

基于卷积神经网络的光伏系统直流串联电弧故障检测

焦治杰¹, 李 腾¹, 王莉娜², 牟龙华³, Alexandra Khalyasmaa⁴

(1. 北京交通大学电气工程学院, 北京 100044;

2. 北京航空航天大学自动化科学与电气工程学院, 北京 100191;

3. 同济大学电子与信息工程学院, 上海 201804;

4. 乌拉尔联邦大学电气系统自动化学院, 叶卡捷琳堡 620002, 俄罗斯)

摘要: 本文提出一种新颖的基于卷积神经网络的光伏系统直流串联电弧故障检测方法。首先采用短时傅里叶变换提取电流信号的时频信息,以能量谱密度作为电流的时频联合能量函数,构造电流的时频谱图,然后以时频谱图中各时频点的能量谱密度作为卷积神经网络的输入,设计卷积神经网络算法实现电弧故障检测。经实验验证,所提出方法可清晰区分电弧故障电流特征和正常工作电流特征;在实验室测试中,所提出方法可准确地检测出光伏系统直流串联电弧故障。

关键词: 光伏系统; 串联电弧; 直流电弧; 短时傅里叶变换; 卷积神经网络

DOI: 10.12067/ATEEE1905065

文章编号: 1003-3076(2019)07-0029-06

中图分类号: TM930.12

1 引言

随着光伏产业的不断发展,光伏系统老化引起的直流电弧故障问题日益突出^[1-4]。由于串联电弧故障电流相对来说较小,难以被保护装置检测到^[5],一旦发生,将对线路或设备造成危害^[6],甚至造成火灾^[7-9]。因此,需设置额外的串联电弧故障检测装置,目前,光伏系统直流串联电弧故障检测已引起国内外学者的广泛关注^[10,11]。

目前,在飞机、电动汽车、直流低压配电柜等领域,对直流串联电弧故障检测已有深入研究^[12]。但是,由于光伏系统的输出特性受日照强度、温度和局部阴影的影响,光伏系统的直流电流特性与上述系统存在本质区别,因此,现有理论和方法并不能很好地适用于光伏系统直流串联电弧故障的检测。

目前,国内外对光伏系统直流串联电弧故障检测已开展研究,已出现的检测方法可归纳为三种:电弧物理特征法^[13]、时域特征法^[1,14]和频域特征法^[9,12,15]。频域特征法因检测准确率高,且不易受负载变化和系统输出特性的影响等优点,为国内外学者所青睐。文献[1]采用小波变换提取信号频域

特征,采用时域、频域混合判据对电弧故障进行综合判定,但判据的动作门槛值需依据历史数据或人类经验人为设定。文献[2]采用快速傅里叶变换提取信号频域特征,采用BP神经网络根据特定频率范围的幅值对电弧故障进行判定,但BP神经网络收敛速度慢,容易陷入局部极小值^[16]。文献[9]采用经验模态分解提取信号频域特征,根据本征模态分量的归一化熵值,采用模糊C均值聚类法进行故障电弧检测,但在算法中加入白噪声的大小与集成的次数需要根据经验人为设定。

本文提出一种新颖的基于卷积神经网络(Convolutional Neural Network, CNN)的电弧故障检测方法,采用短时傅里叶变换,构造信号的时频联合能量谱函数作为CNN的输入,通过CNN实现故障电弧的检测。根据实验室实测结果,所提出方法能够准确地识别电弧故障状态和正常工作状态。

2 实验数据库的建立

本文所用数据全部来自于文献[1]所述的电弧故障实验平台,该实验平台参考UL1699B(UL standard for safety for arc-fault circuit-interrupters)标

收稿日期: 2019-05-29

基金项目: 国家重点研发计划项目(2018YFB1500802)

作者简介: 焦治杰(1996-),男,山西籍,硕士研究生,研究方向为光伏系统电弧检测;

王莉娜(1977-),女,河南籍,特聘研究员,博士,研究方向为电力电子与电力传动(通讯作者)。

准搭建,详见文献[1]。

数据采集由霍尔电流传感器及示波器实现,利用示波器边沿触发功能采集正常工作及故障电弧状态下的电流信号,示波器的采样频率为400MHz。将采集的数据进行数字高通滤波,滤除直流和低频成分,然后将滤波后的数据保存至串联电弧电流数据库,用于形成故障电弧识别算法及算法可靠性的检验。经过高通滤波器后的串联电弧故障电流波形和正常工作电流波形分别如图1、图2所示。由图1和图2可知,发生串联电弧故障时,高频信号幅值明显增大,因此,本文将基于频域特征法展开研究。

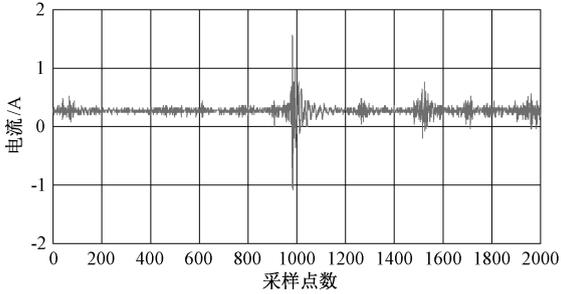


图1 串联电弧故障电流波形

Fig. 1 Waveform of arc-fault current

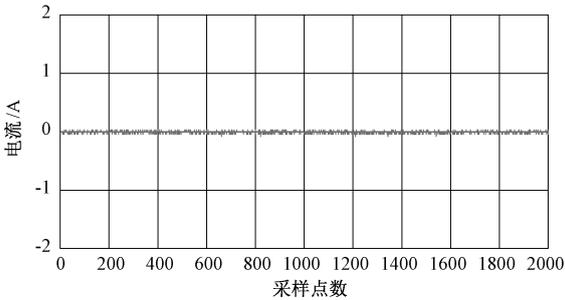


图2 正常工作电流波形

Fig. 2 Waveform of normal operation current

3 时频谱分析

电弧既具有时间随机性,又具有频率随机性。本文提出采用时频分析方法,分析故障电弧电流特征,即通过构建时间和频域的联合函数(能量谱密度),区分故障和正常时的信号特征,从而实现故障识别。由于采集所得的电流信号是时域信息,要进行时频分析,需首先得到信号的频域信息。本文采用短时傅里叶变换获取信号的频域信息。

3.1 短时傅里叶变换

短时傅里叶变换通过对傅里叶变换加时间窗,将时域分段,对时域上的每一小段分别做傅里叶变

换,从而建立时域和频域的关联。若采样周期为 T_s ,则在 $t=kT_s$ 时刻,频率为 $m\Delta f_c$ (Hz)的频率分量幅值的计算式为:

$$\begin{cases} X(k, m) = \sum_{n=0}^{N-1} x(n)g(n-k)e^{-j2\pi\frac{m}{M}n} \\ k = 0, 1, \dots, N-M \\ m = 1, 2, \dots, M \end{cases} \quad (1)$$

式中, Δf_c 为频率分辨率(在频率轴上的最小频率间隔); $x(n)$ 为连续时间信号 $x(t)$ 在 $t=nT_s$ 时刻的采样值; $g(n-k)$ 为窗函数 $g(t)$ 在 $t=(n-k)T_s$ 时刻的采样值; M 为窗函数的宽度(即时间窗内的采样点数); N 为总的的数据量。 $X(k, m)$ 即建立了 $x(t)$ 的频域信息与时间的关联。

在短时傅里叶变换中,时间窗的时间宽度决定了短时傅里叶变换对时间的分辨能力和对频率的分辨能力。窗的时间宽度越长,即截取的信号点数越多,傅里叶变换后对频率的分辨能力越高,而对时间的分辨能力越差,即对信号突变的敏感性越差。可见,短时傅里叶变换对时间的分辨能力和对频率的分辨能力相互制约。实验中为保证获取清晰的时频谱图,经过反复实证,窗函数采用长度为363个采样点的海明窗,滑动步长为9。

3.2 能量谱密度

在时频分析中,能量谱密度是时间和频率的联合函数,它可以很好地反映信号在某一时刻某一频率成分的强弱。电流采样信号为实信号,实信号的能量谱密度计算式为^[17]:

$$P(k, m) = \frac{2T_s}{\sum_{i=1}^M |g(i)|^2} |X(k, m)|^2 \quad (2)$$

由式(2)可知,能量谱密度值与频率分量的幅值的平方成正比。可见,采用能量谱密度可以放大频谱变化梯度。

以时间为横坐标,以能量谱密度值为纵坐标,构造信号的时频谱图。在本文设计的电弧故障检测算法中,时频谱图的像素设置为 182×182 。对电弧故障电流与正常工作电流分别进行时频分析,获取的时频谱图分别如图3和图4所示。可以看出,发生电弧故障时,信号在大部分频率点的能量谱密度会显著增加,而正常工作信号各个点的能量谱密度基本保持不变。即当发生电弧故障时,时频谱图中能量谱密度变化梯度会迅速增加,由此,使得运用卷积神经网络识别串联电弧故障成为可能。

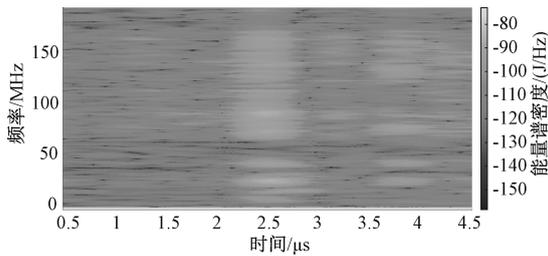


图3 串联电弧故障电流时频谱图

Fig. 3 Time-frequency spectrum of arc-fault current

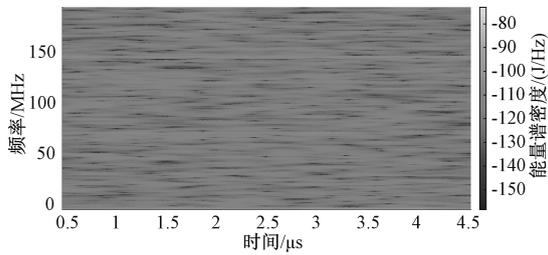


图4 正常工作电流时频谱图

Fig. 4 Time-frequency spectrum of normal operation current

4 基于 CNN 的串联电弧故障检测方法

卷积神经网络是通过模仿动物的视觉而构造的一种具有卷积计算的前馈神经网络。它识别图像的原理是:将图像的每个像素点的明暗程度量化,用 CNN 建立像素点量化值间的梯度关系,用此关系来识别图像。在检测电弧故障时,将电流的时频谱图中的所有像素点(182×182)对应的能量谱密度作为 CNN 的输入,用 CNN 的输出来辨别光伏系统中是否有电弧故障发生。

4.1 CNN 的构建

CNN 的结构可以分为输入层、隐含层和输出层。输入层用来接收时频谱图信息,即由各像素点的能量谱密度构成的二维数组。输出层输出故障电弧判别结果。隐含层包括卷积层、池化层和全连接层,用来对输入的数据进行特征识别。在时频谱图中很大一部分相邻像素点的能量谱密度变化梯度不明显,所以先将输入数据进行池化处理,以提高计算速度。本文设计的隐含层的具体构筑为:池化层-卷积层-池化层-卷积层-池化层-单层感知机,如图 5 所示。

CNN 层与层之间的连接方式有两种,分别是稀疏连接和全连接。稀疏连接结构与全连接结构分别如图 6、图 7 所示。稀疏连接结构的特点是,第 $k+1$ 层的每个神经元只与第 k 层的部分神经元连接。全

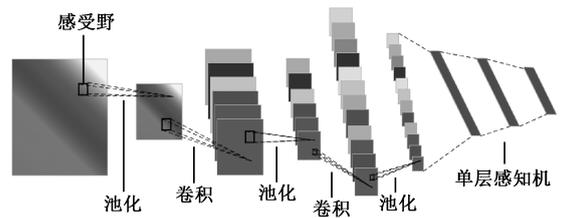


图5 CNN 的构造

Fig. 5 Construction of CNN

连接结构的特点是,第 $k+1$ 层的每个神经元与第 k 层的全部神经元连接。在本文设计的电弧故障检测算法中,由于图片的像素点较多,如果隐含层全部采用全连接结构,计算机的计算量将变得非常庞大。所以卷积层和池化层采用稀疏连接结构。

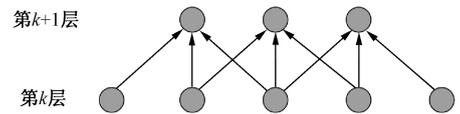


图6 稀疏连接结构

Fig. 6 Sparse connection structure

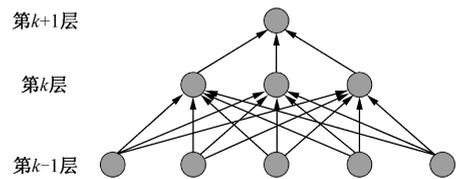


图7 全连接结构

Fig. 7 Fully connected structure

卷积层通过用不同的卷积核作用于图像来提取图片的特征,不同的卷积核提取不同的特征。在提取每张图片独特性的同时,会导致同一类样本出现独特性的多样性。为了包容同一类图片个体之间的差异,本文设计的电弧故障检测算法中设置了两层卷积层,每层有两个卷积核。根据上一层输出数组的大小,设置两个卷积层中卷积核的大小分别为 34×34 和 16×16 。

池化层将卷积层输出的结果进行降维,降到原来的一半,从而把原来的准确描述变为概略描述,可在一定程度上防止过拟合的发生。在本文设计的电弧故障检测算法中,三层池化层的滤波器(用于提取图片特征的矩阵)的大小均设置为 2×2 ,池化步长为 2。为了突出图片特征,CNN 的池化方式采用了最大值池化。

将前面池化层的输出重新排列成一维数组,输入到单层感知机。单层感知机对前面 5 层处理的结

果进行处理,输出判断结果。单层感知机的结构类似于单层 BP 神经网络。

在 CNN 中,所有层都是由神经元构成。单个神经元结构如图 8 所示。其中, f 表示神经元的激活函数。卷积层的激活函数选取线性激活函数,输入与输出的函数关系为:

$$y = \sum_{i=1}^n a_i \omega_i + b \quad (3)$$

式中, a_i 为神经元的输入; ω_i 为每个输入对应的权重; b 为神经元的偏置; y 为神经元的输出; n 为神经元的输入个数。

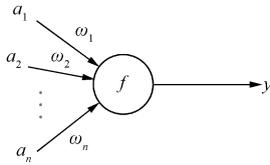


图 8 单个神经元结构

Fig. 8 Single neuron structure

单层感知机的激活函数选取 sigmoid 函数,其输入输出关系为:

$$y = \frac{1}{1 + e^{-\sum_{i=1}^n a_i \omega_i + b}} \quad (4)$$

在本文设计的电弧故障检测算法中,将所有神经元的偏置 b 初始化为 0,权重按式(5)初始化:

$$\omega_0 = \frac{h}{\sqrt{6/(p+q)}} \quad (5)$$

式中, h 为 $-1 \sim 1$ 之间的随机数; p 为输入神经元的数目; q 为输出神经元的数目。

4.2 CNN 的训练

时频谱图中各点的能量谱密度归一化处理,作为 CNN 的输入。CNN 输出 0 表示该信号为正常信号,输出 1 表示该信号为故障信号。

将样本导入 CNN,按已经设置好的参数完成前向计算。按式(6)计算输出误差:

$$\delta = y' - y \quad (6)$$

式中, δ 为输出误差; y' 为理想输出结果,电弧故障时理想输出结果为 1,正常工作时理想输出结果为 0; y 为前向计算实际输出结果。将输出误差代入目标函数,用梯度下降法对目标函数进行优化,实现误差的反向传播,同时优化所有神经元的权重和偏置。在本文设计的电弧故障检测算法中,设置目标函数为:

$$E_d = \frac{1}{2} \delta^2 \quad (7)$$

以上过程完成了一轮机器学习。若没有达到预设的学习次数,则将权值更新后,重复上述过程,直到达到预设次数为止。CNN 实际输出结果与理想输出结果的均方误差曲线如图 9 所示。

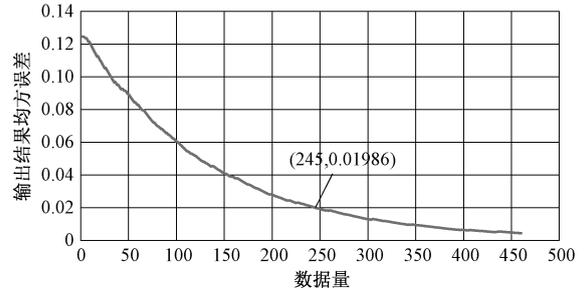


图 9 均方误差曲线

Fig. 9 Mean square error curve after training

由图 9 可以看出,在样本数据量为 245 时,训练输出结果的均方误差已经减小至 0.02 以下。随着学习样本数的增加,输出结果的均方误差将不断减小。

4.3 实验结果

用测试数据对训练好的 CNN 进行测试,测试结果如表 1 所示。

表 1 CNN 测试结果

Tab. 1 Test result of CNN

故障数据组别	测试结果	正常数据组别	测试结果
1	1	1	0.1044
2	0.9982	2	0.1089
3	1	3	0.1044
4	1	4	0.1220
5	1	5	0.1249
6	1	6	0.1270
7	1	7	0.1072
8	1	8	0.1044
9	0.9997	9	0.1051
10	1	10	0.2654

表 1 中,电弧故障数据判别结果大部分为 1,正常工作数据判别结果在 0 附近波动。电弧故障数据的最小值为 0.9982,正常工作数据的最大值为 0.2654。显然,运用卷积神经网络算法能够清晰地区分出电弧故障电流和正常工作电流。所以运用卷积神经网络对电流时频谱图的能量谱密度进行分析,输出结果能够准确地判别出是否发生了串联电弧故障。

5 结论

本文提出一种基于 CNN 的光伏系统直流串联电弧故障检测方法。所提出方法先对采集的电流数据进行时频分析,将时频点的能量谱密度作为 CNN 的输入,采用 CNN 实现电弧故障的识别。根据实验室实测结果,所提出方法能够准确地检测出光伏系统直流串联电弧故障。

实验结果显示,CNN 的实际输出结果与理想输出结果在数值上有微小的偏差,这是由实验数据有限所致。但从输出结果的均方误差曲线趋势可以看出,只要有足够多的样本数据,输出结果能够非常接近于理想结果。

所提出方法主要有三个优点:①不需要根据经验设定电弧故障特征量判别标准,可减小人为因素对判别准确率的干扰;②通过机器学习能够完全将光伏系统的电弧故障状态与正常运行状态区分开,可实现较高的判别准确率;③可以通过设置池化步长、卷积步长以及卷积核的大小来加快收敛速度。经过实测,所提出方法完全可移植到光伏系统中进行直流电弧故障检测。

参考文献 (References):

[1] 牟龙华, 王伊健, 蒋伟, 等 (Mu Longhua, Wang Yijian, Jiang Wei, et al.). 光伏系统直流电弧故障特征及检测方法研究 (Study on characteristics and detection method of DC arc fault for photovoltaic system) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2016, 36 (19): 5236-5244.

[2] 吴春华, 冯夏云, 袁同浩, 等 (Wu Chunhua, Feng Xiayun, Yuan Tonghao, et al.). 基于 BP 神经网络的光伏故障电弧检测方法研究 (Photovoltaic arc fault detection method based on BP neural network) [J]. 太阳能学报 (Acta Energiæ Solaris Sinica), 2016, 37 (11): 2958-2964.

[3] He C, Mu L, Wang Y. The detection of parallel arc fault in photovoltaic systems based on a mixed criterion [J]. IEEE Journal of Photovoltaics, 2017, 7: 1717-1724.

[4] Lu S, Phung B T, Zhang D. A comprehensive review on DC arc faults and their diagnosis methods in photovoltaic systems [J]. Renewable and Sustainable Energy Reviews, 2018, 89: 88-98.

[5] 张士文, 张峰, 王子骏, 等 (Zhang Shiwen, Zhang Feng, Wang Zijun, et al.). 一种基于小波变换能量与神经网络结合的串联型故障电弧辨识方法 (Series arc

fault identification method based on energy produced by wavelet transformation and neural network) [J]. 电工技术学报 (Transactions of China Electrotechnical Society), 2014, 29 (6): 290-295.

[6] Shibo L, Tharmakulasingam S, Phung B T. DA-DCGAN: An effective methodology for DC series arc fault diagnosis in photovoltaic systems [J]. IEEE Journal of Photovoltaics, 2019, 7: 45831-45840.

[7] Georgijevic N, Jankovic M, Srdic S, et al. The detection of series arc-fault in photovoltaic systems based on the arc current entropy [J]. IEEE Transactions on Power Electronics, 2015, 31 (8): 5917-5930.

[8] Chen S, Li X, Xiong J. Series arc fault identification for photovoltaic system based on time-domain and time-frequency-domain analysis [J]. IEEE Journal of Photovoltaics, 2017, 7: 1105-1114.

[9] 吴春华, 徐文新, 李智华, 等 (Wu Chunhua, Xu Wenxin, Li Zhihua, et al.). 光伏系统直流电弧故障检测方法及其抗干扰研究 (Study on detection method and its anti-interference of DC arc fault for photovoltaic system) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2018, 38 (12): 3546-3555.

[10] Shekhar A, Ramirez-Elizondo L, Bandyopadhyay S, et al. Detection of series arcs using load side voltage drop for protection of low voltage DC systems [J]. IEEE Transactions on Smart Grid, 2018, 9 (6): 6288-6297.

[11] Telford R, Galloway S, Stephen B, et al. Diagnosis of series DC arc faults: A machine learning approach [J]. IEEE Transactions on Industrial Informatics, 2017, 13 (4): 1598-1609.

[12] 董伟, 张俊民, 桂美景, 等 (Dong Wei, Zhang Junmin, Gui Meijing, et al.). 基于小波包分解的航空故障电弧的识别 (Identification of aviation arc fault based on wavelet packet decomposition) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2018, 37 (11): 76-81.

[13] 陈照, 李奎, 张洋子, 等 (Chen Zhao, Li Kui, Zhang Yangzi, et al.). 基于电弧电磁辐射的故障电弧识别 (Arc fault detection based on electromagnetic radiation) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2017, 36 (3): 70-74.

[14] 林方圆, 苏建徽, 赖纪东 (Lin Fangyuan, Su Jianhui, Lai Jidong). 光伏系统直流故障电弧识别方法研究 (Study on detection method of DC arc fault in PV systems) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2015, 34 (12): 7-13.

[15] 黄佳平 (Huang Jiaping). 基于 BP 神经网络的直流

- 电弧故障检测技术研究 (Research on DC arc fault detection technology based on BP neural network) [D]. 杭州: 杭州电子科技大学 (Hangzhou: Hangzhou Dianzi University), 2017.
- [16] 张宏建, 孙志强 (Zhang Hongjian, Sun Zhiqiang). 现代检测技术 (Modern detection technology) [M]. 北京: 化学工业出版社 (Beijing: Chemical Industry Press), 2007. 9.
- [17] Zhivomirov H. On the development of STFT-analysis and ISTFT-synthesis routines and their practical implementation [J]. TEM Journal, 2019, 8 (1): 56-64.

DC series arc-fault detection of photovoltaic system based on convolutional neural network

JIAO Zhi-jie¹, LI Teng¹, WANG Li-na², MU Long-hua³, Alexandra Khalyasmaa⁴

(1. School of Electrical Engineering, Beijing Jiaotong University, Beijing 100044, China;

2. School of Automation Science and Electrical Engineering, Beihang University, Beijing 100191, China;

3. School of Electronics and Information Engineering, Tongji University, Shanghai 201804, China;

4. Department of Automated Electric Systems, Ural Federal University, Ekaterinburg 620002, Russia)

Abstract: A novel DC series arc-fault detection method for photovoltaic systems based on convolutional neural network is proposed. Firstly, the short-time Fourier transform is used to derive the time-frequency information of the current. Then energy spectral density, acted as the time-frequency joint function, is used to construct the time-frequency spectrogram of the current. The coordinate information on the time-frequency spectrogram of the current is inputted to the convolutional neural network. And the convolutional neural network is trained to discriminate the arc-fault current and normal operation current. Experiments verified that the proposed method can make a clear distinction between the arc-fault current and normal operation current. In the experiments, the DC series arc-fault current of the photovoltaic system can be detected accurately.

Key words: photovoltaic system; series arc; DC arc; short-time Fourier transform; convolutional neural network