H 处理器、Nvidia-GTX-1050Ti 显卡。并使用 Python3.9 来开发深度学习网络，深度学习架构由 Pytorch、Tensorflow 两个框架组成。

3.1 数据采集与处理

在 MATLAB 的 Simulink 中搭建了图 1 所示的模块化多电平矩阵变换器拓扑结构的仿真模型，采用载波移相调制策略控制开关管的开断，并采用 PI 控制环流电压和电流，断开子模块中 IGBT 触发信号模拟开路故障。该实验将直流侧电压分别设为 10 kV、12.5 kV、15 kV，采样频率设置为 20 kHz。

在 1 个周期中，本文收集了三相线电流信息，并依次进行了处理。在不同的故障模式中收集了 60 个样本，并对共 180 种故障情况使用了 0、1、2、 $\dots$ 、180 的样本标签标记。最终得到了 10 800 组原始数据。根据 8 : 1 : 1 的比例分别进行了训练、测试和验证。为了便于描述故障类别，本文以 xy -SM k -S z 的形式来表示故障的具体位置， xy 为对应的 9 个桥臂 ($x=a, b, c; y=r, s, t$)， k 为子模块的编号，本文 $k=1, 2, 3, 4, 5$ ， z 为子模块内对应 IGBT 的编号， $z=1, 2, 3, 4$ 。对正常无故障工况、ar-SM1-S1 故障工况和 ar-SM1-S2 故障工况 3 种工况的采样方式如表 2

所示, 且这 3 种工况下的同一相输出电流波形如图 10 所示。

表 2 部分故障类别样本标签

Tab. 2 Sample labels for partial fault categories

故障类别	样本标签	直流侧电压值/V	采样数量
正常无故障	0	10 000	20
		12 500	20
		15 000	20
ar-SM1-S1 故障	1	10 000	20
		12 500	20
		15 000	20
ar-SM1-S2 故障	2	10 000	20
		12 500	20
		15 000	20

由图 10 可见, 在放大波峰处波形后可以观测到不同情况下波形的细微区别, 但很难全部分辨出所有故障模式波形上的区别, 由于模块化逆变器拓扑具有对称性, 其他桥臂中难以避免存在多种相似波形的情况。但对 3 种波形先进行一次单层小波分解, 提取高频系数如图 11 所示, 从图 11 发现 3 者区别, 说明借助合适的小波分解方法可以观测到时频域的细小差别。

通过使用 3 层小波包分解技术可以提取出原始信号的高频特征。然后, 使用格莱姆角求和矩阵 (GASF) 来实现对这些特征的二维化。在图 6 中的 3 种工况下经过 WPD 和 GASF 的处理得到了如图 12 所示的结果。为便于后续深度学习, 图片的像素设置为 $3 \times 128 \times 128$, 观察图片可知, 在经过 3 层 WPD 后提取得到的高频系数再配合上时序图像转换, 可以更好地观测和记录到不同故障情况下的波形区别, 并且图像形式的故障数据集更有利于与深度学习训练的结合, 能够更有效地提高诊断准确率和效率, 经过对以 (3, 5) 和 (3, 7) 两种高频信号为输入情况下诊断效果的对比, 最终选择 (3, 5) 为深度学习网络的输入信号, 对比结果如表 3 所示。

3.2 CNN-GRU 网络模型的搭建

将 $3 \times 128 \times 128$ 大小的故障图片输入到 CNN 网络中。CNN 网络由 3 个卷积池化层构成, 卷积和数量依次设置为 32、32、64, 卷积步长设为 1, 卷积方式选取 Same 卷积, 激活函数选用 relu 函数。经 3 次卷积池化运算后, 得到 $64 \times 16 \times 16$ 的张量, 将此张量作为 GRU 的输入, 设置 GRU 层的输入层为




图 10 M3C 仿真电流波形对比

Fig. 10 Comparison of M3C simulation current waveforms

64, 每个输入具有 16×16 的序列长度, 隐藏层设置为 1 024, 批大小设置为 32, 故障分类共 180 种, 故最后通过全连接层的输出层节点设置为 180, 模型采用 Adam 优化损失函数^[22-25], 通过动态调整和自适应学习率来实时调整每一个神经元的权重和误




图 11 小波包分解高频系数图

Fig. 11 High-frequency coefficient diagrams of wavelet packet decomposition

差, 以使损失函数的输出效果达到最佳。GRU 的超参数经过 PSO 训练优化后为: 初始学习率 $l=0.004$, GRU 算法的迭代数量 $m=60$, GRU 网络层数量 $h=3$ 。对应详细参数如表 4 所示。

3.3 不同深度学习模型故障诊断效果对比

为了说明本文所提 CNN-GRU 深度学习网络用于 M3C 故障的优势, 本文还与 LSTM、CNN、LSTM-CNN 和单独 GRU 共 4 种其他方法进行对比仿真, 仿真对比实验结果如图 13 和表 5—6 所示。

图 13 中, 横坐标为逐次累加的迭代时间, LSTM 网络模型由 3 层 LSTM 单元构成; GRU 网络模型由 3 层 GRU 单元构成; CNN 由 5 层卷积池化层构成, CNN-LSTM 模型中 CNN 架构与本文所提



(a) 正常 GASF 图



(b) ar-SM1-S1故障 GASF 图



(c) ar-SM1-S2故障 GASF 图

图 12 部分信号转 GASF 图片

Fig. 12 Partial signals to GASF pictures

表 3 不同高频信号输入诊断效果对比

Tab. 3 Comparison of diagnostic effects of different high-frequency signal inputs

信号节点	诊断准确率/%	训练时间/s
(3,5)	98.10	35.4
(3,7)	97.56	36.9

CNN-GRU 模型中 CNN 架构相同。由图 13、表 5—6 可见, 与 CNN-LSTM、GRU、LSTM、CNN 4 种其他模型相比, 本文提出的 CNN-GRU 深度学习模型诊断准确率分别提高了 0.56%、0.97%、1.41%、2.20%, 损失函数值分别降低了 0.000 5、0.005 7、0.008 3、0.011 8, 训练时间分别缩短了 10.11 s、3.85 s、13.33 s、19.09 s, 测试时间分别缩短了 0.11 s、0.03 s、0.18 s、0.24 s。

表 4 CNN-GRU 网络参数设置
Tab. 4 CNN-GRU network parameter settings

层	卷积核	输出尺寸	批大小	初始学习率	迭代数量
输入		3×128×128			
卷积层 1	32×3×3	32×128×128			
池化层 1	32×2×2	32×64×64			
卷积层 2	32×3×3	32×64×64			
池化层 2	32×2×2	32×32×32	32	0.004	60
卷积层 3	64×3×3	64×32×32			
池化层 3	64×2×2	64×16×16			
GRU 层		(64, 1 024, 3)			
输出		180			




图 13 不同深度学习模型诊断效果对比

Fig. 13 Comparison of diagnostic effects of different deep learning models

表 5 不同深度学习模型诊断结果比较

Tab. 5 Comparison of diagnostic results of different deep learning models

故障诊断深度学习模型	诊断准确率/%	损失函数值
CNN-GRU	98.10	0.015 8
GRU	97.13	0.021 5
LSTM	96.69	0.024 1
CNN	95.90	0.027 6
CNN-LSTM	97.54	0.016 3

表 6 不同深度学习模型诊断效率比较

Tab. 6 Comparison of diagnostic efficiencies of different deep learning models

故障诊断深度学习模型	训练时间/s	测试时间/s
CNN-GRU	35.40	0.24
GRU	39.25	0.27
LSTM	48.73	0.42
CNN	54.49	0.48
CNN-LSTM	45.51	0.35

4 结论

本文在对 M3C 进行故障诊断时提出了一种基于 CNN-GRU 深度学习框架的诊断方法, 首先使用小波包分解对故障信号进行分解, 再使用时序转换方法得到二维故障图片, 通过 CNN 卷积池化提取出特征张量, 再利用 GRU 对其进行训练分类, 得出最终诊断结果。通过分析实验可归纳出如下结论。

1) 利用小波包分解和时序图像转换方法得到的二维故障图片能够很好地适用于 CNN 网络, 充分发挥 CNN 网络在特征提取方面的优势。

2) 使用 GRU 网络能在减少运算参量的特性下高效完成特征数据的训练和分类任务。

3) CNN-GRU 深度学习框架可以充分利用 CNN 和 GRU 的强大功能, 大大改善故障诊断的效率。相比于传统的 4 种深度学习技术, 本文的 CNN-GRU 深度学习方法可以显著地提升故障检测的准确性和检测的速度。

参考文献

[1] WANG C, ZHENG Z, WANG K, et al. Fault detection and tolerant control of IGBT open-circuit failures in modular multilevel matrix converters [J]. IEEE Journal of Emerging in Power Electronics, 2022, 10(6): 31 – 42.

[2] 余冰, 程尹曼, 程启明, 等. MMC 两侧电流基于 Lyapunov 函数的控制策略 [J]. 南方电网技术, 2024, 18 (3): 45 – 55.

YU Bing, CHENG Yinman, CHENG Qiming, et al. Lyapunov function based control strategy for bilateral currents of modular multilevel matrix converter [J]. Southern Power System Technology, 2024, 18 (3): 45 – 55

[3] 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.

[4] 荣飞, 朱语博, 周诗嘉, 等. 基于子模块电压分组检测的 MMC 子模块开路故障诊断定位方法 [J]. 电力自动化设备, 2020, 40(12): 127 – 133.

RONG Fei, ZHU Yubo, ZHOU Shijia, et al. Sub-module open fault diagnosis and location method of MMC based on sub-module voltage packet detection [J]. Electric Power Automation Equipment, 2020, 40(12): 127 – 133.

[5] HAGHNAZARI S, KHODABANDEH M, ZOLGHADRI M R. Fast fault detection method for modular multilevel converter semiconductor power switches [J]. IET Power Electronics, 2016, 9(2): 165 – 174.

[6] 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.
- [7] 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.
- [8] LI Binbin, SHI Shaolei, WANG Bo, 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.
- [9] ZHOU Dehong, QIU Huan, YANG Shunfeng, et al. Sub module voltage similarity-based open circuit fault diagnosis for modular multilevel converters[J]. IEEE Transactions on Power Electronic, 2019, 34(8): 8008 – 8016.
- [10] 刘玉林, 齐静静, 李家宁, 等. 一种基于桥臂电流畸变及自适应观测的 MMC 子模块开路故障诊断定位方法[J]. 电源学报, 2020, 18(3): 106 – 115.
- LIU Yulin, QI Jingjing, LI Jianing, et al. Diagnosis and location method for open-circuit fault in MMC sub-module based on bridge arm current distortion and adaptive observation [J]. Journal of Power Supply, 2020, 18(3): 106 – 115.
- [11] HU Xing, ZHANG Jianzhong, XU Shuai, et al. Detection and location of open-circuit fault for modular multi level converter [J]. International Journal of Electrical Power & Energy Systems, 2020(115): 105425 – 105435.
- [12] 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 Industrial Electronics, 2023, 70(1): 112 – 124.
- [13] 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.
- [14] 尹桥宣, 段斌, 沈梦君, 等. 模块化五电平逆变器子模块开路故障的智能诊断方法[J]. 电力系统自动化, 2018, 42(12): 127 – 133.
- YIN Qiaoxuan, DUAN Bin, SHEN Mengjun, et al. Intelligent diagnosis method for open-circuit fault of sub-modules in modular five-level inverter[J]. Automation of Electric Power Systems, 2018, 42(12): 127 – 133.
- [15] 袁建虎, 韩涛, 唐建, 等. 基于小波时频图和 CNN 的滚动轴承智能故障诊断方法[J]. 机械设计与研究, 2017, 33(2): 93 – 97.
- YUAN Jianhu, HAN Tao, TANG Jian, et al. An approach to intelligent fault diagnosis of rolling bearing using wavelet time-frequency representations and CNN [J]. Machine Design and Research, 2017, 33(2): 93 – 97.
- [16] 柯龙章. 基于信号处理与深度学习的模块化多电平换流器故障诊断研究[D]. 武汉: 武汉大学, 2021.
- [17] 曾昭璐, 何怡刚. 基于 SE-DSCNN 的 MMC 开关管故障诊断方法[J]. 电力自动化设备, 2022, 42(5): 104 – 111.
- ZENG Zhaorong, HE Yigang. Fault diagnosis method for switches in MMC based on SE-DSCNN [J]. Electric Power Automation Equipment, 2022, 42(5): 104 – 111.
- [18] 栾孝驰, 李彦微, 徐石, 等. 基于小波包变换与 CEEMDAN 的滚动轴承故障诊断方法[J]. 航空动力学报, 2024, 39(5): 159 – 173.
- LUAN Xiaochi, LI Yanzheng, XU Shi, et al. Rolling bearing fault diagnosis method based on wavelet packet transform and CEEMDAN [J]. Journal of Aerospace Power, 2024, 39(5): 159 – 173.
- [19] 张辉, 戈宝军, 韩斌, 等. 基于 GAF-CapsNet 的电机轴承故障诊断方法[J]. 电工技术学报, 2023, 38(10): 2675 – 2685.
- ZHANG Hui, GE Baojun, HAN Bing, et al. Motor bearing fault diagnosis method based on GAF-CapsNet [J]. Transactions of China Electrotechnical Society, 2023, 38(10): 2675 – 2685.
- [20] 刘建伟, 宋志妍. 循环神经网络研究综述[J]. 控制与决策, 2022, 37(11): 2753 – 2768.
- LIU Jianwei, SONG Zhiyan. Overview of recurrent neural networks [J]. Control and Decision, 2022, 37(11): 2753 – 2768.
- [21] 王鹏程, 邓艾东, 陵峰, 等. 基于 PSO-SEBD 的风电机组滚动轴承故障诊断[J]. 振动与冲击, 2023, 42(7): 281 – 288.
- WANG Pengcheng, DENG Aidong, LING Feng, et al. Fault diagnosis of rolling bearing of wind turbine generator based on PSO-SEBD [J]. Journal of Vibration and Shock, 2023, 42(7): 281 – 288.
- [22] 杨观赐, 杨静, 李少波, 等. 基于 Dropout 与 ADAM 优化器的改进 CNN 算法[J]. 华中科技大学学报(自然科学版), 2018, 46(7): 122 – 127.
- YANG Guanci, YANG Jing, LI Shaobo, et al. Modified CNN algorithm based on dropout and ADAM optimizer [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2018, 46(7): 122 – 127.
- [23] 李帅, 徐迪, 文祥宇, 等. 面向配电网多业务资源智能调度的边缘容器迁移优化方法[J]. 中国电力, 2023, 56(9): 120 – 126.
- LI Shuai, XU Di, WEN Xiangyu, et al. An edge container migration optimization method for multi-service intelligent resource scheduling of distribution networks [J]. Electric Power, 2023, 56(9): 120 – 126.
- [24] 张程, 罗玉锦, 陈昌亮. 考虑源荷不确定的多园区微网与共享储能电站协同优化运行[J]. 电力系统保护与控制, 2023, 51(24): 77 – 89.
- ZHANG Cheng, LUO Yujin, CHEN Changliang. Collaborative optimization operation of multi park microgrids and shared energy storage power stations considering source load uncertainty [J]. Power System Protection and Control, 2023, 51(24): 77 – 89.
- [25] 王雅雯. 基于需求侧响应的风光储微电网经济优化研究[J]. 广东电力, 2023, 36(9): 10 – 16.
- WANG Yawen. Research on economic optimization of wind and solar energy storage microgrid based on demand response [J]. Guangdong Electric Power, 2023, 36(9): 10 – 16.

收稿日期: 2023-06-21; 网络首发日期: 2023-11-20

作者简介:

朱晋(1995), 男, 硕士研究生, 研究方向为电力电子控制、电力故障诊断, 313049545@qq.com;

程启明(1965), 男, 通信作者, 教授, 博士, 研究方向为电力系统自动化、发电过程控制、先进控制及应用, chengqiming@sina.com;

程尹曼(1990), 女, 工程师, 硕士, 研究方向为电力系统自动化、电力运维和电力营销, chengyinman@hotmail.com。