

doi:10.3969/j.issn.1673-9833.2021.01.004

基于卷积神经网络的光伏逆变器故障诊断

陈旺斌¹, 孟献蒙¹, 程凡永^{1,2}, 徐杰^{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)

摘要: 光伏逆变器将太阳能电池板的直流电压转换为交流电压以驱动家用电器或者升压并入能源互联网, 而绝缘栅双极型晶体管 (IGBT) 是光伏逆变器的核心组件, 其状态异常将直接影响系统的正常运行。从减少传感器数量的角度出发, 以直流侧的电流信号作为输入信号, 设计了基于卷积神经网络 (CNN) 的故障诊断模型来监测 IGBT 的开路状态。并利用设计的 Simulink 模块生成的仿真数据对模型进行了训练和测试, 都取得了很好的故障诊断性能。此外, 还设计了不同噪声水平下的故障诊断测试, 测试结果表明该故障诊断模型在噪声环境下具备有效性和鲁棒性。

关键词: 三相逆变器; 能源互联网; 卷积神经网络; 故障诊断

中图分类号: TM769

文献标志码: A

文章编号: 1673-9833(2021)01-0025-06

引文格式: 陈旺斌, 孟献蒙, 程凡永, 等. 基于卷积神经网络的光伏逆变器故障诊断 [J]. 湖南工业大学学报, 2021, 35(1): 25-30.

Fault Diagnosis of Photovoltaic Inverter Based on Convolution Neural Network

CHEN Wangbin¹, MENG Xianmeng¹, CHENG Fanyong^{1,2}, XU Jie^{1,2}

(1. Key Laboratory of Advanced Perception and Intelligent Control of High-End Equipment of Ministry of Education,

Anhui Polytechnic University, Wuhu Anhui 241000, China; 2. Anhui Key Laboratory of Electric

Drive and Control, Anhui Polytechnic University, Wuhu Anhui 241000, China)

Abstract: Photovoltaic inverters are characterized with the ability to convert DC voltage of solar panels into AC voltage to drive household appliances or boost voltage into the energy internet. As the core component of photovoltaic inverter, insulated gate bipolar transistor (IGBT) under an abnormal state will directly affect the normal operation of the system. In order to reduce the number of sensors, a fault diagnosis model based on convolutional neural network (CNN) is designed to monitor the open circuit state of IGBT with the current signal of DC side as the input signal. The simulation data generated by the designed Simulink module is used to train and test the model, thus achieving a good fault diagnosis performance. In addition, experimental tests under different level noises help to validate the effectiveness and robustness of the proposed method in noisy environments.

Keywords: three-phase inverter; energy internet; convolutional neural network; fault diagnosis

收稿日期: 2020-04-10

基金项目: 安徽省教育厅基金资助重点项目 (KJ2019A0149), 福建省自然科学基金资助面上项目 (2018J01806), 福建省教育厅基金资助项目 (JAT170457)

作者简介: 陈旺斌 (1993-), 男, 安徽池州人, 安徽工程大学硕士生, 主要研究方向为机器学习与故障诊断,

E-mail: karlchen691@163.com

通信作者: 程凡永 (1982-), 男, 山东临沂人, 安徽工程大学讲师, 博士, 硕士生导师, 主要从事模式识别, 故障诊断和机器学习方面的教学与研究, E-mail: chengfanyong@gmail.com

1 背景知识

随着工业化的快速发展,电子设备早期故障检测已成为一项必要技术,同时也是一项难点技术。近年来,随着人工智能的发展,越来越多的基于数据驱动的故障诊断技术被运用到设备故障诊断中,其中最典型的是深度学习中的卷积神经网络(convolutional neural network, CNN)模型^[1]。文献[2]针对高速列车转向架故障问题提出一种利用一维CNN提取高速列车故障信号深层特征模型,该模型能自动完成原始数据的特征提取和选择,进而实现对不同工况下转向架故障的分类。文献[3]提出一种基于二维CNN的故障诊断方法。首先,设计了一种一维时间信号到二维图像信号的转换方法,在此基础上提出了基于二维图像信号的故障诊断算法,并在电机轴承数据集、自吸离心泵故障诊断数据集和轴向数据集上进行了训练和测试,实验结果显示,CNN在基于数据驱动的故障诊断领域具有良好潜力。文献[4]针对轴承故障,利用CNN对轴承信号故障数据进行特征提取和故障检测,实验结果表明,CNN能可靠、有效地提取可分性强的故障特征,提高了系统故障诊断性能。

光伏逆变器是一种功率电子电路器件,其电路结构如图1所示。光伏逆变器能将太阳能电池板的直流电压转换为交流电压,以驱动家用电器或者升压并入能源互联网。图1中,绝缘栅双极型晶体管(insulated gate bipolar transistor, IGBT)是光伏逆变器的核心

部件。当发生开路故障时,尽管系统还能继续运行,但有着很大的隐患,没有发生开路故障的IGBT会流过较大电流,对整个电路系统产生影响,进而影响能源互联网的稳定运行。因此,及时准确地诊断开路故障对能源互联网的稳定运行具有重要意义。同时,使用逆变器输出电压或电流为特征量进行故障诊断时,需要3个传感器进行三相电压或电流信号的检测,但以直流侧电流作为特征量时,则只需要1个传感器。

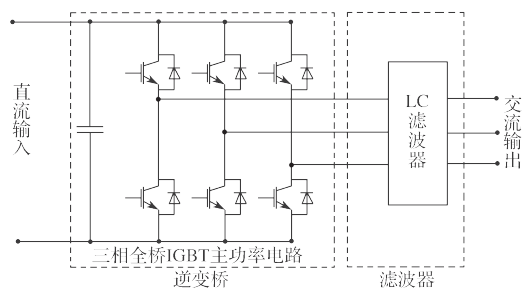


图1 逆变器的电路结构

Fig. 1 Inverter circuit structure

综合以上因素,本研究拟从减少传感器数目的角度出发,采用直流侧电流作为检测量,利用卷积神经网络实现对IGBT开路故障的诊断。

2 光伏逆变器故障仿真

2.1 逆变系统仿真

实验利用Matlab软件中的Simulink仿真模块,搭建了一个光伏逆变器仿真模型,如图2所示。

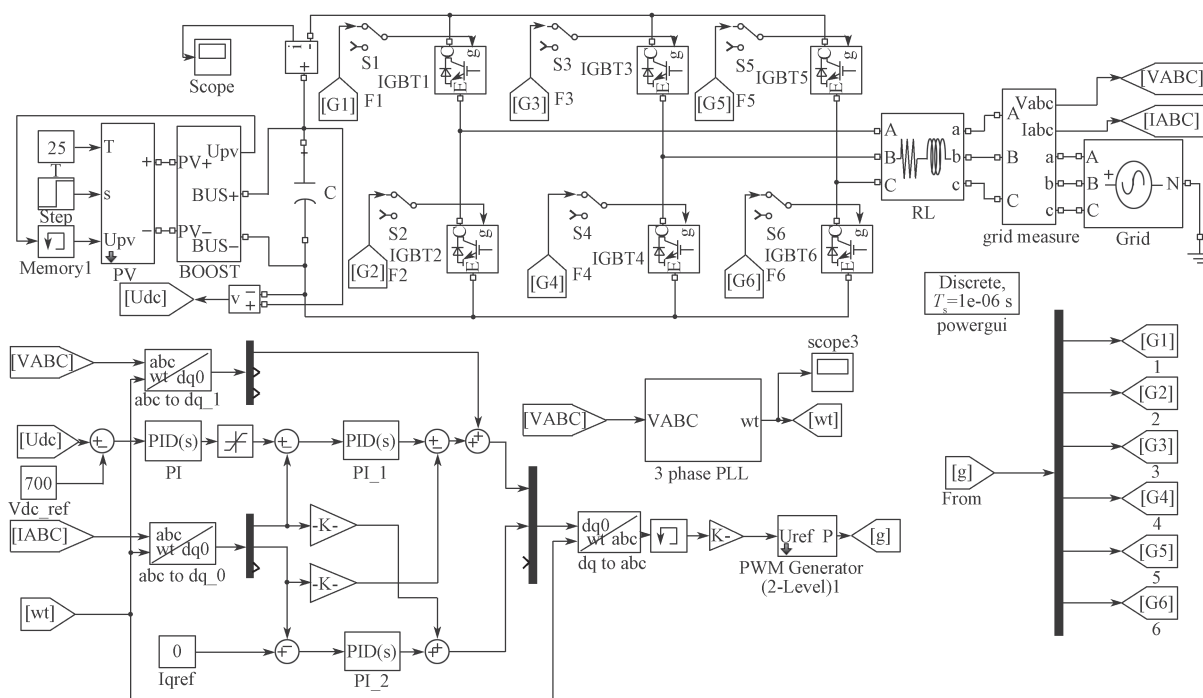


图2 光伏逆变器故障仿真图

Fig. 2 Photovoltaic inverter fault simulation diagram

实际光伏发电系统中, 当光照强度发生变化时, 其输入逆变系统中的电压会发生变化。仿真系统的光照强度在 0.25 s 时由 0.7 kW/m² 突变为 1.0 kW/m², 为抑制由此引起的电压波动, 加入了相应的控制模块, 以实现输出电压的稳定控制^[5]。

本研究的仿真电路图, 主要由光伏与 Boost 电路模块、逆变器、滤波电感、电压电流双闭环控制策略模块以及驱动信号模块 5 部分组成。该系统可以有效地在光照强度发生变化时快速地将输出电压调节到所需电压, 保证系统的稳定性^[6]。运用这个仿真系统来模拟真实电路中的 IGBT 开路故障, 选择的做法是添加开关来控制激励信号, 当某个开关断开时, 相应的桥臂就不会收到触发脉冲, 这样该桥臂的 IGBT 就不会导通, 就相当于 IGBT 管开路。在三相桥式逆变电路中有 6 个 IGBT 管 (每个 IGBT 反并联 1 个二极管), 每个 IGBT 管都是有可能发生故障的, 但是发生故障时, 1 个或者 2 个 IGBT 管故障的概率极高, 很少有 3 个或 3 个以上 IGBT 管同时发生故障^[7], 所以本文中只分析 IGBT 管 1 个或者 2 个发生开路时的情形。根据三相桥式逆变电路的构造, 共有 6 种单管故障情形。当有 2 个管子发生故障时: 1) 同一相两个桥臂同时发生故障; 2) 上桥中两个桥臂同时发生故障; 3) 下桥中两个桥臂同时发生故障; 4) 上下桥臂交叉的同时发生故障, 总计有 15 种故障。因此, 加上正常状态, 总计有 22 种状态类别。

2.2 数据采集

每个故障在实验中的持续时间均为 4.1 s, 而前 0.1 s 系统刚刚通电, 数据的波动巨大, 所以舍去这一部分数据, 故数据采集的时间为 0.1~4.1 s。在正常工作状态下, 输出电压频率为 50 Hz, 也就是 0.02 s 为一个周期。通过设计的仿真模型采集正常工作和各种不同故障下的直流侧电流数据, 用作实验的训练和测试数据。所得的仿真电流图显示, 虽然不同故障的运行时间相同, 但获得的直流侧电流数据数量是不一样的。为了保证输入数据的维度一致性, 需要对电流进行等时间采样, 采样频率为 10 000 Hz, 这样可以保证数据的维度一致。且为了更好地提取数据特征, 需要加大数据集, 同时输入网络的数据维度大小对于神经网络训练也非常重要。因此, 在数据输入网络模型之前对数据进行了预处理——数据移动。数据检测步长的大小需要通过实验来确定一个最佳值, 检测步长代表两次检测的时间差, 在采样频率固定的情况下, 就代表两次检测的样本移动长度。数据移动后, 样本集的数量会增加。例如, 实验中采用了一种如图 3 所示的移动方法。




图3 数据移动示意图

Fig. 3 Schematic diagram of data movement

由图 3 可知, 一段原始采样样本总共有 2 000 个数据, 首先将其前 400 个数据划为一个数据片段 (1~400 个采样数据), 之后以步长为 200 向右移动, 对数据进行划分得到第二个数据片段 (201~600 个采样数据)。按照这种移动方法, 最后就可以将原始的长度为 2 000 的数据, 划分为 9 个长度为 400 的数据片段。总共采集了 352 段训练数据样本, 最后可以得到 3 168 (352 × 9) 条训练数据片段。对测试样本也采取相同的处理方法, 总共采集了 88 条训练数据片段, 这样移动后就得到 792 (9 × 88) 条测试数据片段。

从仿真模型中采集而来的数据不存在噪声, 为模拟实际的噪声情况, 后续处理中对数据都加入了不同信噪比的噪声, 通过观察数据集可以发现, 数据的最大最小值相差很大, 为了提高模型的收敛速度, 对数据进行了标准化预处理。标准化处理的目的是将数据按比例缩放, 使之落入一个小的特定区间, 则标准化公式如下:

$$\hat{x}_i = \frac{x_i - \min X}{\max X - \min X} \quad (1)$$

式中, 数据 $X = \{x_1, x_2, \dots, x_n\}$ 的元素 x_i 经过标准化后为 \hat{x}_i 。

3 一维卷积神经网络

3.1 卷积层

卷积神经网络是一种应用广泛的前馈神经网络, 已在很多领域中成功应用^[8]。通常情况下, 卷积神经网络包括输入层、卷积层、池化层、全连接层和输出层^[9]。数据进入卷积神经网络后, 首先进入卷积层进行卷积运算, 也就是卷积核与输入数据进行局部加权求和^[10]。在实际运用中, 往往是由多个输入特征图和多个卷积核组成, 为方便理解, 以图 4 展示一个输入特征图和一个卷积核时的运算。在卷积运算结束后, 加上偏置项后选用 ReLU 激活函数提升卷积神经网络的表达能力和抑制梯度消失现象^[11]。

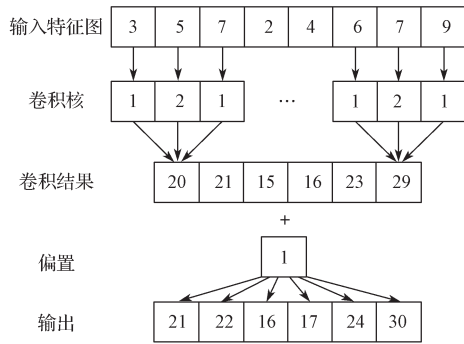


图4 一维卷积运算过程示例

Fig. 4 Illustration of one-dimensional convolution operation process

在卷积层中，每一个输出特征图都是由多个输入特征图组合的卷积结果，例如，第 $l-1$ 层的特征图经过卷积和激活后输出第 l 层的特征图，其前向传播公式为

$$a^l = \sigma(a^{l-1} * W^l + b^l) \quad (2)$$

式中： a^{l-1} 是第 $l-1$ 层的输出特征图的集合，同时是第 l 层的输入特征图的集合；

a^l 为第 l 层的输出特征图的集合；

W^l 为第 $l-1$ 层到第 l 层卷积核的集合；

b^l 为第 $l-1$ 层到第 l 层的偏置项；

* 表示卷积作用；

$\sigma(\cdot)$ 为激活函数。

推导可得卷积层的反向传播公式如下：

$$\delta^{l-1} = \frac{\partial J}{\partial z^{l-1}} = \delta^l \cdot \frac{\partial z^l}{\partial z^{l-1}} = \delta^l * \text{rot180}(W^l) \odot \sigma'(z^{l-1}) \quad (3)$$

式中： z^l 为第 l 层的卷积结果，且

$$z^l = a^{l-1} * W^l = \sigma(z^{l-1}) * W^l;$$

δ^{l-1} 为第 $l-1$ 层的梯度；

δ^l 为第 l 层的梯度；

$\text{rot180}(\cdot)$ 表示将核旋转 180 度；

\odot 表示对应元素相乘。

由 $z^l = a^{l-1} * W^l + b^l$ ，可进一步推导出其权重导数和偏置导数，分别如下：

$$\frac{\partial J}{\partial W^l} = \frac{\partial J}{\partial z^l} \frac{\partial z^l}{\partial W^l} = \delta^l * \text{rot180}(a^{l-1}), \quad (4)$$

$$\frac{\partial J}{\partial b^l} = \sum_k (\delta^l)_k \quad (\text{所有 } k \text{ 子项求和}) \quad (5)$$

3.2 池化层

在卷积神经网络中，池化层的作用是将卷积层输出的特征图缩小，有最大池化、最小池化、平均池化、随机池化等^[12]。图 5 列出了最大池化和平均池化的运算结果，通常最大池化可以有效地提取特征，比较适用于分类问题。本文模型中采用了最大池化，

从目标区域中取出最大值，通过池化层的二次提取特征进行降维，进一步降低网络的计算量。经过多次的卷积和池化运算后，即可获得数据特征，最后连接到全连接层进行分类^[13]。




图5 一维池化运算示例

Fig. 5 Illustration of one-dimensional pooling operation

从 l 层到第 $l+1$ 层的池化前向传播公式如下：

$$a_j^{(l+1)} = \sigma(\text{down}(a_j^l)) \quad (6)$$

式中， $\text{down}(\cdot)$ 是一个下采样方法，池化层窗口大小为 $n \times 1$ ，则对池化层窗口滑过的每一个 $n \times 1$ 块中的元素进行相对应的池化运算，得到一个 1×1 的输出特征图，缩小为原来的 $1/n$ 。

根据反向传播方法，可推得池化层的反向传播公式为

$$\delta^{l-1} = \frac{\partial J}{\partial z^{l-1}} = \frac{\partial J}{\partial z^l} \cdot \frac{\partial z^l}{\partial a^{l-1}} \cdot \frac{\partial a^{l-1}}{\partial z^{l-1}} = \text{upsample}(\delta^l) \cdot \sigma'(z^{l-1}), \quad (7)$$

式中， $\text{upsample}(\delta^l)$ 表示上采样操作，即将每个元素在一个维度上展开 n 次，还原到池化之前的大小， n 为 $\text{down}(\cdot)$ 下采样时缩小的比例。

CNN 在池化层反向传播时如图 6 所示，对于池化层的梯度 δ^l ，首先还原为池化前的长度，然后根据池化类型进行数值分配，如果采用的是最大池化，就需要将 δ^l 中的数值分配到池化前的最大位置处，如果采用的是平均池化，就将 δ^l 等分为 n 份再分配到各个位置处。

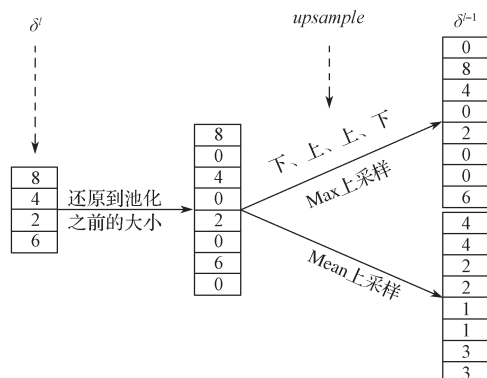


图6 池化层的反向传播示例

Fig. 6 Illustration of back-propagation in the pooling layer

通过上述卷积层和池化层的反向传播，可以求得参数的梯度，这样就可以利用梯度下降法来更新所构建的卷积神经网络中所有的参数，最后得到一个能实际运用的模型。

4 实验结果和分析

4.1 检测步长

为验证所提方案的可靠性, 将本文模型与支持向量机 (support vector machines, SVM) 和 k 最近邻 (k -Nearest Neighbor, kNN) 分类算法进行比较。

1) SVM 故障诊断方法。采用与 CNN 模型相同的数据集, 选用线性核函数, 运用间接法的多分类器进行故障诊断。

2) kNN 故障诊断方法。kNN 通过测量不同特征值之间的距离进行分类。如果一个样本在特征空间中的 k 个最邻近的样本中的大多数属于某一个类别, 则该样本也被划分为这个类别。在 kNN 的参数设置中, $k = 9$ 。

为了确定最佳检测数据步长, 课题组采用了信噪比为 10 dB 的数据进行训练与测试。逆变器正常工作时, 输出的三相电压频率为 50 Hz, 直流侧电流的采样频率为 10 000 Hz, 因此在输出电压的一个周期 (0.02 s) 时间内, 可以采集到 200 个电流值。为此, 以 200 为中心, 分别将数据检测步长 100, 150, 200, 250, 300 输入到已经搭建好的网络模型 (CNN 参数设置如表 1 所示) 中进行训练与测试, 得到如图 7 所示的 3 种方法下不同检测步长对应的测试结果图。

表 1 CNN 网络参数

Table 1 CNN network parameters

层名	输出数据大小 @ 通道数	卷积核大小 @ 个数	池化方式 和长度	激活 函数
Conv1	398 × 1@16	3 × 1@16	最大池化 2 × 1	ReLU
Conv2	197 × 1@32	3 × 1@32	最大池化 2 × 1	ReLU
Conv3	96 × 1@64	3 × 1@64	最大池化 2 × 1	ReLU
Flatten	3 072			
FC1	1 024			ReLU
FC2	512			ReLU
Softmax	22			




图 7 不同检测步长下 3 种方法的准确率比较

Fig. 7 Accuracy comparison of three methods under different moving steps

由图 7 可以看出, 不同的检测步长对最后的测试准确率有一定的影响, 当检测步长为 100, 150,

250, 300 时, 得到的结果都不理想, 当检测步长为 200 时, 得到的检测效果最佳。因此, 本文后续实验中将步长 200 设置为默认检测步长。当检测步长为 200 时, 可以得到 3 168 条训练数据, 每条包含 400 个样本点。将数据进行标准化后输入 CNN 模型中, 经过相应的卷积和池化后, 将数据串联并传入全连接层, 此外为防止过拟合对全连接层使用了 Dropout^[14] 技术, 最后接 SoftMax 函数输出, 得到该条数据所对应的故障类别概率分布。

4.2 对比结果

为了验证 CNN 模型的实用性, 分别将信噪比为 5, 1, 0, -1 dB 的数据放入网络中进行训练和测试, 所得实验结果如图 8 所示。

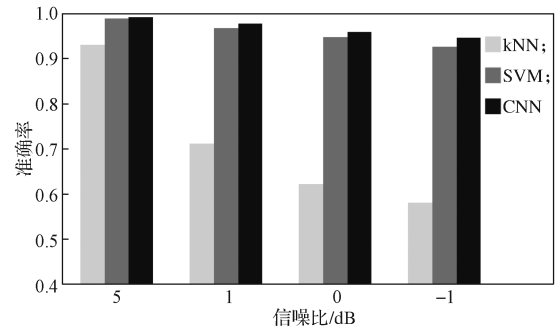


图 8 不同信噪比下 3 种方法的准确率比较

Fig. 8 Accuracy comparison of three methods under different SNR

由图 8 可以得知, kNN 在低信噪比故障数据分类中的准确率最低, 这说明 kNN 方法的噪声鲁棒性比较弱。与 kNN 相比, SVM 和 CNN 的分类准确率均有显著的提升, 其中 CNN 在三者中的准确率最高, 5, 1, 0, -1 dB 信噪比下的准确率分别是 0.992 4, 0.978 5, 0.959 6, 0.945 9。这一结果说明, 在逆变器开路故障诊断性能上, CNN 相对其他的算法效果更好。

5 结语

本文以光伏逆变器的直流侧电流为研究对象, 提出了一种基于 CNN 的光伏逆变器故障诊断新方法。实验结果表明, 在 CNN 网络结构中, 数据的检测步长为 200 时, 故障诊断效果最佳。另外, 为了测试该实验方法的鲁棒性和适用性, 将 5, 1, 0, -1 dB 的高斯白噪声人工添加到数据集中。得到的实验结果表明, 该方法在不同噪声水平下仍然能获得高于 94% 的故障诊断准确率。

在后续研究中, 准备搭建一个基于 Dspace 的逆变电路模型, 获取实际模型的故障数据, 利用仿真模型和实际模型开展迁移学习方面的研究。

参考文献:

- [1] KHAN T, ALEKHYA P, SESHADRINATH J. Incipient Inter-Turn Fault Diagnosis in Induction Motors Using CNN and LSTM Based Methods[C]//2018 IEEE Industry Applications Society Annual Meeting (IAS). Portland: IEEE, 2018: 1-6.
- [2] LIANG K W, QIN N, HUANG D Q, et al. 1D Convolutional Neural Networks For Fault Diagnosis of High-Speed Train Bogie[C]//2018 IEEE 23rd International Conference on Digital Signal Processing (DSP). Shanghai: IEEE, 2018: 1-5.
- [3] WEN L, LI X Y, GAO L, et al. A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Method[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.
- [4] BHADANE M, RAMACHANDRAN K I. Bearing Fault Identification and Classification with Convolutional Neural Network[C]//2017 International Conference on Circuit, Power and Computing Technologies (ICCPCT). Kollam: IEEE, 2017: 1-5.
- [5] 钟杰. 光伏并网逆变器 MPPT 及双闭环控制技术研究[D]. 成都: 西南交通大学, 2013.
ZHONG Jie. Research on MPPT and Double Closed-Loop Control Technology of Photovoltaic Grid-Connected Inverter[D]. Chengdu: Southwest Jiaotong University, 2013.
- [6] 王晖辉. 三相光伏并网逆变器的设计与仿真[D]. 郑州: 郑州大学, 2004.
WANG Huihui. The Design and Simulation of the Three-Level Photo Voltage Grid Connected Inverter[D]. Zhengzhou: Zhengzhou University, 2004.
- [7] 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.
- [8] 孙志军, 薛磊, 许阳明, 等. 深度学习研究综述[J]. 计算机应用研究, 2012, 29(8): 2806-2810.
SUN Zhijun, XUE Lei, XU Yangming, et al. Overview of Deep Learning[J]. Application Research of Computers, 2012, 29(8): 2806-2810.
- [9] 李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508-2515, 2565.
LI Yandong, HAO Zongbo, LEI Hang. Survey of Convolutional Neural Network[J]. Journal of Computer Applications, 2016, 36(9): 2508-2515, 2565.
- [10] 赵璐, 马野. 基于一维卷积神经网络的齿轮箱故障诊断研究[J]. 测试技术学报, 2019, 33(4): 302-306.
ZHAO Lu, MA Ye. Fault Diagnosis of Gear Box Based on One-Dimensional Convolutional Neural Networks[J]. Journal of Test and Measurement Technology, 2019, 33(4): 302-306.
- [11] 田娟, 李英祥, 李彤岩. 激活函数在卷积神经网络中的对比研究[J]. 计算机系统应用, 2018, 27(7): 43-49.
TIAN Juan, LI Yingxiang, LI Tongyan. Contrastive Study of Activation Function in Convolutional Neural Network[J]. Computer Systems & Applications, 2018, 27(7): 43-49.
- [12] 陈旭, 张军, 陈文伟, 等. 卷积网络深度学习算法与实例[J]. 广东工业大学学报, 2017, 34(6): 20-26.
CHEN Xu, ZHANG Jun, CHEN Wenwei, et al. Convolutional Neural Network Algorithm and Case[J]. Journal of Guangdong University of Technology, 2017, 34(6): 20-26.
- [13] SAINATH T N, MOHAMED A R, KINGSBURY B, et al. Deep Convolutional Neural Networks for LVCSR[C]//2013 IEEE International Conference on Acoustics, Speech and Signal Processing. Vancouver: IEEE, 2013: 8614-8618.
- [14] 任义丽, 罗路. 卷积神经网络过拟合问题研究[J]. 信息系统工程, 2019(5): 140, 142.
REN Yili, LUO Lu. Research on Convolutional Neural Network Overfitting[J]. Information System Engineering, 2019(5): 140, 142.

(责任编辑: 廖友媛)