

doi:10.3969/j.issn.1673-9833.2021.05.002

基于 EMD-CNN 的光伏逆变器开路故障诊断

孟献蒙^{1,2}, 郭兴众^{1,2}, 程凡永^{1,2}, 陈旺斌³, 方骏仁^{1,2}

(1. 安徽工程大学 高端装备先进感知与智能控制教育部重点实验室, 安徽 芜湖 241000;
2. 安徽工程大学 电气传动与控制安徽省重点实验室, 安徽 芜湖 241000;
3. 铜陵有色股份铜冠电器有限公司, 安徽 铜陵 244001)

摘要: 绝缘栅双极型晶体管 (IGBT) 是光伏逆变器的核心部件, 其若发生开路故障, 不但会影响光伏逆变系统的稳定运行, 且可能会损坏系统设备。从减少传感器使用数量和融合多尺度特征的角度出发, 对开路故障诊断问题进行了研究, 提出了一种基于经验模式分解 (EMD) 和二维卷积神经网络 (2D-CNN) 的光伏逆变器故障诊断新方法。该方法利用 EMD 提取电流信号的本征模函数分量和原始信号组成二维特征数据, 然后将该数据输入 2D-CNN 模型中进行训练, 最后实现 IGBT 开路故障的诊断。实验结果表明, 该方法不仅能提高故障诊断的准确率, 而且在噪声环境下具备有效性和鲁棒性。

关键词: IGBT; 光伏逆变器; 多尺度特征; 经验模式分解; 二维卷积神经网络

中图分类号: TM769

文献标志码: A

文章编号: 1673-9833(2021)05-0010-08

引文格式: 孟献蒙, 郭兴众, 程凡永, 等. 基于 EMD-CNN 的光伏逆变器开路故障诊断 [J]. 湖南工业大学学报, 2021, 35(5): 10-17.

Open-Circuit Fault Diagnosis of Photovoltaic Inverters Based on EMD-CNN

MENG Xianmeng^{1,2}, GUO Xingzhong^{1,2}, CHENG Fanyong^{1,2}, CHEN Wangbin³, FANG Junren^{1,2}

(1. Key Laboratory of Advanced Perception and Intelligent Control for High-End Equipment, Anhui Polytechnic University, Wuhu Anhui 241000, China; 2. Anhui Key Laboratory of Electric Drive and Control, Anhui Polytechnic University, Wuhu Anhui 241000, China; 3. Tongling Nonferrous Metals Tongguan Electric Co., Ltd., Tongling Anhui 244001, China)

Abstract: As the core component of the photovoltaic inverter, insulated gate bipolar transistor (IGBT) will not only affect the stable operation of photovoltaic inverter system in case of an open circuit fault occurrence, but also damage the system equipment as well. In view of a reduction of the number of sensors and fuse multi-scale features, a new fault diagnosis method has thus been proposed for the photovoltaic inverter based on empirical mode decomposition (EMD) and two-dimensional convolution neural network (2D-CNN). The proposed method uses EMD to extract the intrinsic mode function component of current signal and the original signal so as to form two-dimensional feature data, with the data subsequently input into the 2D-CNN model for training, thus finally realizing the open circuit fault diagnosis of IGBT. Experimental results show that this method helps to improve the accuracy of fault diagnosis, characterized with a better performance of both effectiveness and robustness in a noisy environment.

Keywords: IGBT; photovoltaic inverter; multi-scale feature; empirical mode decomposition; 2D-CNN

收稿日期: 2020-12-07

基金项目: 国家自然科学基金资助项目 (61976005); 安徽省教育厅基金资助重点项目 (KJ2019A0149); 福建省教育厅基金资助项目 (JAT170457)

作者简介: 孟献蒙 (1994-), 男, 安徽阜阳人, 安徽工程大学硕士生, 主要研究方向为故障诊断,
E-mail: 2180210111@stu.ahpu.edu.cn

通信作者: 郭兴众 (1962-), 男, 安徽阜阳人, 安徽工程大学教授, 硕士生导师, 主要从事智能控制理论, 电力传动和系统建模与仿真方面的教学与研究, xzguo@ahpu.edu.cn

1 研究背景

近年来,随着石油、天然气等不可再生资源的日益消耗,越来越多的国家开始进行低碳能源转型^[1]。在可再生、低碳能源生产中,太阳能光电技术显现出小规模能源生产的巨大潜力^[2]。2005年以来,中国光伏制造产业发展迅速,并于2007年超过日本,成为世界上最大的光伏组件制造国^[3]。截至2017年,中国、美国、印度、德国、日本等国家积极部署太阳能光伏产业,并已经在光伏市场中占主导地位^[4]。未来太阳能光伏在全球各个国家低碳能源产业中继续具有重要的战略地位。而逆变器是光伏发电系统中的核心部件,其一旦发生故障,不仅会影响系统的正常运行,而且可能会对设备造成不可估量的损失。因此,开展光伏逆变器的故障诊断研究在设备损耗和降低成本投入以及逆变器保护等方面有着至关重要的意义。

目前,关于逆变器的故障诊断方法大体上可以分为如下3类:基于参数辨识的方法、基于物理信号分析的方法和基于人工智能的方法。文献[5]通过对实测电流-电压($I-V$)曲线进行参数辨识,以识别并且发现故障。文献[6]通过采集三相电压逆变器的输出电流信号,然后根据电流矢量的瞬时频率特征和瞬时角度特征的变化来进行故障诊断。文献[7-8]利用小波包分解和主成分分析法实现了故障诊断,其中,文献[7]基于极端学习机实现了单器件及多器件开路等多种故障诊断,文献[8]基于径向基神经网络对NPC三电平逆变器开路故障进行了诊断。但是这些故障诊断方法都需要专业的物理知识和复杂的特征提取工程,不具备强的通用性。近年来,随着人工智能技术的发展,越来越多的深度学习技术被广泛地应用于逆变器的故障诊断中。文献[9]针对光伏组件中各种类型的故障,采用多层感知器来识别发生故障的类型和位置,但由于特征区分能力的限制,该方法不能有效地诊断不显著的故障类型。文献[10]为提高特征区分能力,采集了电压、电流和速度的变化信号,利用神经网络和遗传算法相结合的结构,对感应电动机电压源逆变器故障进行了诊断。尽管该方法提高了故障诊断率,但是需要3个传感器采集数据,增加了设备的投入。

为减少传感器的使用数量和提高特征区分能力,本文提出一种基于经验模式分解(empirical mode decomposition, EMD)和二维卷积神经网络(two-dimensional convolutional neural network, 2D-CNN)结合的故障诊断方法。该方法首先使用一个传感器采

集光伏逆变器的直流侧电流信号,采用EMD提取电流中的多个本征模函数与原始数据组成的二维特征图作为2D-CNN的输入;然后,利用2D-CNN进行特征提取;最后,用2D-CNN模型对多类开路故障进行诊断和分类。

2 光伏发电系统分析

2.1 光伏发电系统

光伏发电系统利用电池组件将太阳能直接转变为电能。在光照条件下,太阳电池组件产生一定的电动势,通过组件的串并联形成太阳能电池方阵,使得光伏阵列的电压达到系统输入电压的要求。光伏发电系统的主电路拓扑结构如图1所示,左侧由光伏阵列产生直流输入,经过逆变器输出三相电流和电压。图中 R 、 L 分别是电阻和电感, C 是电容, $T1\sim T6$ 为6个绝缘栅双极型晶体管(insulated gate bipolar transistors, IGBT), $S1\sim S6$ 是6个开关,系统通过调制电路来控制IGBT的导通。

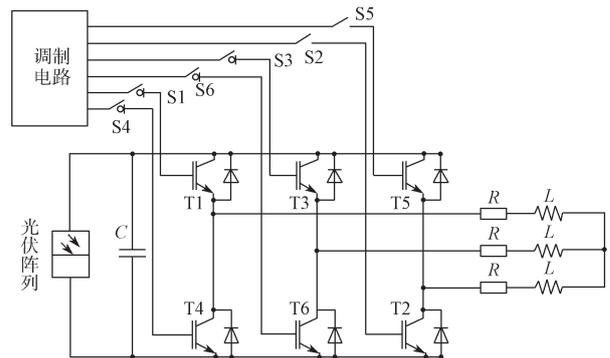


图1 光伏发电系统主电路拓扑结构

Fig. 1 Topological structure of main circuit of the photovoltaic power generation system

2.2 常见故障类型

逆变器的故障可以分为IGBT短路故障和IGBT开路故障两类^[11]。IGBT短路因时间短暂可以在电路上直接进行处理,目前已经有相当成熟的解决方法^[12]。当一个或两个IGBT发生开路时,会导致逆变器不能正常导通。如果同一时间内有更多的IGBT开路,则此时逆变器早已不能正常工作,对于研究已无意义。因此文中的研究对象为一个或两个IGBT开路故障。如图1所示,当电路中一个开关断开的情况下,将会出现单管故障,共6种情况($T1\sim T6$ 分别开路)。当电路中两个开关断开情况下,将会出现两管故障,而两管故障又分3种情况:同一相的两个功率管开路故障,例如 $T1$ 和 $T4$,共3种;同一半桥的两个功率管开路故障,例如 $T1$ 和 $T3$,共6种;交叉

的两个功率管开路故障，例如 T1 和 T6，共 6 种。把正常情况归为一类，则 IGBT 开路故障的类型为 22 种。

3 多模态信号分解与特征提取

3.1 经验模式分解

经验模式分解 (EMD)，又可以称为 Hilbert-Huang 变换 (Hilbert-Huang transform, HHT) [13]，它是一种新型自适应信号时频处理方法。经验模式分解能够从单个信号中提取多尺度特征，特别适用于非线性、非平稳信号的分析处理之中 [14]。EMD 能够使复杂信号分解为有限个本征模函数 (intrinsic mode function, IMF) 和一个残余项 (res) 之和，所分解出来的各 IMF 分量包含了原信号的不同时间尺度的局部特征信号。

EMD 的基本分解流程如下：

- 1) 获取原始时间序列 $x(t)$ 的极值点；
- 2) 采用三次样条插值函数拟合形成原数据的上包络 $x_1(t)$ 和下包络 $x_2(t)$ ，计算包络均值 $m(t)$ ，

$$m(t) = [x_1(t) + x_2(t)] / 2; \quad (1)$$

- 3) 计算新序列 $h(t)$ ，

$$h(t) = x(t) - m(t); \quad (2)$$

- 4) 判断 $h(t)$ 是否满足 IMF 的两个条件；

5) 如果不是，则以 $h(t)$ 代替 $x(t)$ ，重复以上步骤，直到 $h(t)$ 满足判据，则 $h(t)$ 就是需要提取的 IMF；

6) 每得到一阶 IMF，就从原信号中去除它，重复以上步骤，直到信号最后剩余部分就只是单调序列或者常值序列。

这样，经过 EMD 分解，将原始信号 $x(t)$ 分解成高频到低频的 IMF 分量的线性组合和残余项 $r(t)$ ；

$$x(t) = \sum_{i=1}^M c_i(t) + r(t). \quad (3)$$

式中： $c_i(t)$ 为第 i 个 IMF 分量；

$r(t)$ 为残余项，不包含信号的震荡模态，只反映信号的变化趋势。

前面几个高频的 IMF 分量包含了原始信号中显著且重要的特征信息。

3.2 卷积神经网络

3.2.1 卷积层

卷积层用到了数学运算 - 卷积，卷积是一种特殊的线性运算，用来替代一般的矩阵乘法运算。卷积运算的数学公式如下：

$$y(i, j) = (X * W)(i, j) = \sum_m \sum_n X(i-m, j-n) W(m, n). \quad (4)$$

式中： X 为二维矩阵；

W 为权重参数，它可以是一个或多个二维矩阵；

$y(i, j)$ 为卷积运算的输出；

$*$ 为卷积运算符号。

在 CNN 中，除了权重参数，还存在偏置。滤波器的参数就对应之前的权重。具体的卷积层运算如图 2 所示，有一个 3*3 的卷积核，卷积核都与输入信号进行卷积运算。卷积核滑动步长为 1，卷积核为 3*3，输入数据为 4*4，经过卷积运算后，加上相对应的偏置，经过激活函数激活后就得到了大小为 2*2 的输出特征图。

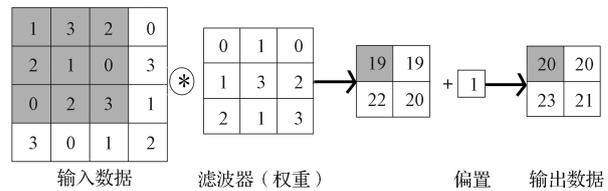


图 2 卷积运算示例

Fig. 2 Illustration of convolution operation

3.2.2 池化层

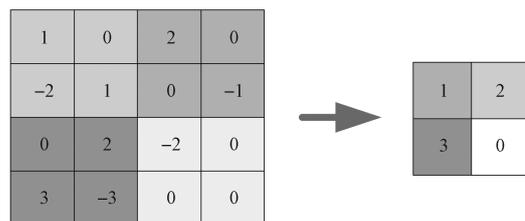
理论上来说，所有经过卷积层获取的特征都可以直接输入到分类器中，但是巨大的计算量是一个难题。为了解决这个问题，一般会使用池化层来减少卷积计算中的冗余特征。池化层会将平面内某一位置及其相邻位置的特征值进行聚合统计 (降采样)，并且将聚合后的结果作为这一位置在该平面内的值。假设第 $l-1$ 层为池化层的上一层卷积层，第 l 层为池化层，则可以得到从第 $l-1$ 层到第 l 层的最大池化传播公式如下：

$$y^l = \sigma(\text{down}(x^{l-1})). \quad (5)$$

式中： $\text{down}(\cdot)$ 为一个下采样方法，可以采用最大池化或平均池化；

$\sigma(\cdot)$ 是激活函数。

图 3 所示为最大池化层处理结果示意图，其中左侧图是原始的二维矩阵网格数据 (深度为 2，宽度和高度各为 4)，池化核的大小是 2*2，并且池化核每次移动的步长是 2。右侧图给出了网格数据经过最大池化之后的输出结果。



a) 第一层的最大池化

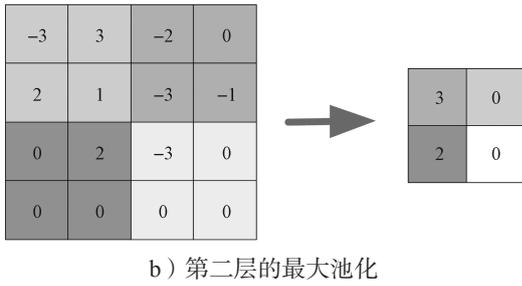


图 3 最大池化层处理结果示意图

Fig. 3 Schematic diagram of the treatment results of the maximum pooling layer

3.2.3 全连接层

卷积层从输入中提取特征, 这些特征经过池化层处理后被输入到一个全连接层中进行分类。全连接层的计算公式为

$$y^l = \sigma \left(\sum_{i=1}^n W_i^{l-1} x_{i-1} + b^l \right) \quad (6)$$

式中: y^l 为第 l 层的输出;

W_i^{l-1} 为第 $l-1$ 层的第 i 个神经元到第 l 层的各个神经元之间的权值集合矩阵;

b^l 为第 $l-1$ 层的所有神经元到第 l 层的所有神经元集合的偏置;

$\sigma(\cdot)$ 为激活函数。

4 基于 EMD-CNN 的故障诊断方法

4.1 EMD 分解和 2D-CNN 模型

为了确定 IMF 的个数, 本研究中对 5 类开路故障中的一种故障数据分别进行了 EMD 分解, 每一种故障数据的序列长度为 200, 所得到的实验结果如图 4 所示。所设计的二维卷积神经网络模型 (2D-CNN) 如图 5 所示, 由输入层、3 个卷积-池化模块、平铺层、全连接层、Softmax 层和输出层构成。

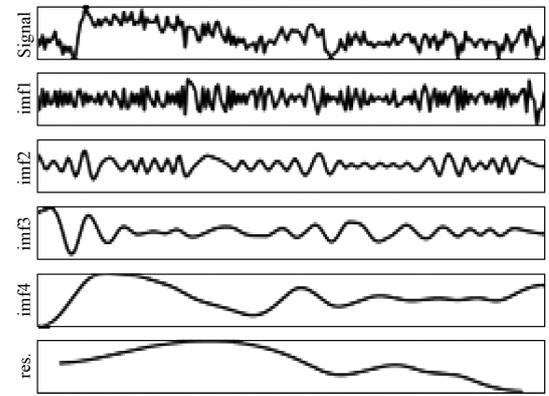
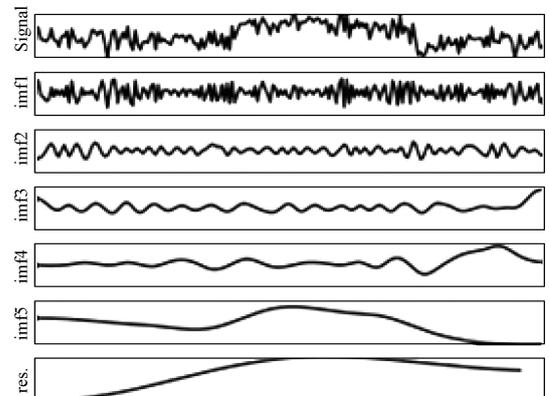
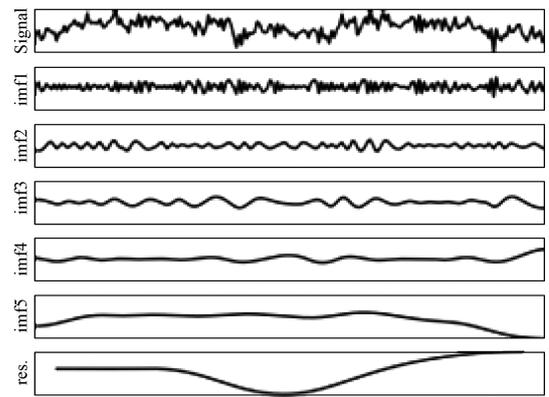
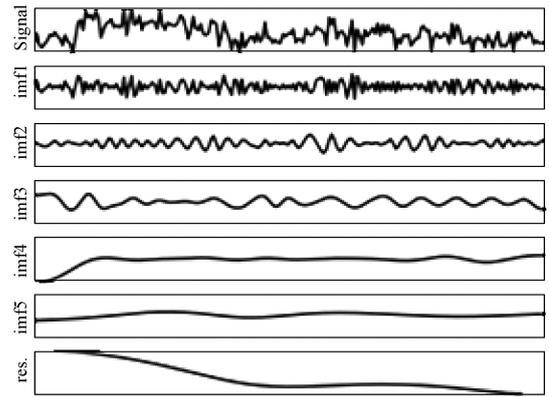
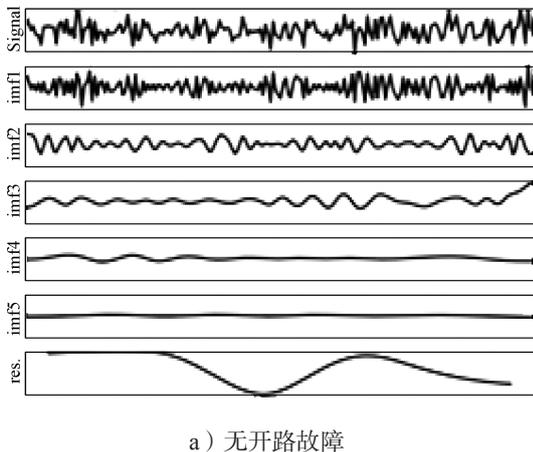


图 4 5 类开路故障数据的 EMD 分解

Fig. 4 EMD of five types of open-circuit fault data

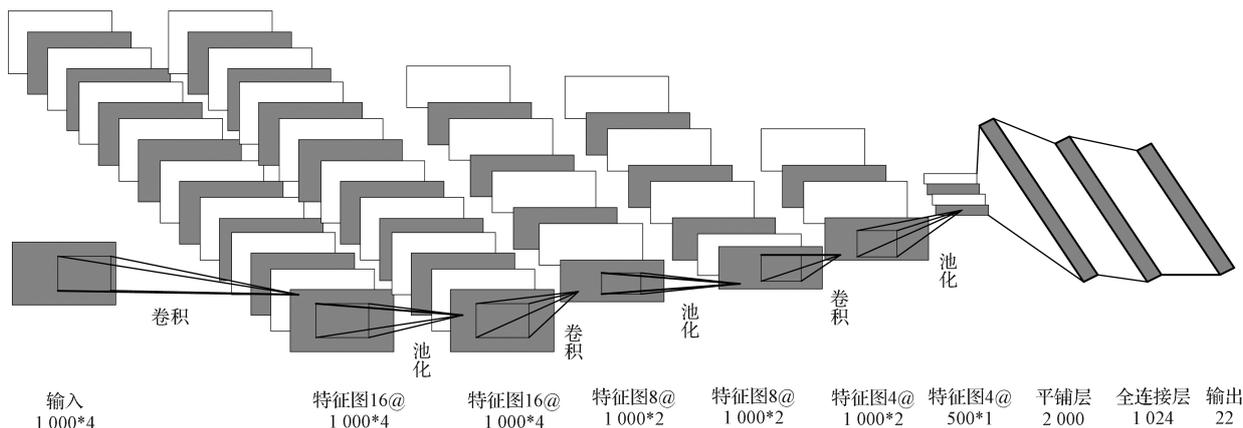


图5 2D-CNN 模型示意图

Fig. 5 2D-CNN model diagram

4.2 诊断方法

基于 EMD-CNN 的故障诊断方法如图 6 所示。

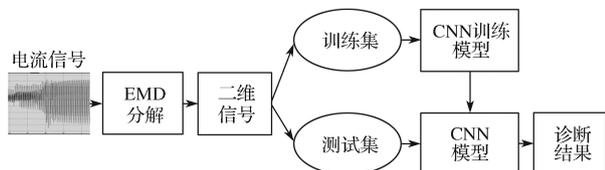


图6 基于 EMD-CNN 的故障诊断方法

Fig. 6 Fault diagnosis method based on EMD-CNN

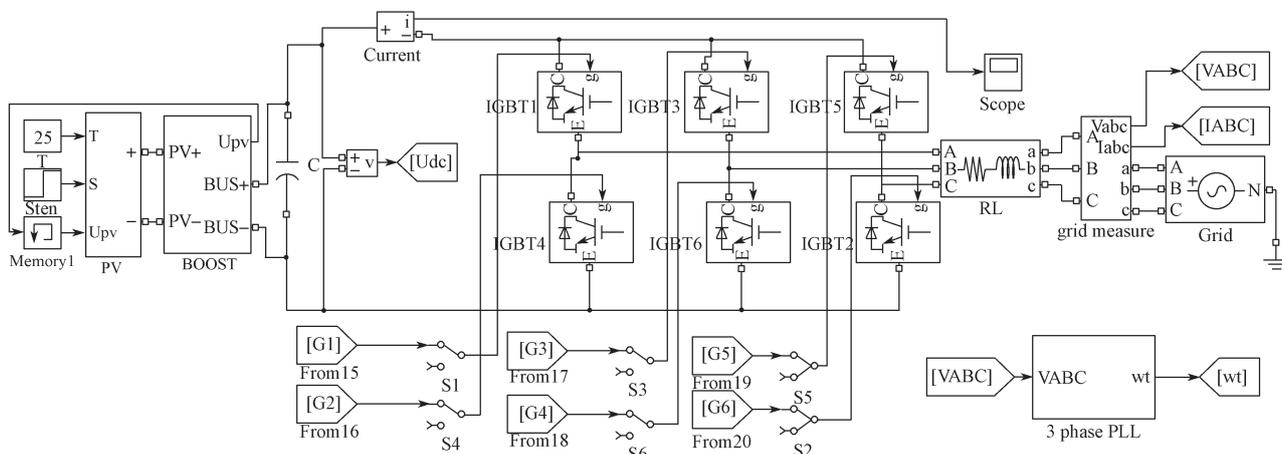
基于 EMD-CNN 的故障诊断的具体步骤如下：

- 1) 控制开关的闭合来模拟光伏逆变器的 IGBT 开路故障，并利用传感器采样电流信号；
- 2) 设置 IMF 的个数，对电流信号进行 EMD 分解，得到各开路故障下的 IMF 分量；
- 3) 组合 IMF 和原始数据，获取不同开路故障下的特征向量样本；
- 4) 将故障数据集分为训练集和测试集，利用训练集训练 EMD-CNN 故障诊断模型；
- 5) 把测试集输入训练的 EMD-CNN 中进行故障识别和诊断。

5 实验结果与分析

5.1 数据的采集和分割

本研究中所设计的光伏发电系统的仿真模块如图 7 所示。图 7 所示仿真模块具有最大功率点跟踪和电压前馈控制功能。在仿真中，采样频率设置为 10^4 Hz，总运行时间为 4.1 s，电阻为 0.1Ω ，电感为 0.002 H，三相电流频率为 50 Hz。前 0.1 s，系统刚刚通电，数据的波动巨大，所以舍去这一部分的数据，数据采集的时间为 0.1~4.1 s。此外，当采样过程执行到 0.25 s 时，系统的工作条件发生变化，光照强度从 700 W/m^2 变为 1000 W/m^2 。这样做的目的是更加符合光伏逆变器的实际工作环境。从图中可以看出，6 个 IGBT 分别连接了一个开关。数据集的获取方法如下：人为地控制不同开关的闭合，利用传感器以数据片段的形式等时间采样每一种情况下（22 种）的直流侧电流信号，每种故障的采样数为 2000 个，总共收集了 20 个数据段，最后经 EMD 分解后，汇总成 440 个样本的数据集。



a) 光伏逆变模块

由图9可知,当检测步长设置为200个数据时,故障诊断的效果最佳,准确度达到了0.9874。同时,200个数据的采样时间正好为0.02s,这与相电流的周期保持一致。因此,文中的后续实验将检测步长设置为200个数据。

滑动窗口代表每一次输入网络模型的数据样本个数,其数值的改变将会影响模型的故障诊断和分类。实验过程中设置了5种滑动窗口,其数据量分别为400,600,800,1000,1200。5种噪声下的故障诊断准确率如图10所示。

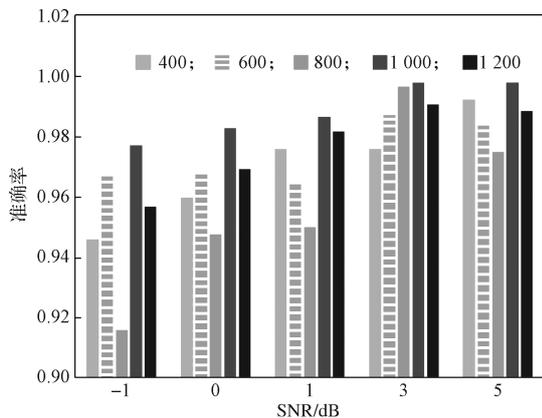


图10 不同噪声下5种滑动窗口的故障分类准确率

Fig. 10 Accuracy rate of the fault classification of five sliding windows under different noises

由图10可知,相较于另外4种滑动窗口,当滑动窗口为1000个数据时,5种噪声下的故障诊断准确率均最高。因此,当滑动窗口为1000个数据时,故障的分类效果最好。

5.3 实验对比

选择kNN(k-nearest neighbor)^[18]、SVM(支持向量机)^[19]和CNN方法进行对比实验。

1) kNN方法。在实验中,kNN的超参数 n_{neighbor} 设置为7。

2) SVM方法。实验中采用线性核支持向量机对逆变器数据进行故障诊断。

3) CNN方法。将输入数据变形为[400,1]的形状,并输入CNN网络,最后通过Softmax层输出故障诊断结果。

在实验中,批量大小设置为600个数据,学习率设置为0.0001。所得4种方法的故障诊断结果如表1所示。从表1中的数据可以得知,EMD-CNN的诊断精度均优于前3种方法。最重要的是,EMD-CNN在5种不同级别的噪声上均具有最佳性能。这主要是由于EMD对故障数据进行了多尺度分解,CNN可以快速且精准地对故障数据进一步提取特征,最后实现

故障的诊断和分类。因此,EMD-CNN在处理光伏逆变器的IGBT开路故障和获得最佳故障诊断性能方面具有明显的优势。

表1 不同噪声下不同方法的故障诊断准确率

Table 1 Accuracy rate of different methods under different noises

方法	SNR/dB				
	-1	0	1	3	5
kNN	0.6023	0.6212	0.6452	0.8068	0.9407
SVM	0.9293	0.9545	0.9571	0.9697	0.9848
CNN	0.9283	0.9417	0.9567	0.9733	0.9783
EMD-CNN	0.9772	0.9829	0.9867	0.9981	0.9981

6 结语

本文提出了一种结合EMD和CNN的光伏逆变器故障诊断方法,利用直流侧电流对开路故障进行监测。并且对光伏逆变器系统进行了Simulink仿真,以验证所提出方法的性能。为了测试该方法的鲁棒性和适用性,将不同强度的高斯噪声人工添加到数据集中。实验结果表明,与传统的分类方法相比,该方法在不同噪声水平下可以获得更高的故障诊断精度。

后续研究中,为了充分利用CNN进行直流侧电流的深度特征提取能力和LSTM在处理时间序列数据上的优异性能,值得研究CNN-LSTM的组合模型,以进一步提高在较高噪声水平下的故障诊断性能。

参考文献:

- [1] SCHUMACHER K. Approval Procedures for Large-Scale Renewable Energy Installations: Comparison of National Legal Frameworks in Japan, New Zealand, the EU and the US[J]. Energy Policy, 2019, 12: 139-152.
- [2] ROBY H, DIBB S. Future Pathways to Mainstreaming Community Energy[J]. Energy Policy, 2019, 135: 111020-111028.
- [3] GAO X, RAI V. Local Demand-Pull Policy and Energy Innovation: Evidence from the Solar Photovoltaic Market in China[J]. Energy Policy, 2019, 128: 364-376.
- [4] ADENLE A A. Assessment of Solar Energy Technologies in Africa-Opportunities and Challenges in Meeting the 2030 Agenda and Sustainable Development Goals[J]. Energy Policy, 2020, 137: 111180-111195.
- [5] LI Y, DING K, ZHANG J, et al. A Fault Diagnosis Method for Photovoltaic Arrays Based on Fault Parameters Identification[J]. Renewable Energy, 2019, 143: 52-63.
- [6] 陈勇, 刘志龙, 陈章勇. 基于电流矢量特征分析的

- 逆变器开路故障快速诊断与定位方法[J]. 电工技术学报, 2018, 33(4): 883-891.
- CHEN Yong, LIU Zhilong, CHEN Zhangyong. Fast Diagnosis and Location Method for Open-Circuit Fault in Inverter Based on Current Vector Character Analysis[J]. Transactions of China Electrotechnical Society, 2018, 33(4): 883-891.
- [7] 姜媛媛, 王友仁, 吴 祎, 等. 基于小波包能量谱和 ELM 的光伏逆变器多故障在线诊断[J]. 仪器仪表学报, 2015, 36(9): 2145-2152.
- JIANG Yuanyuan, WANG Youren, WU Yi, et al. Online Multiple Fault Diagnosis for PV Inverter Based on Wavelet Packet Energy Spectrum and Extreme Learning Machine[J]. Chinese Journal of Scientific Instrument, 2015, 36(9): 2145-2152.
- [8] 余运俊, 裴石磊, 万晓凤, 等. NPC 三电平光伏逆变器开路故障诊断[J]. 电子测量与仪器学报, 2018, 32(5): 41-49.
- YU Yunjun, PEI Shilei, WAN Xiaofeng, et al. Open-Circuit Fault Diagnosis of NPC Three-Level Photovoltaic Inverter[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(5): 41-49.
- [9] HAQUE A, BHARATH K V S, KHAN M A, et al. Fault Diagnosis of Photovoltaic Modules[J]. Energy Science Engineering, 2019, 7: 622-644.
- [10] RAJESWARAN N, LAKSHMI S M, SANJEEVA R T, et al. Hybrid Artificial Intelligence Based Fault Diagnosis of SVPWM Voltage Source Inverters for Induction Motor[J]. Materials Today: Proceedings, 2018, 5(1): 565-571.
- [11] 余运俊, 裴石磊, 谢玉麟. NPC 三电平逆变器混杂建模及开路故障诊断[J]. 电测与仪表, 2020, 57(11): 16-23.
- YU Yunjun, PEI Shilei, XIE Yulin. Hybrid Modeling and Open-Circuit Fault Diagnosis of NPC Three-Level Inverter[J]. Electrical Measurement & Instrumentation, 2020, 57(11): 16-23.
- [12] 赏吴俊, 何正友, 胡海涛, 等. 基于 IGBT 输出功率的逆变器开路故障诊断方法[J]. 电网技术, 2013, 37(4): 1140-1145.
- SHANG Wujun, HE Zhengyou, HU Haitao, et al. An IGBT Output Power-Based Diagnosis of Open-Circuit Fault in Inverter[J]. Power System Technology, 2013, 37(4): 1140-1145.
- [13] HUANG N E, SHEN Z, LONG S R, et al. The Empirical Mode Decomposition and the Hilbert Spectrum for Nonlinear and Non-Stationary Time Series Analysis[J]. Proceedings A, 1998, 454(1971): 903-995.
- [14] 陈华宝, 韩 伟, 张晓东. 基于功率预测的光伏组件阴影故障类型判定[J]. 电测与仪表, 2018, 55(7): 122-129, 136.
- CHEN Huabao, HAN Wei, ZHANG Xiaodong. Judgment on Shadow Fault Type for Photovoltaic Module Based on Power Prediction[J]. Electrical Measurement & Instrumentation, 2018, 55(7): 122-129, 136.
- [15] GONG W, CHEN H, ZHANG Z, et al. A Novel Deep Learning Method for Intelligent Fault Diagnosis of Rotating Machinery Based on Improved CNN-SVM and Multichannel Data Fusion[J]. Sensors (Basel, Switzerland), 2019, 19(7). DOI:10.3390/s19071693.
- [16] ZHANG W, PENG G, LI C, et al. A New Deep Learning Model for Fault Diagnosis with Good Anti-Noise and Domain Adaptation Ability on Raw Vibration Signals[J]. Sensors, 2017, 17(2): 425-435.
- [17] GONG Wenfeng. A Data-Driven-Based Fault Diagnosis Approach for Electrical Power DC-DC Inverter by Using Modified Convolutional Neural Network with Global Average Pooling and 2-D Feature Image[J]. IEEE Access, 2020, 8: 73677-73697.
- [18] 张昊宇, 姚 钢, 殷志柱, 等. 基于小波神经网络与 KNN 机器学习算法的六相永磁同步电机故障态势感知方法[J]. 电测与仪表, 2019, 56(2): 1-9.
- ZHANG Haoyu, YAO Gang, YIN Zhizhu, et al. Fault State Perception Method for Six-Phase PMSM Based on Wavelet Neural Network and KNN Machine Learning Algorithm[J]. Electrical Measurement & Instrumentation, 2019, 56(2): 1-9.
- [19] 王 飞, 金 毅, 黄细霞. 基于支持向量机的逆变电源故障诊断[J]. 电测与仪表, 2015, 52(5): 45-51.
- WANG Fei, JIN Yi, HUANG Xixia. Fault Diagnosis of Inverter Power Supply Device Based on SVM[J]. Electrical Measurement & Instrumentation, 2015, 52(5): 45-51.

(责任编辑: 廖友媛)