

# 基于 CNN 的三相逆变器开路故障诊断及其样本条件分析\*

申皓澜,唐欣,罗毅飞,肖飞,艾胜,樊亚翔

(海军工程大学舰船综合电力技术国防科技重点实验室,湖北武汉 430033)

**摘要:**为了合理选择样本条件以实现高效的智能化诊断,以及克服智能化方法中传统反向传播(back propagation, BP)网络权值较多、局部信息提取能力不足的问题,对基于卷积神经网络(convolutional neural network, CNN)的开路故障诊断方法进行研究,并以典型的三相两电平逆变器为具体对象,着重分析样本时长、样本数量变化时,CNN方法相较于BP网络方法在网络权值数量、训练稳定性、诊断准确率上的量化优势。结果表明,基于CNN的方法可在权值数量远少于BP网络方法的情况下构建深度更深的诊断模型,并在更短样本时长、更少训练样本数量下实现高效、准确的开路故障诊断。

**关键词:**电能变换装置;逆变器;故障诊断;开路故障;深度学习;卷积神经网络;样本条件

**中图分类号:**TM93 **文献标志码:**A **文章编号:**1001-2486(2022)06-163-10

## Open-circuit fault diagnosis for three-phase inverters based on CNN and analysis of its sample conditions

SHEN Haolan, TANG Xin, LUO Yifei, XIAO Fei, AI Sheng, FAN Yaxiang

(National Key Laboratory of Science and Technology on Vessel Integrated Power System, Naval University of Engineering, Wuhan 430033, China)

**Abstract:** In order to reasonably choose a sample condition which supports efficient intelligent diagnosis, and to overcome the problems of too many weights and weak local information extraction capability of intelligent traditional BP (back propagation) network, an open-circuit faults diagnosis method based on CNN (convolutional neural network) was studied. Moreover, by taking the typical three-phase two-level inverter as the specific object, the advantages of the CNN method on network weights number, network training stability and diagnosis effects under different conditions of sample durations and training sample numbers over the BP network method were analyzed quantitatively. Results show that the CNN method can build a deeper network model with much less weights than the BP network method, and it can achieve efficient and accurate model training and diagnosis with shorter and less samples.

**Keywords:** power converter; inverter; fault diagnosis; open-circuit fault; deep learning; convolutional neural network; sample condition

基于绝缘栅双极型晶体管(insulated gate bipolar transistor, IGBT)等半导体开关器件的电能变换装置已被广泛应用于电网、舰船、高铁、电动汽车等重要领域,其安全可靠运行至关重要。然而,由于长期受电、热、振动等应力冲击,开关器件及其驱动、连接件面临着严峻的健康风险,是装置的主要故障源。据统计,装置中约38%的故障与开关器件有关<sup>[1]</sup>。

开关器件的故障主要包括短路和开路故障,其中短路故障伴随着大幅过电流现象,基于此已有集成于驱动的退饱和和检测、集电极电流检测、快速熔断等成熟的硬件检测及保护方法,可在10 μs内迅速结束短路状态<sup>[1]</sup>。然而,开路故障的隐蔽

性较强,可由IGBT键丝断裂、端子松动及破裂、驱动异常等众多因素引起,故障发生后装置通常能在一段时间内带故障运行而不触发系统保护。但是,开路故障仍会引起电压、电流畸变,如不及时诊断容易诱发严重的次生故障<sup>[2]</sup>。因此,对开路故障进行在线诊断具有重要的现实意义。

对电能变换装置整体输出电压或电流波形进行分析,是在较少传感条件下进行开路故障诊断的普遍途径<sup>[1-2]</sup>。其中,传统方法需要针对具体装置,人为地完成数据特征选择与提取、特征-故障解析建模、故障诊断机制设计等工作,当装置拓扑复杂度较高或结构发生改变时,存在建模难度大、诊断机制通用性弱等不足<sup>[3-4]</sup>。近年来,以数

\* 收稿日期:2020-12-29

**基金项目:**国家自然科学基金青年基金资助项目(52007196);舰船综合电力技术国防科技重点实验室基金资助项目(6142217200401,6142217190401)

**作者简介:**申皓澜(1997—),男,湖南邵阳人,博士研究生,E-mail:3150101284@zju.edu.cn;

唐欣(通信作者),男,助理研究员,博士,E-mail:tangxin11@nudt.edu.cn



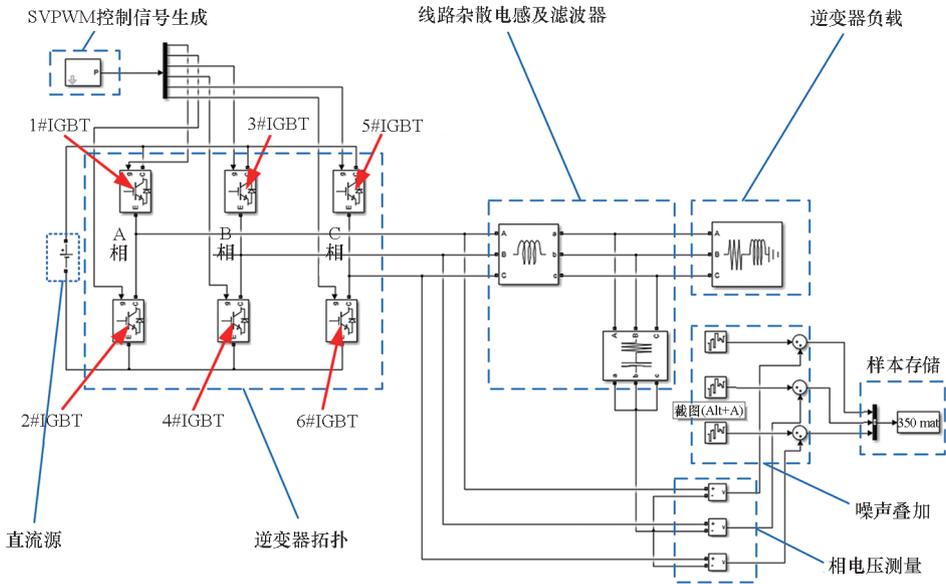


图 2 三相两电平逆变器的 Simulink 模型及 IGBT 编号

Fig. 2 Simulink model and IGBT order of the three-phase two-level inverter

差异性造成影响。此外,即使考虑长期运行时的参数退化,以及负载在一定范围内的变化,它们也不是影响本文所监测的三相 PWM 电压的关键因素。总之,这些参数设置对后文开路诊断方法的建立及效果评价影响较小,因此不再做详细讨论。考虑到实际传感器的测量噪声影响,在模型输出电压上叠加了最大幅值约为 0.5 V 的高斯噪声。

该模型运行在 50 Hz 基波频率,5 kHz 开关频率工况下。综合考虑:生成的故障样本须有效包含反映故障信息的 IGBT 开关状态,以保证开路诊断的准确率,此时要求采样频率应至少大于 2 倍开关频率;在保证足够信息量的前提下应尽可能减少冗余数据,从而减小 CNN 规模及计算量,即采样频率不应过大。最终设置模型采样频率为 20 kHz,可较好权衡上述诊断准确率与计算量之间的矛盾。

模型使用 1 台便携式计算机进行仿真,硬件资源主要包括 Intel i7 - 7700HQ CPU (主频 2.8 GHz)、NVIDIA GeForce GTX 1050Ti GPU、16 GB RAM。未发生开路故障时,模型采集的一段 30 ms 三相 PWM 电压波形如图 3 所示,仿真耗时约为 4.5 s,波形符合预期。

### 1.2 开路故障样本生成

电力电子逆变器通常为指定输出电压的电压源,根据其工作原理,当调制比、开关频率、基波频率等控制参数已确定时,逆变器输出的三相 PWM 电压波形也基本固定,使得与三相电流相比,三相 PWM 电压受负载变化的影响较小。在发生开路

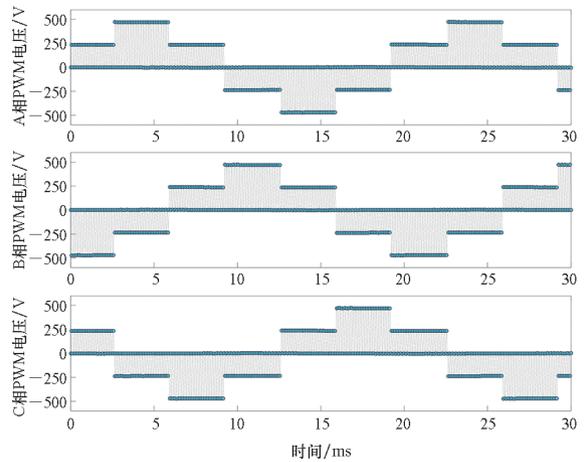


图 3 模型无故障运行时的三相 PWM 电压数据

Fig. 3 Three-phase PWM voltage data when the model runs without fault

故障后,不同开路位置对三相 PWM 电压的影响也远远大于负载变化的影响,使得 PWM 电压能够清晰地反映开路故障信息。因此,本文利用三相 PWM 电压对负载变化不敏感的优势,将其采集为故障数据样本,用于 CNN 开路诊断模型的训练及测试。

将模型中不同的 IGBT 设置为常断开,即可模拟不同位置的开路(不同故障模式)并生成故障样本。单个故障样本包含两方面数据:①样本标签,即对应故障模式的编码;②对应故障模式下一定时长的三相 PWM 电压数据。该样本时长内各 IGBT 均受到多次开关驱动作用,由此组合成各种驱动状态并产生不同状态下的三相 PWM 电压数据,它们共同提供可区分不同开路故障模式

的故障特征。

1.2.1 故障模式分类及样本标签

考虑到多个 IGBT 同时发生开路故障的概率极小,因此仅对单管、双管故障进行研究,加上“无故障”共计有 22 种故障模式。为了便于编程和神经网络训练,根据 IGBT 编号顺序及开路情况将 22 种故障模式编码成如图 4 所示长度为 6 的布尔向量。

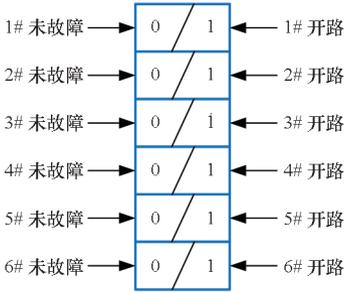


图 4 三相两电平逆变器开路故障的编码规则  
Fig. 4 Open-circuit fault coding rule of the three-phase two-level inverter

22 种故障模式的标准编码如表 1 所示,即不同故障模式所对应样本的样本标签,将被用作 CNN 诊断模型训练时网络的标准输出。

表 1 22 种故障模式的样本标签

Tab. 1 Sample labels for the 22 fault modes

故障模式 (无、单管 开路)	样本标签	故障模式 (双管开路)	样本标签
无故障	0 0 0 0 0 0	1#、2#开路	1 1 0 0 0 0
1#开路	1 0 0 0 0 0	1#、4#开路	1 0 0 1 0 0
2#开路	0 1 0 0 0 0	1#、6#开路	1 0 0 0 0 1
3#开路	0 0 1 0 0 0	3#、2#开路	0 1 1 0 0 0
4#开路	0 0 0 1 0 0	3#、4#开路	0 0 1 1 0 0
5#开路	0 0 0 0 1 0	3#、6#开路	0 0 1 0 0 1
6#开路	0 0 0 0 0 1	5#、2#开路	0 1 0 0 1 0
		5#、4#开路	0 0 0 1 1 0
		5#、6#开路	0 0 0 0 1 1
		1#、3#开路	1 0 1 0 0 0
		1#、5#开路	1 0 0 0 1 0
		3#、5#开路	0 0 1 0 1 0
		2#、4#开路	0 1 0 1 0 0
		2#、6#开路	0 1 0 0 0 1
		4#、6#开路	0 0 0 1 0 1

1.2.2 仿真样本生成及预处理

根据表 1 中各类故障模式,在图 2 所示模型中设置相应 IGBT 为常断开,随后仿真获取相应故障模式下的三相 PWM 电压样本。为了较好权衡诊断准确率与计算量之间的矛盾,设置采样频率为 20 kHz,即 4 倍于 5 kHz 的开关频率(具体参见 1.1 节)。为了使样本具有一般性,设置每条样本的初始相位为随机。每种故障模式保存 350 个 20 ms(单基波周期)样本,后续通过样本抽取及截断来分析样本时长、数量对 CNN 训练及诊断效果的影响。

对于单个样本,预处理时首先将三相数据序列并列组合为二维矩阵,以便于 CNN 对存在于三相电压局部差异中的大量故障细节信息进行卷积提取;然后,根据式(1)将矩阵元素归一化至  $[-1, 1]$  范围,有利于避免网络权值过小和神经元饱和等数值问题、加速网络训练的收敛、提高网络在工况改变时的泛化能力。

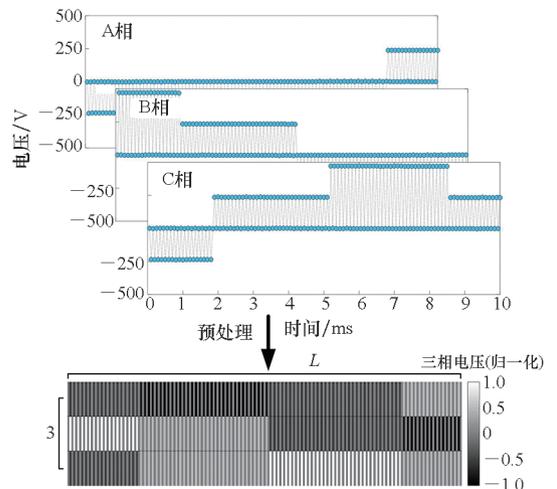
$$D_{nor} = \frac{D}{|d|_{max}} \tag{1}$$

其中,  $D_{nor}$  为对样本  $D$  进行归一化后得到的样本,  $|d|_{max}$  为样本  $D$  中绝对值最大的元素。如图 5 所示,经上述预处理后,单个样本可被近似看作一幅像素为  $L \times 3$  的灰度图像,  $L$  为样本时长所对应的单相采样点数。

2 基于 CNN 的逆变器开路故障诊断方法

2.1 CNN 诊断方法的建立流程

CNN 及其他神经网络故障诊断方法的建立均参照图 6 所示流程,可大致分为网络训练和网络测试两个部分。首先将样本按一定比例分组为



(a) 无故障  
(a) Normal

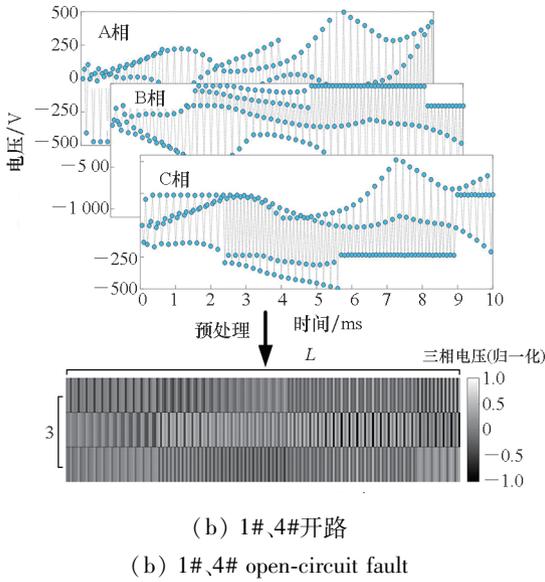


图5 电压样本预处理示意图

Fig. 5 Schematic diagram of the voltage sample preprocessing

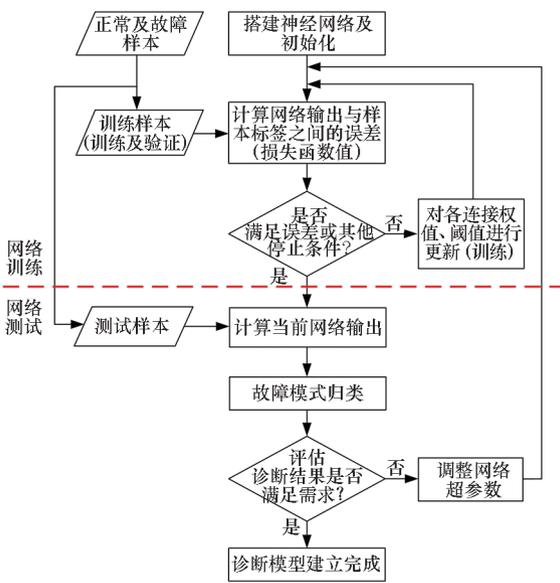


图6 神经网络故障诊断方法的建立流程

Fig. 6 Establishment process of neural network-based fault diagnosis methods

训练集、测试集。训练时,将训练集中的电压数据样本逐个输入搭建的神经网络,以网络输出与对应样本标签之间的误差最小化(损失函数值最小)为目标,对网络各连接权重及阈值进行迭代更新。网络被训练后,将测试集中的电压数据样本(对网络而言是未知样本)逐条输入网络,随后将输出归类到最接近的样本标签,对归类标签与样本实际标签进行对比分析,进而评估网络的诊断能力是否满足需求。若满足,即完成诊断模型的建立;若未满足,则对网络层数、神经元数、激活函数等超参数进行优化调整,并重复网络训练、测

试流程。

上述方法流程的目标是使网络能自动提取和利用样本的故障特征,进而形成由样本中的电压数据向样本标签映射的能力,实现故障诊断。

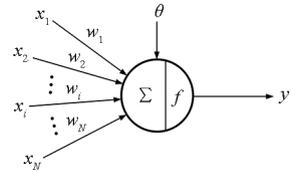
### 2.2 CNN 构建及训练

基于 BP 网络或 CNN 的方法均遵循图 6 所示流程,并使用如图 7(a)所示的同种 M - P 神经元模型,其区别主要体现在神经元不同的层间连接方式,如图 7(b)、图 7(c)所示。

单个 M - P 神经元的输入输出关系可表示为:

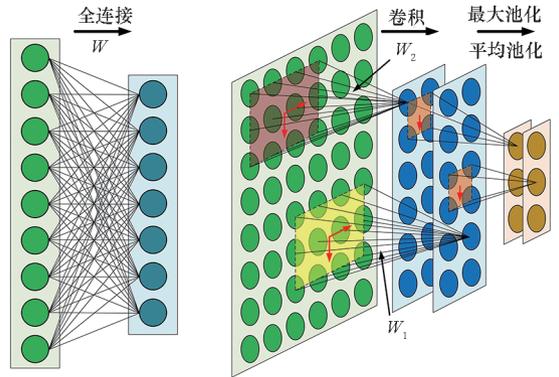
$$y = f\left(\sum_{i=1}^N x_i w_i - \theta\right) \quad (2)$$

式中,  $f(\cdot)$  为神经元的激活函数,  $w_i$  为神经元第  $i$  个输入的连接权重,  $\theta$  为神经元的阈值,这些权重和阈值即为网络的待训练权值。



(a) M - P 神经元模型

(a) M - P neuron model



(b) 全连接

(b) Full connection

(c) 卷积连接及池化

(c) Convolution and pooling

图7 M-P 神经元模型及其连接方式

Fig. 7 M-P neuron model and its connection modes

可以看出,对于图 7(b)中 BP 网络的全连接结构而言,待训练的权值数量会随着网络层数、神经元数量的增加而大幅增加。CNN 中则大量采用与如图 7(c)所示的卷积层、池化层相配合的结构。卷积层中的每个神经元通过由卷积核(一组连接权值)构成的滤波器与前一层的局部区域连接,滤波器可视作按一定步长滑动从而提取不同区域的局部特征,即网络局部连接;可使用多个滤

滤波器来加深信息提取的深度,但每个滤波器的卷积核保持不变,即卷积核权值共享。池化层中的元素一般取上一层的局部最大值或均值,可压缩神经元数量并增强网络的泛化能力。CNN的“网络局部连接”“卷积核权值共享”及池化层的使用,使网络可在大幅缩减待训练权值的条件下,对样本局部特征进行深度提取,并改善网络训练的“局部最优”及“过拟合”问题<sup>[21]</sup>。

由于三相 PWM 电压之间的相对差异是故障诊断的重要依据,因此自然做法是在某一算子支持下对三相数据进行逐段的局部对比,进而从局部差异中提取出大量的故障细节信息。这一过程符合 CNN 的“网络局部连接”“卷积核权值共享”特点,使 CNN 有望实现较好的诊断效果。对适合较小规模问题的 LeNet-5 网络模型进行了适应性优化,作为本文的 CNN 结构,同时建立 BP 网络用于对比,如表 2 所示。两种网络结构均是多次测试后的择优结果。

表 2 中的各隐藏层普遍采用 ReLU 激活函数,有利于加速训练收敛和改善“过拟合”问题<sup>[26]</sup>;输出层采用 Sigmoid 激活函数,促使网络输出较好逼近与样本标签相对应的 0、1 布尔值。CNN 由卷积层、池化层完成局部特征提取后,仍

使用全连接层来完成特征-样本标签映射,但其规模已远远小于 BP 网络中的全连接层,可有效避免权值过多问题。

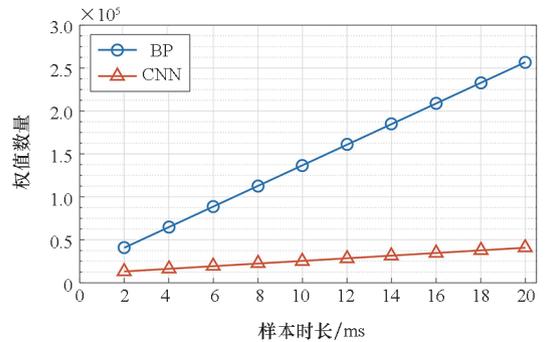
网络训练时,样本时长分别取 2 ms, 4 ms, ..., 20 ms,各故障模式的样本个数分别取 20, 40, ..., 300,以分析样本时长、训练样本数量对训练及诊断的影响;测试集中各故障模式取 40 个样本,用于评估诊断效果。网络训练采用自适应性优化器 Adam<sup>[27]</sup>,损失函数为均方误差(mean square error, MSE)。此外,设置批训练样本量 Batch Size 为 40,在本文条件下可取得较好的网络训练收敛速度及收敛稳定性;训练停止条件为“近 5 轮训练的损失函数不再下降”,可较好权衡欠拟合、过拟合问题。该 CNN 模型基于 Python 3.8.5 和 TensorFlow-GPU 2.4.0 深度学习框架搭建,使用便携式计算机的 NVIDIA GeForce GTX 1050Ti GPU 进行训练和推理。经测试,样本时长 10 ms、各故障模式训练样本数为 160 时,上述 CNN 模型训练耗时约 30 s,单样本推理耗时约 0.14 ms。

图 8 对比了不同时长样本输入时 CNN、BP 网络的待训练权值数量,以及同条件多次训练中损失

表 2 CNN 与 BP 网络的主要结构参数对比

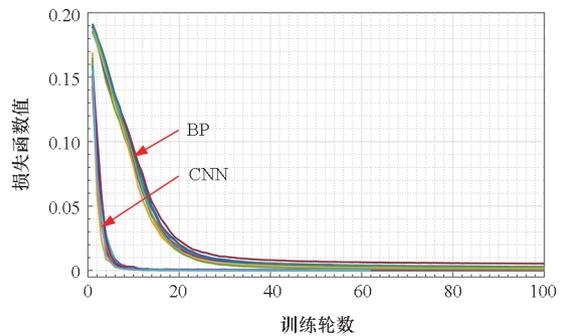
Tab.2 Main structural parameters of the CNN and BP network

层级	CNN		BP 网络	
	连接	参数	连接	参数
输入层	一对一	神经元: 同输入	一对一	神经元: 同输入
隐藏层 I	卷积 + 池化	滤波器:32 卷积核尺寸:16 池化范围:8 步长: 1(卷积)、 5(池化)	全连接	神经元: 200
		滤波器:48 卷积核尺寸:4 池化范围:6 步长: 2(卷积)、 4(池化)		
隐藏层 II	卷积 + 池化	滤波器:48 卷积核尺寸:4 池化范围:6 步长: 2(卷积)、 4(池化)	全连接	神经元: 80
隐藏层 III	全连接	神经元:64		
隐藏层 IV	全连接	神经元:32		
输出层	全连接	神经元:6	全连接	神经元:6



(a) 权值数量对比

(a) Comparison of weight number



(b) 损失函数值对比

(b) Comparison of loss function value

图 8 CNN 与 BP 网络训练的权值数量及损失函数值对比

Fig. 8 Comparison of the number of parameters and loss function values in CNN and BP training

函数值的变化情况(样本时长 10 ms、各故障模式训练样本数 160)。可见,CNN 在网络层数更多(深度更深)的情况下,其权值数量却远少于 BP 网络,例如当样本时长为 20 ms 时,BP 网络的权值数量为 256 766,而 CNN 的权值数量仅为 40 822。训练中的损失函数值变化反映了训练过程收敛于全局最优解的趋势,可见 CNN 的收敛速度显著快于 BP 网络,且 CNN 可较稳定地收敛于较小的损失函数值,即 CNN 训练更容易接近全局最优解。

### 2.3 网络输出结果的故障模式归类器设计

将一个测试样本输入上述 CNN、BP 网络后,网络输出的 6 维向量处于 (0,1) 区间内,尚未与表 1 中的样本标签一一对应。为此,按式(3)对输出向量与各标签之间的欧氏距离进行计算,以距离最小作为判断标准将输出向量归类至对应标签,从而实现故障模式诊断。

$$d_{AB} = \sqrt{(a_1 - b_1)^2 + (a_2 - b_2)^2 + \dots + (a_N - b_N)^2} \quad (3)$$

式中, $a_1, a_2, \dots, a_N$  为输出向量  $A$  中的元素; $b_1, b_2, \dots, b_N$  为某一标签  $B$  中的元素。归类器在完成输出归类的同时,也使诊断过程具备了一定的容错能力。

完成上述 CNN 诊断模型训练及故障模式归类器设计后,单次诊断过程如图 9 所示(以 1#

IGBT 开路为例),主要包括三相 PWM 电压采集及归一化、CNN 诊断模型推理、故障模式归类三个环节。

### 3 结果分析

在不同样本时长、训练样本数量条件下进行 CNN、BP 网络的训练及诊断测试对比。

#### 3.1 评价指标

使用训练结束时的损失函数值  $L_{final}$ 、诊断准确率  $D_{rate}$  作为评价指标。 $L_{final}$  越小,表明训练使网络越准确地提取和利用了训练样本中的故障特征; $D_{rate}$  越高,表明训练后的网络对测试样本具有越强的诊断能力。

图 10 为某次训练后(样本时长 10 ms、各故障模式训练样本数 160) CNN、BP 网络在测试集上的诊断结果分布图。

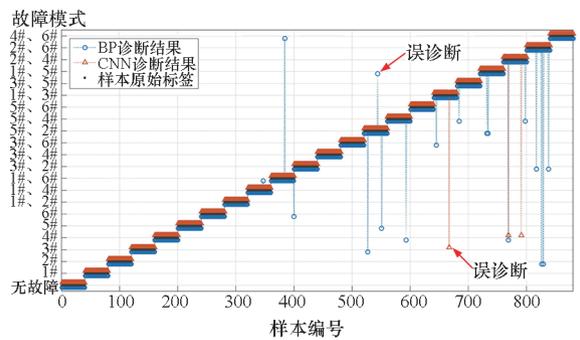


图 10 CNN 与 BP 网络在一次训练后的诊断结果分布  
Fig. 10 Distribution of diagnosis results of CNN and BP network after a training

可以看出,在总计 880 个测试样本中,BP 对 17 个样本诊断有误,CNN 对 3 个样本诊断有误。根据诊断分布结果,由式(4)对诊断准确率进行计算。

$$D_{rate} = \frac{N_c}{N_a} \times 100\% \quad (4)$$

式中, $N_c$  为测试中被正确判断及定位的开路故障数量, $N_a$  为测试样本中的开路故障总数。在同一样本时长、训练样本数量条件下,后续均对网络进行多次训练,记录如图 11 所示的多个  $L_{final}$  和  $D_{rate}$  (图中重复 30 次),再计算均值以体现结果的一般性。可以看出,与 BP 网络相比,CNN 在该条件下的  $L_{final}$  普遍较小、 $D_{rate}$  普遍较高,且数值波动较小,表明 CNN 可更有效提取和利用训练样本中的故障特征,实现更准确且稳定的诊断。

#### 3.2 不同样本时长下 CNN 与 BP 网络的结果对比

图 12 为各类故障模式的训练样本数为 160,

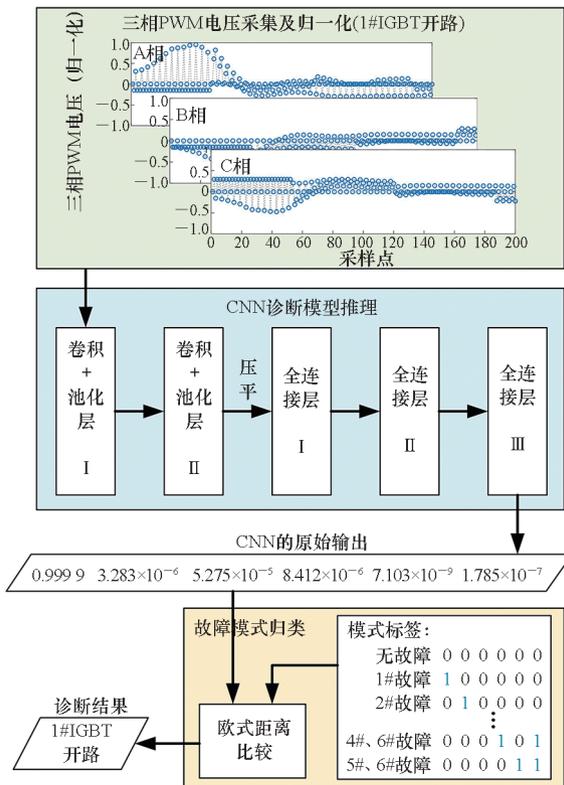
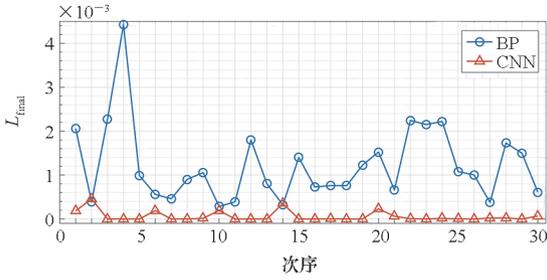


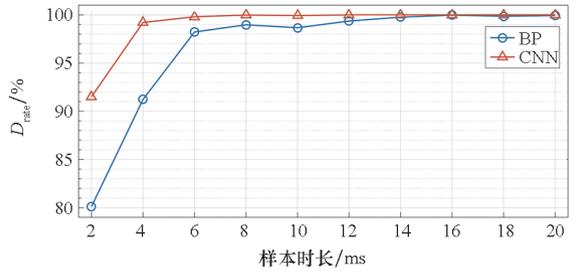
图 9 单次开路故障诊断过程示例

Fig. 9 An example of open-circuit fault diagnosis



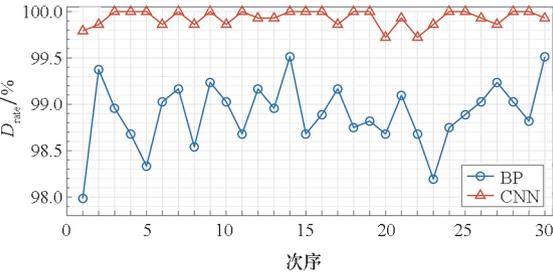
(a) 30 次训练及测试的  $L_{final}$  对比

(a) Comparison of  $L_{final}$  in 30 training and diagnoses



(b) 不同样本时长下的  $D_{rate}$  对比

(b) Comparison of  $D_{rate}$  under different sample durations



(b) 30 次训练及测试的  $D_{rate}$  对比

(b) Comparison of  $D_{rate}$  in 30 training and diagnoses

图 12 不同样本时长下 CNN 与 BP 网络的  $L_{final}$  及  $D_{rate}$  对比

Fig. 12 Comparison of  $L_{final}$  and  $D_{rate}$  between CNN and BP network under different sample durations

率的计算方法如式(4)所示)。

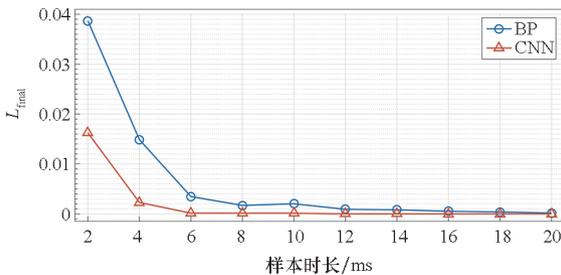
### 3.3 不同训练样本数量下 CNN 与 BP 网络的结果对比

图 13 是样本时长为 10 ms(半基波周期), 各故障模式的训练样本数分别取 20, 40, ..., 300 时, CNN 与 BP 网络  $L_{final}$  和  $D_{rate}$  的变化趋势, 图中每个数据点均为 5 次训练及测试后的平均结果。可以看出,  $L_{final}$  随训练样本数量的增加总体呈减小趋势,  $D_{rate}$  则随训练样本数量的增加总体呈上升趋势, 这表明增加训练样本数量有利于改善网络的训练及诊断效果, 这是因为较多的训练样本可为网络训练提供更丰富和全面的故障信息。此外, CNN 与 BP 网络相比,  $L_{final}$  整体较小、 $D_{rate}$  整体较高, 当训练样本数较少时优势十分显著, 且随着训练样本数量的增加更快收敛至较优值, 这意味着 CNN 方法可在明显较少样本的支持下得到相同的诊断精度, 从而显著降低应用中对实际故障样本的积累要求并缩短网络训练时间。具体而言, CNN 在各类故障模式的训练样本数量为 40 时就可达到 99.82% 的诊断准确率。

图 11 CNN 与 BP 网络在 30 次训练及诊断中的  $L_{final}$  及  $D_{rate}$  对比

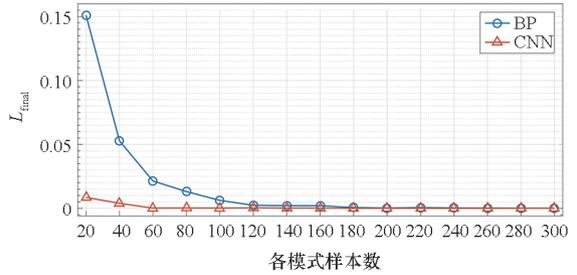
Fig. 11 Comparison of  $L_{final}$  and  $D_{rate}$  between CNN and BP network in 30 trainings and diagnoses

样本时长分别取 2 ms, 4 ms, ..., 20 ms 时, CNN 与 BP 网络  $L_{final}$  和  $D_{rate}$  的变化趋势, 图中每个数据点均为 5 次训练及测试后的平均结果。可以看出,  $L_{final}$  随样本时长的增加总体呈减小趋势,  $D_{rate}$  则随样本时长的增加总体呈上升趋势, 这表明增加样本长度总体有利于改善网络的训练及诊断效果, 这是因为较长的样本中包含了更充分的故障信息。此外, CNN 的  $L_{final}$  比 BP 网络整体较小、 $D_{rate}$  整体较高, 且随着样本时长的增加更快收敛至较优值, 这意味着 CNN 方法可在样本较短(网络权值亦较少)时取得相同的诊断精度, 实现更高的诊断效率。具体而言, CNN 在样本时长为 4 ms 时就达到了 99.21% 的诊断准确率(文中诊断准确



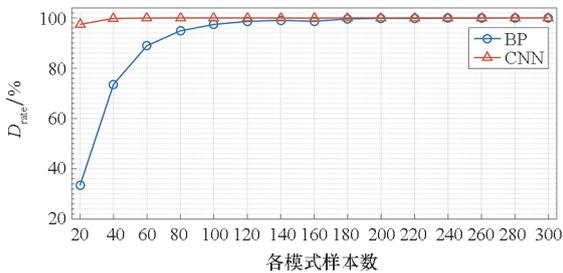
(a) 不同样本时长下的  $L_{final}$  对比

(a) Comparison of  $L_{final}$  under different sample durations



(a) 不同训练样本数量下的  $L_{final}$  对比

(a) Comparison of  $L_{final}$  under different training sample numbers



(b) 不同训练样本数量下的  $D_{rate}$  对比

(b) Comparison of  $D_{rate}$  under different training sample numbers

图 13 不同训练样本数量下 CNN 与 BP 网络的

$L_{final}$  及  $D_{rate}$  对比

Fig. 13 Comparison of  $L_{final}$  and  $D_{rate}$  between CNN and BP network under different training sample numbers

## 4 结论

本文以电能变换装置开路故障的智能诊断需求为牵引,针对传统 BP 神经网络方法存在的“参数膨胀”“局部模糊”问题,研究了基于 CNN 的开路故障诊断方法,并以三相两电平逆变器为代表,着重开展了不同样本时长、训练样本数量条件下的方法仿真对比及验证。结果表明,利用 CNN “网络局部连接”“卷积核权值共享”等特点,可建立比 BP 网络权值更少、深度更深的深度学习网络模型,使诊断网络具备权值少、训练收敛快、稳定性强、诊断准确率高等优势。对于本文的三相两电平逆变拓扑而言,当各类故障模式的训练样本数为 160 时,基于 CNN 的诊断方法仅需 4 ms 样本时长就达到 99.21% 的诊断准确率;当样本时长为 10 ms 时,各类故障模式只需 40 个训练样本就达到 99.82% 的诊断准确率。本文的样本条件分析过程及相关结果可为实际应用中合理确定样本条件,从而为提高神经网络诊断模型的训练及诊断效率提供有益参考。

下一步计划结合实验装置搭建,进行实机环境下充分考虑噪声、线路杂散参数、多类故障耦合等干扰因素的诊断方法优化,同时综合考虑 AI 终端硬件的计算能力、诊断准确率等因素,研究在线诊断时样本时长、采样率的最优选择策略,从而进一步提高方法的鲁棒性和工程适应性。

## 参考文献 (References)

[1] LU B, SHARMA S K. A literature review of IGBT fault diagnostic and protection methods for power inverters [J]. IEEE Transactions on Industry Applications, 2009, 45(5): 1770 - 1777.

[2] 王霞霞,陈超波,高嵩. 逆变器开关管故障诊断方法综

述[J]. 计算机测量与控制, 2019, 27(8): 1 - 6.

WANG X X, CHEN C B, GAO S. Review of fault diagnosis methods for switches in inverter [J]. Computer Measurement & Control, 2019, 27(8): 1 - 6. (in Chinese)

- [3] GAO Z W, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques—part I: fault diagnosis with model-based and signal-based approaches [J]. IEEE Transactions on Industrial Electronics, 2015, 62(6): 3757 - 3767.
- [4] GAO Z W, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques—part II: fault diagnosis with knowledge-based and hybrid/active approaches [J]. IEEE Transactions on Industrial Electronics, 2015, 62(6): 3768 - 3774.
- [5] CAI B P, ZHAO Y B, LIU H L, et al. A data-driven fault diagnosis methodology in three-phase inverters for PMSM drive systems [J]. IEEE Transactions on Power Electronics, 2017, 32(7): 5590 - 5600.
- [6] LIU Q, LIANG T, HUANG Z, et al. Real-time FPGA-based hardware neural network for fault detection and isolation in more electric aircraft [J]. IEEE Access, 2019, 7: 159831 - 159841.
- [7] WU X, CHEN C Y, CHEN T F, et al. A fast and robust diagnostic method for multiple open-circuit faults of voltage-source inverters through line voltage magnitudes analysis [J]. IEEE Transactions on Power Electronics, 2020, 35(5): 5205 - 5220.
- [8] XIA Y, XU Y, GOU B. A data-driven method for IGBT open-circuit fault diagnosis based on hybrid ensemble learning and sliding-window classification [J]. IEEE Transactions on Industrial Informatics, 2020, 16(8): 5223 - 5233.
- [9] XUE Z Y, XIAHOU K S, LI M S, et al. Diagnosis of multiple open-circuit switch faults based on long short-term memory network for DFIG-based wind turbine systems [J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2020, 8(3): 2600 - 2610.
- [10] 王兆兵,高丽敏. 大数据时代的民机健康管理技术革新 [J]. 航空维修与工程, 2018(5): 20 - 25.
- WANG Z B, GAO L M. Innovation of aircraft health management technology in big data era [J]. Aviation Maintenance & Engineering, 2018(5): 20 - 25. (in Chinese)
- [11] 赵晓明,孙希德. 基于大数据的风电设备远程故障监测与诊断系统研究 [J]. 电力大数据, 2019, 22(4): 22 - 29.
- ZHAO X M, SUN X D. Research on remote fault monitoring and diagnosis system of wind power equipment based on big data [J]. Power Systems and Big Data, 2019, 22(4): 22 - 29. (in Chinese)
- [12] 张礼立. 三一重工转型的催化剂: 工业互联网 [J]. 中国工业评论, 2016(8): 90.
- ZHANG L L. Catalyst for SANY's transformation—industrial Internet [J]. China Industry Review, 2016(8): 90. (in Chinese)
- [13] XIN B, WANG T Z, TANG T H. A deep learning and softmax regression fault diagnosis method for multi-level converter [C]//Proceedings of IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives, 2017.
- [14] ZHAO G Q, ZHANG G H, GE Q Q, et al. Research

- advances in fault diagnosis and prognostic based on deep learning [C]//Proceedings of Prognostics and System Health Management Conference (PHM-Chengdu), 2017.
- [15] FAN B, YIN Y X, FU C F. A method of inverter circuit fault diagnosis based on BP neural network and D-S evidence theory [C]// Proceedings of the 8th World Congress on Intelligent Control and Automation, 2010.
- [16] KHOMFOI S, TOLBERT L M. Fault diagnostic system for a multilevel inverter using a neural network [J]. IEEE Transactions on Power Electronics, 2007, 22(3): 1062 - 1069.
- [17] 吴迪. 基于神经网络的电力电子电路故障诊断方法研究 [D]. 哈尔滨: 哈尔滨理工大学, 2017.  
WU D. The power electronic circuit fault diagnosis based on the neural network [D]. Harbin: Harbin University of Science and Technology, 2017. (in Chinese)
- [18] ZENG G, XI Y F, SU Y M, et al. Application of GA-BP in fault diagnosis of power circuit of SVC [C]//Proceedings of CES/IEEE the 5th International Power Electronics and Motion Control Conference, 2009.
- [19] KETKAR N. Convolutional neural networks [M]//Deep Learning with Python. Berkeley: Apress, 2017: 63 - 78.
- [20] 俞颂华. 卷积神经网络的发展与应用综述 [J]. 信息通信, 2019, 32(2): 39 - 43.  
YU S H. Overview of the development and application of convolutional neural networks [J]. Information & Communications, 2019, 32(2): 39 - 43. (in Chinese)
- [21] HAN J H, CHOI D J, HONG S K, et al. Motor fault diagnosis using CNN based deep learning algorithm considering motor rotating speed [C]//Proceedings of IEEE the 6th International Conference on Industrial Engineering and Applications, 2019.
- [22] PANDARAKONE S E, MASUKO M, MIZUNO Y, et al. Deep neural network based bearing fault diagnosis of induction motor using fast Fourier transform analysis [C]//Proceedings of IEEE Energy Conversion Congress and Exposition, 2018.
- [23] WANG H, ZHANG C, ZHANG N, et al. Fault diagnosis for IGBTs open-circuit faults in high-speed trains based on convolutional neural network [C]//Proceedings of Prognostics and System Health Management Conference (PHM-Qingdao), 2019.
- [24] 商蕾, 武美君, 高海波, 等. 基于三通道 2D-CNN 的逆变器功率管开路故障诊断方法 [J]. 船海工程, 2020, 49(1): 78 - 82.  
SHANG L, WU M J, GAO H B, et al. A diagnostic technique for open-switch fault of inverters based on three-channel 2D-CNN [J]. Ship & Ocean Engineering, 2020, 49(1): 78 - 82. (in Chinese)
- [25] 徐继伟, 宋保业, 公茂法. 基于深度神经网络的多电平逆变器故障诊断 [J]. 电测与仪表, 2019, 56(2): 123 - 128.  
XU J W, SONG B Y, GONG M F. Fault diagnosis of multilevel inverter based on deep neural network [J]. Electrical Measurement & Instrumentation, 2019, 56(2): 123 - 128. (in Chinese)
- [26] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks [C]//Proceedings of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS), 2011.
- [27] KINGMA D P, BA J. Adam: a method for stochastic optimization [EB/OL]. (2017 - 01 - 30) [2020 - 12 - 15]. <https://arxiv.org/abs/1412.6980>.