[高压开关]

基于多源信号输入卷积神经网络的高压开关故障诊断方法

文/广西电网有限责任公司电力科学研究院　林翔宇　王晓明　彭博雅

针对高压开关故障中出现频次最高的机械故障诊断问题，通过模拟试验采集铁心卡涩、弹簧疲劳等典型机械故障时的声音及电流信号，将其进行下采样、滤波后输入到深度学习模型。结果表明该方法的故障识别率可达94%，相比其他传统方法具有较大优势。

高压断路器机械故障辨识是对断路器进行状态监测、异常识别和故障分类。振动、电流和声音等传感器可用来采集断路器运行的各项数据，并根据这些数据预测断路器机械故障的发生以及对故障进行分类。目前，已有部分学者对断路器机械故障识别方法开展了一些研究，并取得了一定成效，但传统的方法仍然存在以下局限：①一些研究主要关注于断路器的机械振动信号，并将其用于故障征兆的预测，如小波变换、经验模态分解等方法均是用于对振动信号进行分析。在这些研究中，必须在断路器表面安装加速度传感器来采集振动信号，加速度传感器的安装拆卸在实际应用中会带来运维不便，同时传感器安装位置也会极大影响辨识效果。②一些研究采用电流信号作为故障识别的依据，主要聚焦于分合闸线圈电流的时间、幅值等波形分析。但受采样频率限制，当采样点中未能包含电流波形的关键特征点时，该类方法的效果将大打折扣。此外，该类方法只能识别与分合闸线圈有关的机械故障，而对驱动机构的故障则无能为力。③传统的断路器机械故障特征是基于人工选择，极大依赖于研究人员的经验和判断，当人工选择的鲁棒性较差时，传统方法的故障分类效果将受到严重影响。

为了克服上述①和②的局限性，多源信号分析可作为一种有效的断路器机械故障诊断思路，综合考虑了声音和电流信号，其中声音信号能反映断路器运行状态，电流信号以时域波形的形式进行采集，便于读取和分析其特征。同时，这两种信号的采集不需要安装复杂的传感器。针对③的局限性，深度学习方法具备强大的特征学习能力，提供了一种有效的解决方案。深度学习架构具有多个隐藏层，可以直接从原始数据中挖掘深层次的特征信息。

综合以上因素，本文采用深度学习的方法对断路器动作的声音和电流信号进行分析，建立了信号采集系统，进行了故障模拟试验，采用预处理方法对数据进行放大和规范化，采用卷积神经网络（CNN）来提取信号特征。基于CNN模型对断路器机械故障诊断进行了深入研究。

试验模拟与故障识别方法

1．信号采集系统

本文研究对象为一种采用弹簧操作机构的220 kVSF_6断路器。声音采集系统主要包含了PCB公司生产的378b02型声音传感器、交直流电流钳、PXI－3342数据采集卡和范华恒兴公司生产的PXI－9106型工业计算机，如图1所示。其中，信号采样频率为200 kHz，电流采样阈值设置为

0.05 A。在电流达到采样阈值时，系统自动记录该时刻前0.25 s和该时刻后0.75 s这一时间窗口内的声音和电流信息。

2．断路器各类型机械故障模拟试验

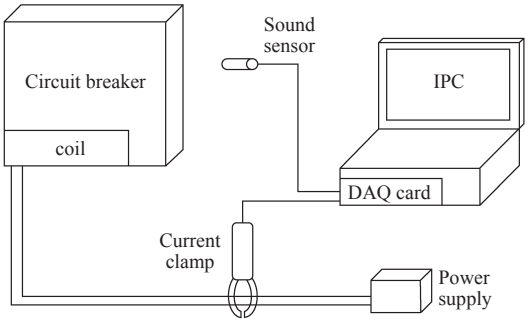

图1　信号采集系统

典型的断路器机械故障类型包括线圈故障、分合闸机构故障、分闸失败及合闸失败等。本文主要考虑铁心卡涩、分合闸机构故障和弹簧疲劳，并具体模拟了正常状态和以下4种故障场景。①在铁心上安装螺栓来模拟铁心卡涩；②将分合闸机构中弹簧1替换为不同弹性的弹簧来模拟分合闸机构故障；③将分合闸机构中弹簧2替换为不同弹性的弹簧来模拟分合闸机构故障；④将分合闸弹簧进行拉伸或压缩来模拟弹簧疲劳。对于每种场景均进行了20次测试，故障模拟示意如图2所示。

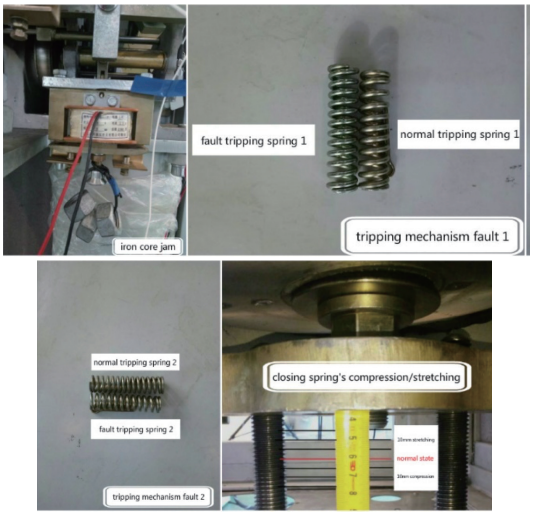

图2　故障模拟示意图

3．卷积神经网络

一个CNN的结构主要包含了卷积层、池化层和全连接层。在卷积层中，声音和电流信号的局部特征及其相关性被卷积核提取出来，通过输入特征图和卷积核之间的一系列卷积运算，这些特征被重新分组。卷积运算可表示为

$$u_q^r = \sum_p \upsilon_p^{r-1} k_q^r + b_q^r \tag{1}$$

式中，v_p^{r-1}；是第$r-1$层的第p个输入；u_q^r是第r层的第q个输出，K_q^r是第r层的第q个卷积核；b_q^r是第q个输出特征图的偏差。

可见，对于同一个输出特征图，不同的输入特征图共享卷积核和偏差。

在卷积运算之后，还会通过一个激励函数对输出特征图进行处理，即

$$h_q^r = \varphi(u_q^r) \tag{2}$$

式中，h_q^r是最终的输出特征图；$\varphi(x)$是非线性激励函数，通常在整个网络中都设置为Relu函数。

为了提高特征图的鲁棒性，减少计算量，在卷积层之后加入一个池化层，本文采用最大池化作为池化层的操作，见式（3）。

$$h_p(i,j) = \max_{0\le m,n<t} \left\{ \upsilon_p(it+m, jt+b) \right\} \tag{3}$$

池化层的本质是将第p个输入特征图v_p中不重叠的$s \times s$大小的局部区域通过下采样得到第p个输出特征图的神经元h_m。全连接层是连接到输出层之前的最后一层，用于预测状态。基于均方差的损耗函数定义为

$$J(\delta; d, y) = \frac{1}{2} \left\| h_\delta(d) - y \right\|^2 \tag{4}$$

式中，d是最后一层的输出特征；y是预期输出；h_δ是回归函数；$\delta=\{w, b\}$是回归函数的参数。

CNN模型通过不断优化参数来减少训练中的损耗。

本文设计的CNN模型共有八层结构，如图3所示，包括四个卷积层、两个最大池化层和两个全连接层。针对采用深层神经网络进行故障诊断的问题，有学者提出随着网络层数的增加，每层网络的节点不断减少，在此降维过程中特征可被不断压缩和挖掘。基于这样的思路，本文的四层卷积层的神经元个数分别设置为128、128、64和64个，对应的卷积核大小分别为11×11、5×5、3×3和3×3。输出层的神经元个数设置为5，分别对应一种正常状态和4种模拟故障状态。本文采用随机梯度下降（SGD）优化器对CNN模型进行训练，训练中将每16个样本打包成一个集合，初始学习率设置为0.001。整个训练是在一台装载了GTX 1060 GPU的64位个人PC机的TensorFlow系统中完成。

4．数据预处理

深度学习比传统方法需要更多的数据来训练

图3　本文CNN网络结构

和调整模型。因此，使用下采样和翻转来扩展数据。相关文献指出，采样频率为200 Hz的声音信号足以用于此类断路器的故障分析。因此，将声音信号从200 kHz下采样至0.4 kHz。另外，将声音信号垂直翻转后亦可用于训练神经网络。电流信号下采样至0.4 kHz并保持其波形。然后将声音信号和其对应的电流信号叠加并归一化后成为400×200的图像。数据预处理的过程如图4所示。

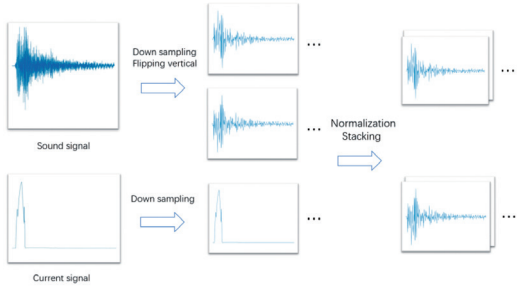

图4　数据预处理过程

通过以上操作，原始声音信号和电流信号被组合成1 000张复合图像。其中，随机选取10%的图像作为训练样本，选取50%来对CNN模型参数进行调整，剩余40%用于验证模型识别故障的准确性。因此，对于每个断路器状态，训练集中有5 000个训练样本，验证集中有5 000个验证样本，训练集中的样本被输入到网络中，网络计算损耗和准确度并调整参数。整个数据集经过一次训练称为一个epoch，在运行一个epoch之后，网络将计算验证集的损耗和识别准确度。

结果分析

对正常状态和其中一种故障状态进行训练，验证集的识别准确度可达到100%，见表1～表4。其中，Tra_loss表示训练集损耗，Tra_acc表示训练集准确度，Val_loss表示验证集损耗，Val_accuracy表示验证集准确度。

表1　对正常状态和铁心卡涩故障进行训练的识别效果

epoch	Tra_loss	Tra_acc	Val_loss	Val_acc
1	0.004 55	0.999 6	0.005 16	1.000 0
2	0.023 16	0.996 8	0.003 68	1.000 0
3	0.020 10	0.998 1	0.007 97	1.000 0
4	0.015 51	0.998 4	0.009 13	1.000 0
5	0.005 65	0.999 4	0.008 99	1.000 0

表2　对正常状态和分合闸机构故障（替换弹簧1）进行训练的识别效果

epoch	Tra_loss	Tra_acc	Val_loss	Val_acc
1	0.014 66	0.998 9	0.003 24	1.000 0
2	0.023 67	0.997 5	0.004 59	1.000 0
3	0.020 24	0.998 1	0.004 74	1.000 0
4	0.005 27	0.999 5	0.001 16	1.000 0
5	0.023 30	0.997 7	0.004 34	1.000 0

表3　对正常状态和分合闸机构故障（替换弹簧2）进行训练的识别效果

epoch	Tra_loss	Tra_acc	Val_loss	Val_acc
1	0.010 89	0.999 1	0.002 92	1.000 0
2	0.014 17	0.998 7	0.003 01	1.000 0
3	0.021 35	0.998 1	0.004 42	1.000 0
4	0.031 89	0.996 9	0.006 07	1.000 0
5	0.040 37	0.995 9	0.006 22	1.000 0

表4　对正常状态和合闸弹簧疲劳进行训练的识别效果

epoch	Tra_loss	Tra_acc	Val_loss	Val_acc
1	0.011 95	0.998 9	0.003 33	1.000 0
2	0.020 78	0.997 9	0.004 86	1.000 0
3	0.026 47	0.996 1	0.006 33	1.000 0
4	0.026 01	0.997 4	0.007 57	1.000 0
5	0.011 20	0.998 8	0.003 94	1.000 0

表5展示了对正常状态和所有故障状态进行训练的识别效果。可见，在整个训练过程中，训练集的识别准确度在0.965 9～0.996 2之间，验证集的识别准确度在0.902 0～0.941 2之间。在运行完第一个epoch之后，训练集的准确度就达到了0.96以上，并在以后每个epoch完成后保持在0.99左右。而训练集的损耗在前三个epoch就从0.115 68下降到0.050 08，之后随着训练继续，该损耗又有所上升并在小范围内波动，最后在第10次epoch完成后，其上升至0.104 95。通过数据分析可见，在第五个epoch完成后验证集准确度达到最高值，而在第六个epoch之后该准确度则开始下降。

表5　对所有状态进行训练的识别效果

epoch	loss	Tra_acc	Val_loss	Val_acc
1	0.115 68	0.965 9	0.141 39	0.921 6
2	0.059 55	0.996 2	0.314 66	0.921 6
3	0.050 08	0.996 2	0.277 49	0.921 6
4	0.057 41	0.995 3	0.252 80	0.921 6
5	0.061 44	0.994 8	0.283 57	0.941 2
6	0.081 13	0.985 8	0.223 65	0.941 2
7	0.073 74	0.992 8	0.340 47	0.902 0
8	0.085 81	0.992 8	0.377 83	0.902 0
9	0.075 51	0.992 9	0.221 07	0.941 2
10	0.104 95	0.988 2	0.315 21	0.902 0

（下转第65页）

虚拟现实技术的特点和优势使其成为电力培训领域的重要发展趋势之一。将虚拟现实技术引入电力培训中，能够打破传统培训壁垒，高效传授教学内容，并最大限度地发挥学员的主动性与自适应性，增强培训过程的实践性和真实感，从而提升培训效果。

电网虚拟现实技术应用研究展望

鉴于虚拟现实技术发展特点，推动虚拟现实技术与电网实际工作的创新融合，可以提高生产效率、运维水平及安全水平，能够对电网生产、管理及教育培训等多方面产生广泛影响。未来虚拟现实技术在电网领域的应用研究可从以下方面考虑：

1）对现有电网系统各类设备元件的三维虚拟素材资源分类整合，搭建完整、全面的电网系统虚拟现实资源素材库，为虚拟现实技术在电网各个业务领域的应用奠定素材资源基础。

2）探究虚拟现实通用平台建设，研究不同三维模型的数据转换方法和统一格式规范，提升系统内虚拟现实资源的可移植性和通用性。

3）结合特高压等重大示范工程建设，将虚拟现实技术应用于工程虚拟规划设计、关键设备虚拟巡视及监测等多个方面，助力工程安全高效建设运行、提升工程影响力和示范效果的同时，驱动虚拟现实应用技术能力提升。

4）针对虚拟现实电力培训，制定配套软硬件教学资源及系列课程开发计划，组建高素质虚拟教学师资队伍，搭建具有高度沉浸感与互动性的虚拟现实教学课堂。同时积极开展虚拟现实技术与网络培训技术的有效融合研究，不断促进虚拟现实技术在电力培训中的创新应用。

5）对于虚拟现实产业标准不一的问题，应提高虚拟现实相关电力行业的技术标准制定意识，结合电力系统实际情况，探索虚拟现实电力行业技术标准规范，促进电网领域的虚拟现实生态健康发展。

6）针对系统中具有明确实际应用需求的相关领域，开展虚拟现实技术储备和重点应用，对于促进电网创新发展具有十分积极的意义。

结束语

虚拟现实技术以其突出的技术特点和优势受到诸多行业或领域的青睐，应用前景广泛。在电网领域，虚拟现实技术将成为有效提升工作效率的重要手段。本文在介绍虚拟现实技术概念的基础上，研究论述了虚拟现实技术在电力工程规划设计、电网生产运维检修及电力培训中的应用，并提出了虚拟现技术电网领域研究应用的展望和建议。随着虚拟现实技术的快速发展，虚拟现实技术对电网规划与决策支持、提升安全管控及运行管理水平等产生影响，带来显著的技术和经济效益。EA

（收稿日期：2020.08.19）

（上接第32页）

将本文方法与以下传统的机器学习方法进行比较：方法一采用K-S检验方法提取出声信号的特征，然后将其输入WSVM中；方法二获取线圈电流信号的时间和幅度，并用KNN对其进行分类（$k=10$）。利用本文研究中的样本，上述方法的准确度见表6。在这三种方法中，本文所提出的方法具有最高的准确度。

表6　不同方法的识别效果

识别方法	准确度
方法一	0.91
方法二	0.89
本文方法	0.94

结束语

本文建立了一种信号采集信号来收集断路器分合闸过程中的声音和电流信号，并对断路器的各种机械故障状态进行了模拟，对信号进行下采样、翻转和叠加等预处理操作，将处理后的图像输入到由4个卷积层、2个最大池化层和2个全连接层构成的CNN网络，用于故障特征的提取和故障识别。

结果表明，本文提出方法在断路器机械故障识别方面取得较好的效果。相比其他传统故障识别方法，本文方法识别准确度最高，可达到94%。EA

（收稿日期：2020.06.08）