

DOI: 10.19783/j.cnki.pspc.200335

# 基于卷积深度网络的高压真空断路器机械故障诊断方法

曹宇鹏<sup>1</sup>, 罗林<sup>1</sup>, 王乔<sup>1</sup>, 张建良<sup>2</sup>

(1. 辽宁石油化工大学, 辽宁 抚顺 113001; 2. 浙江大学, 浙江 杭州 310027)

**摘要:** 高压断路器执行机构所产生的振动信号蕴含着丰富的机械状态信息。针对传统基于浅层的振动信号分析法存在特征提取和泛化能力等方面的不足, 提出一种基于卷积神经网络和长短期记忆网络的混合深度网络。该网络利用卷积层对原始振动数据进行特征转换, 结合门控循环单元的局部时域特征表示能力, 对故障敏感特征进行提取。通过对 10 kV 真空断路器振动信号的分析实验表明, 所提出的混合网络模型在 ROC 曲线和 PR 曲线上的诊断性能要优于广泛应用的支持向量机诊断法。这种端到端的故障诊断策略通过振动信号特征的深度映射能够有效提高机械状态故障识别精度。

**关键词:** 高压真空断路器; 深度学习; 故障诊断; 长短期记忆模型

## Fault diagnosis of high-voltage vacuum circuit breaker with a convolutional deep network

CAO Yupeng<sup>1</sup>, LUO Lin<sup>1</sup>, WANG Qiao<sup>1</sup>, ZHANG Jianliang<sup>2</sup>

(1. Liaoning Shihua University, Fushun 113001, China; 2. Zhejiang University, Hangzhou 310027, China)

**Abstract:** Information on mechanical conditions is contained in the vibration signals generated from the actuator control system of a high-voltage vacuum circuit breaker. To overcome the limitation on feature representation in the traditional fault detection methods, this paper proposes a hybrid network model combining a convolutional neural network and a long-short term memory network. The convolution layer and gate recurrent unit in the network are respectively used for the feature conversion and the extraction of local time-domain characteristics of the vibration signals. The feature extracted by the network layers is sensitive to the fault. Experiments on a 10 kV high voltage vacuum circuit breaker show that the proposed method is able to detect various types of mechanical faults. The ROC curve and PR curve show that the diagnostic effect of the proposed model is better than a SVM model. This end-to-end fault diagnosis strategy improves the diagnostic accuracy of the mechanical state of a high voltage circuit breaker by deepening feature mapping.

This work is supported by the National Natural Science Foundation of China (No. 61703191), the Foundation of Liaoning Educational Committee (No. L2017LQN028) and the Scientific Research Foundation of Liaoning Shihua University (No. 2017XJJ-012).

**Key words:** high-voltage vacuum circuit breaker; deep learning; fault diagnosis; long short-term memory

## 0 引言

随着我国经济的不断发展, 对电力系统稳定运行的要求也不断地提高。高压断路器是电力系统中的关键设备之一。断路器既要保障电力系统正常供电, 又要承担当电气设备发生故障时可以快速将其切除的责任。所以高压断路器的正常运行是确保电

力系统稳定运行的基础。国内外的统计分析表明, 高压断路器发生的 2/3 以上的故障都是因为其机械性能差所造成的, 其中主要是由操动机构的不正常动作所引起的。所以能够实时识别高压断路器的缺陷和故障是非常必要的<sup>[1-5]</sup>。

高压断路器机械操作的过程中蕴含丰富的振动信号, 采用适当的方法可以有效地提取出故障状态下振动信号的特征值, 从而可以准确地判断断路器是否发生故障及故障的类型。断路器分合闸线圈电流可以反映出所控制的机构在操作过程中的工作情况, 对该电流信号的监测也是非常重要的<sup>[6]</sup>。将带

**基金项目:** 国家自然科学基金项目资助(61703191); 辽宁省教育厅青年项目资助(L2017LQN028); 辽宁石油化工大学科研启动基金项目资助(2017XJJ-012)

电运行时的电流信号及机械操作时的振动信号共同作为输入信号,提取可有效表征状态的特征因子,可进一步分析发生缺陷的部件及位置,从而快速有效地进行断路器的状态监测与诊断<sup>[7-8]</sup>。基于振动信号的非侵入式故障诊断方法由于数据采集方便,逐渐成为研究的主流。为了有效提取高压断路器振动信号的特征,文献[9]提出了一种基于变分模态分解(Variational Mode Decomposition, VMD)和多尺度熵的特征提取方法。利用VMD对振动信号进行预处理,获取所需的模态分量,然后通过支持向量机对所获得的特征向量进行诊断,确定故障类型。文献[10]通过经验模态分解(Empirical Mode Decomposition, EMD)求取Hilbert值,提取断路器振动信号的特征向量,再用粗糙集理论对特征向量进行故障诊断,从而区分断路器发生的不同故障。文献[11]采用基于小波包对数能量熵来对高压断路器的机械状态进行诊断。将正常状态下和故障状态下的信号进行分解,通过计算出各个节点的故障状态相对正常状态的对数能量熵,来确定故障类型。

近年来,深度网络如卷积神经网络(Convolutional Neural Networks, CNN)和长短期记忆神经网络(Long Short-Term Memory, LSTM)的发展推动了人工智能在电力设备方面的诸多应用<sup>[12-14]</sup>。CNN是由输入层、卷积层、池化层、全连接层组成。在输入层接收到的高压断路器的机械振动信号包含多层时间序列,这些以时间序列为样本的数据组成了指标图像数据集。在数据收集的过程中,对每个采样点同步使用差分拟合法,可以获得高压断路器机械振动信号的特征向量。通过对比分析未知状态与典型正常工作状态下指标图集的相似因子,可以识别未知运行状态的类型并实现对高压断路器机械状态的诊断<sup>[15-18]</sup>。LSTM通过输入门、输出门和遗忘门对样本的联合作用可以有效地解决传统神经网络中梯度消失和梯度爆炸的问题<sup>[19-22]</sup>。

本文提出了一种结合卷积神经网络和长短期记忆网络的混合网络模型。该方法将高压断路器机械动作时的振动信号特征提取与机械故障诊断相结合,从而得到一种端到端的故障诊断策略。避免了故障信号特征提取与诊断策略独立进行所产生的故障信息缺失问题,从而提高了高压断路器状态诊断的精度。通过在高压真空断路器上的实验表明了该方法的有效性。

## 1 卷积神经网络模型

传统的基于浅度神经网络机械故障识别方法存在识别精度低、识别效率低、训练速度慢等缺点。

深度神经网络比浅层神经网络拥有更多的层次结构,来获取振动信号中更深层的机械状态信息,可以及时对用电设备的机械状态进行诊断。

深度神经网络中的卷积神经网络可以用来处理大量、复杂的振动信号。在过去的几年里,许多学者利用卷积神经网络的局部感受能力、共享权值的优点来加速训练进程。2012年Krizhevsky提出深度卷积神经网络在影像分类中的应用吸引了众多研究者的关注。这使深度学习进入了全面发展的阶段。近些年,利用卷积神经网络进行机械故障诊断,在仿真结果中具有高达99.5%的准确率,要远远高于其他神经网络模型<sup>[23]</sup>。现已证明,在不考虑尺度、位移和失真的情况下,卷积神经网络具有保持数据信息稳定的能力。卷积神经网络通过滤波器对输入的样本信息进行卷积操作获取有效的特征信息;卷积神经网络发挥其权值共享的优势可以加速训练进程;在池化层采用最大池化操作可以保留样本中最为突出、重要的特征信息。一维的卷积神经网络在最后一次池化操作后,将提取的特征向量转换为二维向量,分类器可以快速地对二维向量进行诊断<sup>[24]</sup>。

采用卷积神经网络可以有效地对断路器的机械振动信号进行特征提取。首先,通过预先设定步长的滑动滤波器对输入信号进行卷积运算,卷积运算可以遍历整个样本,从而获取样本中的故障信息,然后将信息传递给池化层。在池化层进行非线性激活有助于减少样本数量以及避免过度拟合来达到加快训练速度的目的。这也可以看作是一个平滑的过程,从中可以消除不必要的噪声。最后,将之前获取的局部信息传递给全连接层来连接所有之前的特征映射,获取完整的特征向量,最终进行故障诊断。

CNN在训练过程中考虑了样本在维度上的特性而忽视了样本在时间序列上的特性,因此可能会造成在训练过程中样本序列特征信息丢失的现象发生,降低了最终的机械状态诊断精度。LSTM在训练过程中采用自适应的方式来对振动信号中的特征向量进行提取,避免信息丢失,并且提取的特征向量包含时序特性。本文提出的结合卷积神经网络和长短期记忆网络的混合网络模型(CNN-LSTM),在对断路器的机械状态诊断过程中,既考虑了原始样本中的多维度特性也考虑了时间序列特性,提高了断路器机械状态的诊断精度。

## 2 卷积长短期记忆模型

传统的故障诊断模型是将特征提取与建模过程分别独立进行的。所提取出的特征表达能力在一定

程度上依赖于所选参数, 特征表达能力强弱将直接影响后续建模过程。本文结合深度学习中的卷积网络及长短期记忆模型, 提出一种特征提取与序列分类相结合的“端到端”深度学习模型。

## 2.1 卷积层

在输入层接收到的高压断路器的机械振动信号包含多层时间序列  $\{A_1, \dots, A_n\}$ , 这些以时间序列为样本的数据组成了网络层上的特征。在卷积和池化层, 使用  $n$  个卷积滤波器对特征集进行处理来获取  $n$  个特征向量和  $n$  个特征图。对所有以时间序列输入的机械振动信号提取特征, 对应的特征向量在区域矩阵中进行叠加, 叠加公式为

$$X_{A_n}^{\text{dataset}} = \text{ReLU}(\text{dataset}, A_n) \quad (1)$$

式中,  $\text{ReLU}$  是非线性的激活函数。CNN 的隐含层是由若干个卷积层和池化层组成。卷积层中包含卷积滤波器  $W_c \in \mathbf{R}^{d \times h}$ , 其中  $h$  代表步长,  $d$  代表特征向量的维度。滤波器产生的特征向量表示为

$$C = f\left(\text{conv}\left(X_{A_n}^{\text{dataset}} * W_c\right) + b\right) \quad (2)$$

式中,  $b$  是偏置向量。池化层对卷积层输出的样本进行二次采样。池化层对每个滤波器的输出结果进行最大池化操作得到输出值如式(3)所示。

$$X_{A_n}^{\text{map}} = \max\{C\} \quad (3)$$

采用最大池化操作有如下两个原因: (1) 通过消除非最大值, 减少了计算量; (2) 最大池化运行时拥有平移不变的性质。从池化层中获取的特征向量输入到序列中。为了对高压断路器机械振动信号的相关性进行在线检测, 将 LSTM 引入序列层进行矢量合成。

## 2.2 长短期记忆模型

长短期记忆神经网络最早是由 S.Hochreiter 等外国学者提出的深度神经网络模型, 用来解决传统神经网络无法处理的长距离依赖问题<sup>[25]</sup>。LSTM 体系结构由一组重复连接的子网组成, 也称为内存块。记忆单元中设置了 3 种门结构: 遗忘门、输入门和输出门, 用于提供连续的读、写及重置单元的操作。LSTM 网络与标准 RNN 相同, 只是隐藏层中的求和单位被内存块替换<sup>[26]</sup>。这里采用一种树状结构来解决传统 LSTM 过分依赖训练序列的问题, 其结构图如图 1 所示。对于每个母节点, 都存在两个子节点  $h_n, c_n$ , 分别表示节点的隐藏状态和存储单元。由图 1 可知,  $X$  是从 CNN 网络中获取的作为 LSTM 的输入特征数据,  $Y$  是预测标签。节点  $n$  的传递方程为

$$\begin{bmatrix} C_n \\ f_n^l \\ f_n^r \end{bmatrix} = \begin{bmatrix} \tan h \\ \sigma \\ \sigma \end{bmatrix} T_{a,b} \begin{bmatrix} X_j \\ h_n^l \\ h_n^r \end{bmatrix} \quad (4)$$

式中:  $X_j$  代表输入向量;  $l$  和  $r$  表示左右子节点;  $\sigma$  表示 sigmoid 函数;  $T_{a,b}$  表示线性变化, 其中  $a$  和  $b$  是学习出的网络参数。然后, 将 LSTM 的输出端连接到 softmax 分类器并得到高压断路器机械振动信号的分类结果。基于 CNN-LSTM 的诊断模型如图 2 所示。

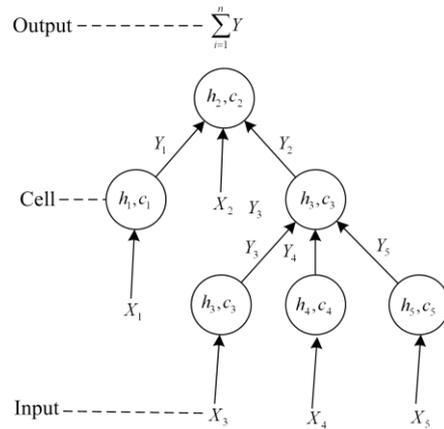


图 1 具有树结构的 LSTM 模型

Fig. 1 LSTM with a tree structure

CNN-LSTM 混合模型充分发挥了卷积神经网络和长短期记忆神经网络的优点, 利用 CNN 网络将大量的断路器振动信号中关联部分与非关联部分的特征信号提取出来, 然后将所提取的有效特征向量输入 LSTM 网络中进行高压断路器的故障诊断。CNN 与传统故障诊断的特征向量提取方法相比能够将大量的振动信号数据按时序窗口创造连续的特征向量图输送给 LSTM 网络, CNN 可以提取有效的故障特征向量, 便于对故障的诊断。LSTM 解决了传统循环神经网络无法处理长距离的依赖问题。

## 3 实验讨论

### 3.1 高压断路器振动信号采集

本文介绍了 ZW32-12FG/630-20 型真空断路器的机械性能测试系统, 该系统用 YD-39 型加速度传感器测量开/关过程中的振动加速度参数, 得到相应的电压。采用 NI9234 数据采集卡对电压进行数字化处理。传感器的测量范围为 0~5 000 m/s<sup>2</sup>, 采样率为 10 kHz。加速度传感器的位置在真空断路器的壳体上, 在壳体上采集垂直振动信号, 比较各种监测方法。实验模拟了 4 种实验类型: 正常状态; 脱扣闭合电磁铁堵塞; 主轴堵塞; 半轴堵塞。

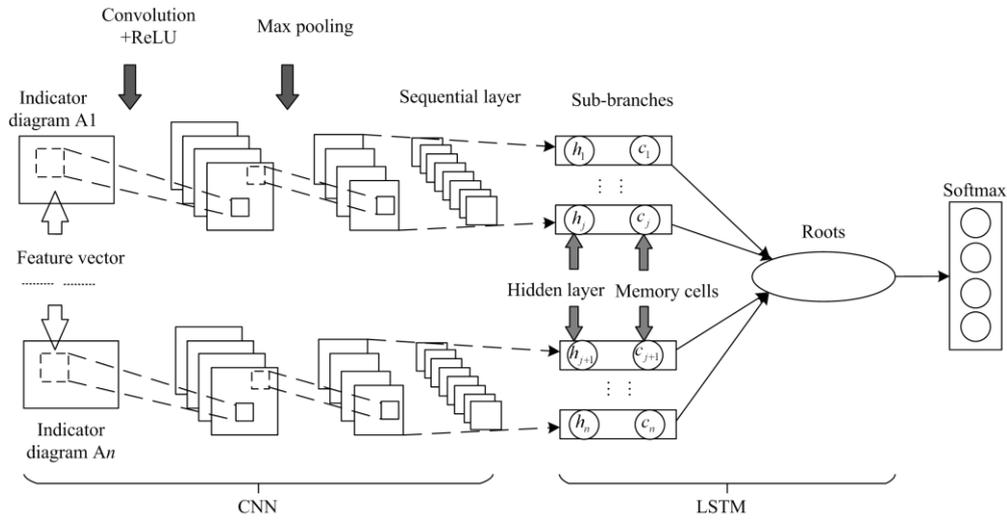


图 2 CNN-LSTM 模型的网络结构

Fig. 2 Network architecture of CNN-LSTM model

在每种情况下进行了 7 次实验，真空断路器正常和故障状态的典型信号如图 3 所示。在这 7 个数据集中，选择其中 3 个作为训练数据集，选择其余的作为每个状态的测试数据集。振动信号在时域上没有明显的差异和变化，由图 3(a)—图 3(d)中的振动信号可以明显看出弱振动信号的特征分析对状态识别尤为重要。

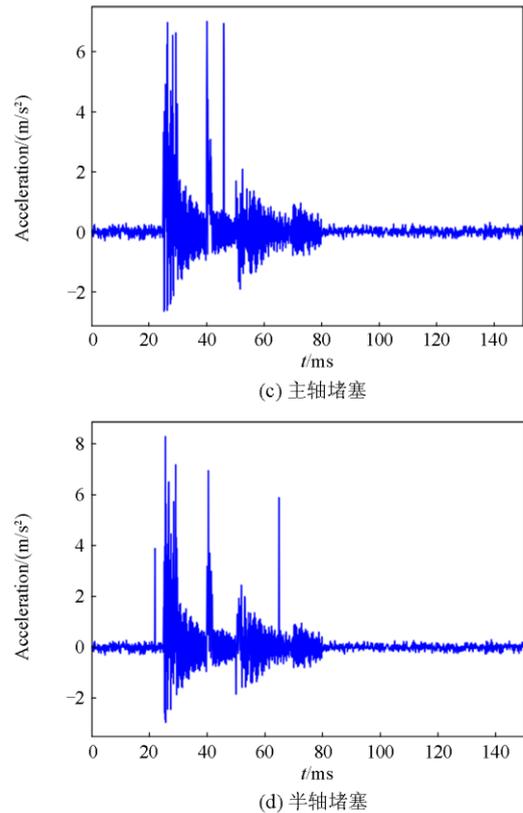
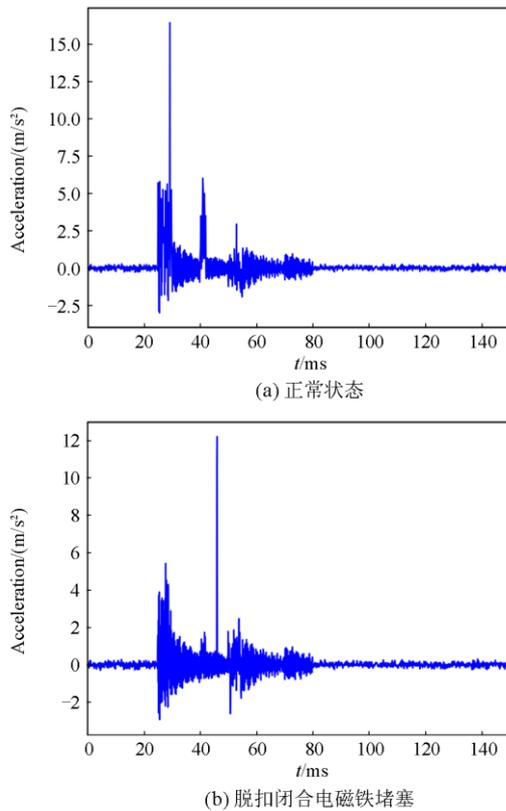


图 3 基于 YD-39 加速度传感器实时采集的 4 种机械状态振动信号

Fig. 3 Acquisition of vibration signals based on YD-39 acceleration sensor in time domain

### 3.2 模型参数设置及评价方法

本文设计的 CNN 有 1 个卷积层和 1 个池化层，卷积滤波器的个数为 64。将卷积核大小设为 1，步

长为1。在池化层中MaxPooling1D的大小为1。CNN网络中的激活函数采用ReLU函数。通过卷积操作和池化操作来减小振动信号的输出维度,然后经过扁平操作(Flatten)对样本进行处理,作为整个网络的特征提取。LSTM模型采用的网络层节点数目为100,激活函数采用sigmoid函数。

ROC曲线可以用来描述诊断模型对高压断路器的振动信号敏感性及其特异性的连续变量指标。以假正率和真正率为横纵坐标绘制曲线,通过设定不同的阈值,计算出曲线与坐标轴围成的面积(AUC),曲线围成的面积越大,诊断的准确精度越高;曲线越靠近左上角,诊断模型对振动信号的变化越灵敏。若正常状态信号样本与故障状态信号样本比例悬殊时可采用查准率-查全率曲线(PR)进一步来判定模型分类性能。以查全率为横坐标,查准率为纵坐标。当查全率不断增大时,查准率始终保持很高的数值,即曲线越接近右上角,此时曲线的爬升越快,在查全率不断增加的情况下,查准率依旧保持较高值,该诊断模型对断路器的机械振动信号的诊断精度就越高;曲线越平滑模型的分类效果越明显。本文采用SVM模型作为对比方法。SVM、CNN-LSTM对相同输入的机械振动信号的样本进行故障诊断,在ROC曲线、PR曲线中对两种模型诊断结果进行评估。表1为故障类型及其编号。

表1 真空断路器三类机械故障编号

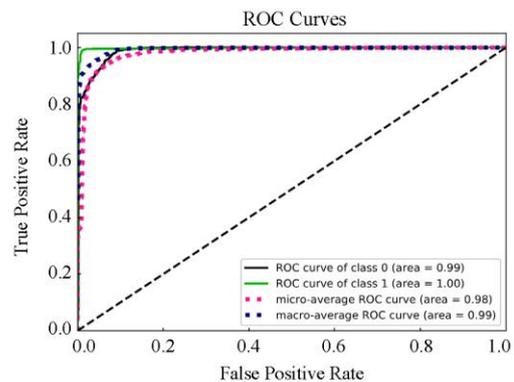
Table 1 Encoding for 3 mechanical fault in vacuum breaker

故障类型	故障编号
脱扣闭合电磁铁堵塞	1
主轴堵塞	2
半轴堵塞	3

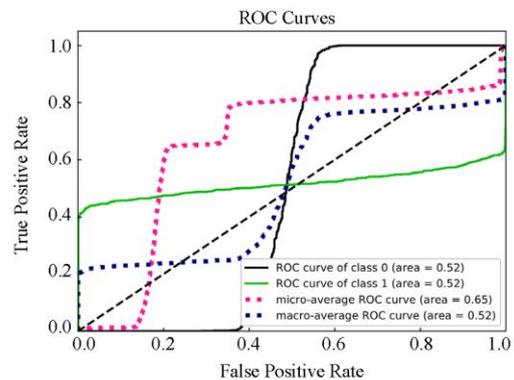
### 3.3 实验分析

实验1: CNN-LSTM与SVM在正常状态与脱扣闭合电磁铁堵塞情况下振动信号的诊断比较。class 0表示正常状态下的振动信号, class 1表示脱扣闭合电磁铁堵塞情况下的振动信号。首先,图4(a)采用CNN-LSTM模型的ROC曲线更接近坐标轴的左上角,诊断精度较高。识别为脱扣闭合电磁铁堵塞的ROC曲线完全将正常状态的ROC曲线包络住,从而可以将故障信号与正常信号进行准确分类。其次,图4(a)中的正常状态和故障状态的曲线随着阈值变化保持平稳变化,而图4(b)的正常状态曲线在此期间出现大幅度波动变化,故采用CNN-LSTM模型对断路器的脱扣闭合电磁铁堵塞的故障趋势能更好地进行预测。最后,由图4(a)可知,采用CNN-LSTM模型的正常状态和第一种故障在ROC

曲线中的AUC的值分别为0.99和1.00,而图4(b)中SVM模型相对应的AUC的值分别为0.52和0.52,采用CNN-LSTM模型的AUC的值更高一些。为进一步分析模型的识别能力,采用图5所示的查准率-查全率(Precision-recall, PR)曲线进行了模型评价。如图5(a)所示,采用CNN-LSTM混合模型的PR曲线相对于图5(b)所示的PR曲线更接近坐标轴的右上角。由此可以说明采用CNN-LSTM模型在训练过程中,无论查全率如何变化都具有较高的查准率。此外,图5(a)中的正常状态和故障状态曲线在诊断过程中随着阈值的变化始终保持平滑,在查全率不断提高的过程中,查准率依旧保持平稳变化。采用CNN-LSTM模型的正常状态和断路器发生脱扣闭合电磁铁堵塞故障时在PR曲线中的AUC的值分别为0.992和0.997,而采用SVM模型所对应的AUC的值分别为0.575和0.629,采用CNN-LSTM模型的AUC值要远远大于采用SVM所对应的值。综上,从ROC曲线和查准率-查全率曲线可以看出,采用CNN-LSTM模型对断路器正常工作时和发生脱扣闭合电磁铁堵塞时的状态诊断均有更高的灵敏性和准确性。



(a) CNN-LSTM



(b) SVM

图4 故障1中CNN-LSTM和SVM所对应的ROC曲线

Fig. 4 ROC curve of CNN-LSTM and SVM in fault 1

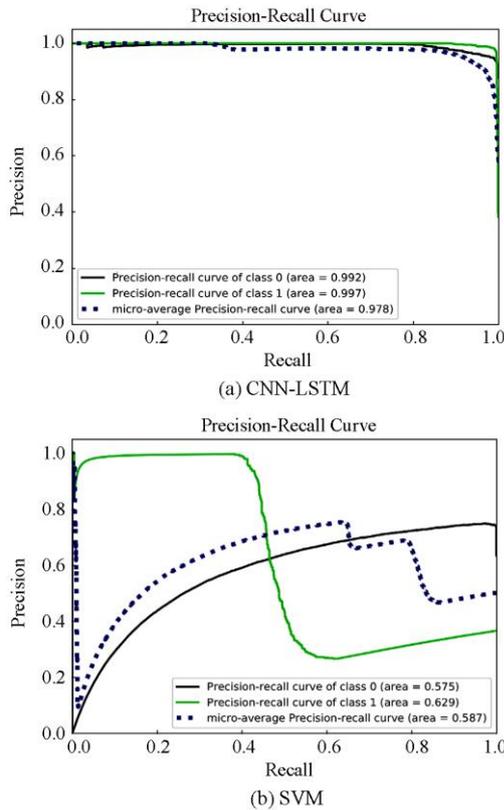


图 5 故障 1 中 CNN-LSTM 和 SVM 所对应的查准率-查全率曲线

Fig. 5 Precision-recall curve of CNN-LSTM and SVM in fault 1

实验 2: CNN-LSTM 与 SVM 在正常状态与发生主轴堵塞故障情况下振动信号的诊断对比。class 2 表示发生主轴堵塞故障下的振动信号。从图 6(a)中可以看出,采用 CNN-LSTM 模型的正常状态和发生主轴堵塞的故障状态的曲线随着阈值变化保持平稳变化,而图 6(b)所示的正常状态曲线在此期间出现大幅度波动变化,采用 CNN-LSTM 模型对断路器的故障趋势能更好地预测。正常状态和发生主轴堵塞时在 ROC 曲线中的 AUC 值分别为 1.00 和 1.00,而 SVM 模型所对应的 AUC 值分别为 0.54 和 0.54,采用 CNN-LSTM 模型的 AUC 值要远远大于采用 SVM 所对应的值。CNN-LSTM 模型的正常状态和发生主轴堵塞时的故障状态曲线在诊断过程中随着阈值的变化始终保持平滑,在查全率不断提高的过程中,查准率依旧保持平稳变化,如图 7(a)所示。采用 CNN-LSTM 模型的正常状态和发生主轴堵塞故障时在 PR 曲线中的 AUC 的值分别为 0.997 和 0.997,而采用 SVM 模型相对应的 AUC 的值分别为 0.585 和 0.647,采用 CNN-LSTM 模型的 AUC

值更高一些。在对主轴堵塞故障和正常状态进行监测时,采用 CNN-LSTM 模型的高压断路器机械状态监测模型对发生主轴堵塞故障和正常状态的分类效果都要强于 SVM 模型,因此更有利于对高压断路器的机械状态进行监测。

实验 3: CNN-LSTM 与 SVM 在正常状态与半轴堵塞情况下振动信号的诊断对比。class 3 表示发生半轴堵塞故障下的振动信号。首先,由图 8(a)可以看出,采用 CNN-LSTM 模型的正常状态和发生半轴堵塞故障时的 ROC 曲线更接近坐标的左上角。

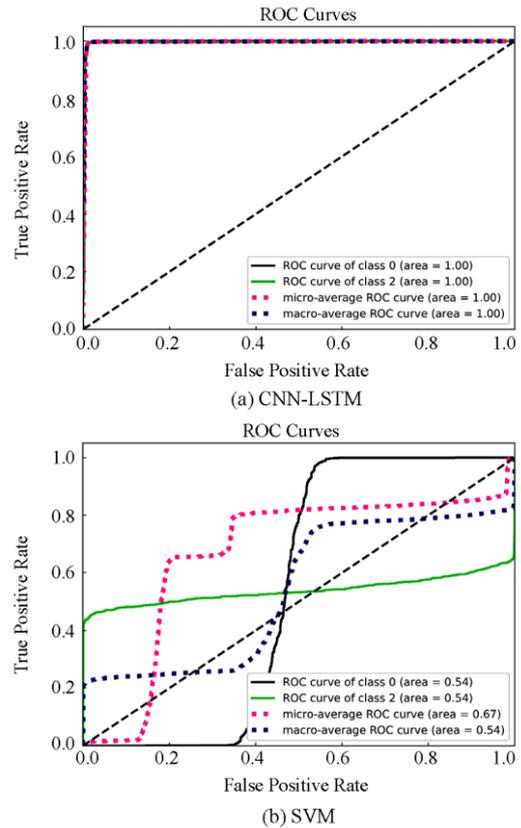
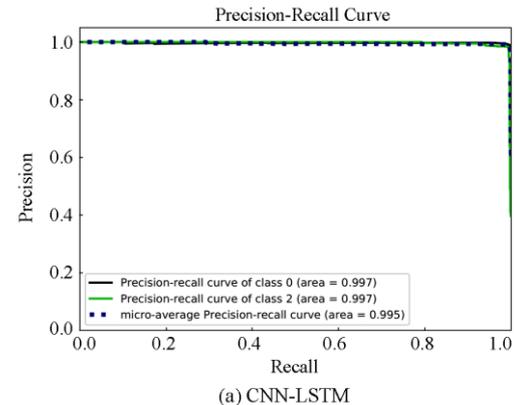


图 6 故障 2 中 CNN-LSTM 和 SVM 所对应的 ROC 曲线



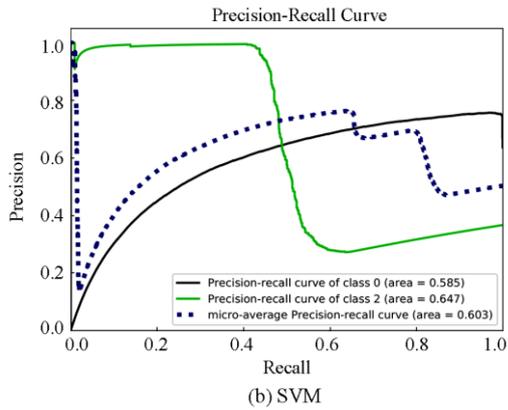
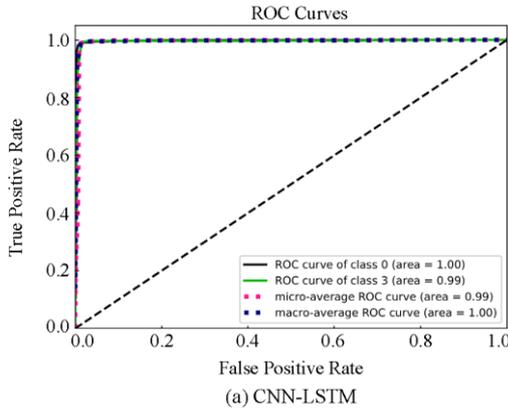
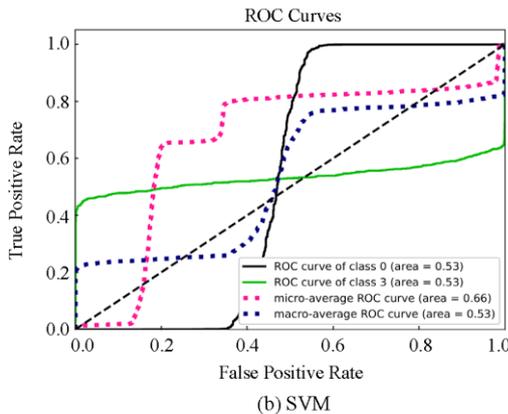


图7 故障2中 CNN-LSTM 和 SVM 所对应的查准率-查全率曲线

Fig. 7 Precision-recall curve of CNN-LSTM and SVM in fault 2



(a) CNN-LSTM



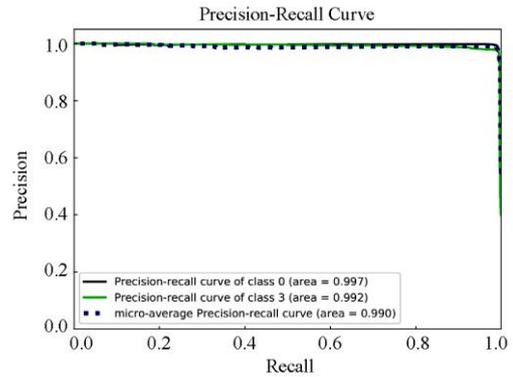
(b) SVM

图8 故障3中 CNN-LSTM 和 SVM 所对应的 ROC 曲线

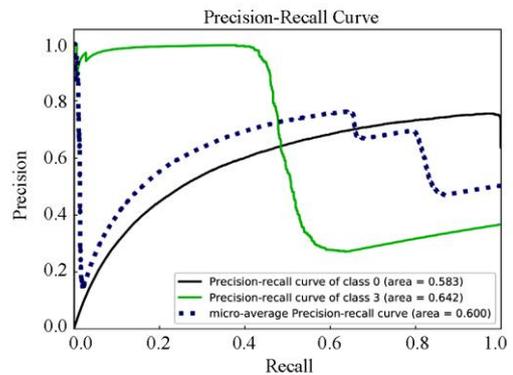
Fig. 8 ROC curve of CNN-LSTM and SVM in fault 3

其次, 采用 CNN-LSTM 模型对断路器发生半轴堵塞时, 真正类率值(True Positive Ratio, TPR)随着阈值的增加稳定地接近于 1, 而图 8(b)中 SVM 模型对于故障诊断的 TPR 值随着阈值的增加维持在 0.4~0.6。CNN-LSTM 模型在正常状态和发生半轴堵塞故障时在 ROC 曲线中的 AUC 值分别为 1.00 和 0.99, 而

SVM 模型相对应的 AUC 值分别为 0.53 和 0.53, 采用 CNN-LSTM 模型的 AUC 值要远远大于采用 SVM 所对应的值。从图 9 中可以看出, 采用 CNN-LSTM 模型的 PR 曲线相对于 SVM 模型的 PR 曲线更接近坐标轴的右上角。图 9(a)中的正常状态和发生半轴堵塞的曲线在诊断过程中始终保持平滑, 在查全率不断提高的过程中, 查准率依旧保持平稳变化。最后, CNN-LSTM 模型在正常状态和发生半轴堵塞故障时在 PR 曲线中的 AUC 值分别为 0.997 和 0.992, 而采用 SVM 模型相对应的 AUC 值分别为 0.583 和 0.642, 采用 CNN-LSTM 模型具有更高的 AUC 值。综上, 从 ROC 曲线和 PR 曲线中可以看出, 无论是对断路器正常状态诊断或者发生半轴堵塞的故障状态诊断, 采用 CNN-LSTM 模型相较于采用 SVM 模型都具有更高的准确性。



(a) CNN-LSTM



(b) SVM

图9 故障3中 CNN-LSTM 和 SVM 所对应的查准率-查全率曲线

Fig. 9 Precision-recall curve of CNN-LSTM and SVM in fault 3

## 4 结论

本文针对传统神经网络对高压断路器机械振动信号提取困难、提取有效特征值速度慢、对特征向量识别不准确的问题, 提出 CNN-LSTM 模型来对

高压断路器进行机械振动信号状态检测。充分发挥 CNN 模型对潜在特征值提取的优势,快速、准确地提取大量有效的特征值, LSTM 网络模型能较好地拟合机械振动信号的时序性和复杂非线性关系,从而有效地对机械振动状态进行识别。

通过三组实验,结果表明采用 CNN-LSTM 模型与采用 SVM 模型进行对比,采用 CNN-LSTM 模型能更快速、准确地提取有效特征向量,更加精确地对特征向量进行诊断。采用 CNN-LSTM 模型随着样本数量的增加依旧可以保持很高的诊断精度,而采用 SVM 模型随着样本数量的增加,诊断精度出现了下降的趋势。故采用 CNN-LSTM 模型相较于传统神经网络能更加准确地对高压断路器的机械故障进行诊断。

### 参考文献

[1] 王竞,夏加富,刘晓晖,等.牵引变电站直流断路器机械状态监测与故障诊断研究[J].电力系统保护与控制,2020,48(1):33-40.  
WANG Jing, XIA Jiafu, LIU Xiaohui, et al. Research on mechanical condition monitoring and fault diagnosis for DC circuit breaker in traction substation[J]. Power System Protection and Control, 2020, 48(1): 33-40.

[2] 杨凌霄,朱亚丽.基于概率神经网络的高压断路器故障诊断[J].电力系统保护与控制,2015,43(10):62-67.  
YANG Lingxiao, ZHU Yali. High voltage circuit breaker fault diagnosis of probabilistic neural network[J]. Power System Protection and Control, 2015, 43(10): 62-67.

[3] 贾嵘,洪刚,薛建辉,等.粒子群优化-最小二乘支持向量机算法在高压断路器机械故障诊断中的应用[J].电网技术,2010,34(3):197-200.  
JIA Rong, HONG Gang, XUE Jianhui, et al. Application of particle swarm optimization-least square support vector machine algorithm in mechanical fault diagnosis of high-voltage circuit breaker[J]. Power System Technology, 2010, 34(3): 197-200.

[4] 刘政光,谭亲跃,周宇博,等.基于 IBAS-BP 算法的 SF6 断路器监测系统优化[J].高压电器,2020,46(6):94-100.  
LIU Zhengguang, TAN Qinyue, ZHOU Yubo, et al. Optimization of SF6 circuit breaker monitoring system based on IBAS-BP algorithm[J]. High Voltage Apparatus, 2020, 46(6): 94-100.

[5] 刘伟鹏,张国钢,刘亚魁,等.基于主成分分析和支持向量机的高压断路器机械状态识别方法[J].高压电器,2020,56(9):267-272.  
LIU Weipeng, ZHANG Guogang, LIU Yakui, et al. Mechanical status identification of high voltage circuit

breakers based on principal component analysis and support vector machines[J]. High Voltage Apparatus, 2020, 56(9): 267-272.

[6] 杨奕飞,焦文文,何祖军,等.基于 IAFSA-SVM 的岸电箱断路器故障诊断[J].电工电气,2019(8):57-61.  
YANG Yifei, JIAO Wenwen, HE Zujun, et al. Circuit breaker fault diagnosis of shore connection box based on improved artificial fish swarm algorithm and support vector machine[J]. Electrotechnics Electric, 2019(8): 57-61.

[7] 万书亭,李聪,豆龙江,等.基于振电结合的高压断路器特征提取及分类方法研究[J].华北电力大学学报:自然科学版,2019,46(4):31-38,53.  
WAN Shuting, LI Cong, DOU Longjiang, et al. Study on the signal feature extraction and classification of high voltage circuit breaker based on vibration signal and current signal[J]. Journal of North China Electric Power University: Natural Science, 2019, 46(4): 31-38, 53.

[8] 张佳,陈志英,陈丽安,等.基于改进集合模态分解的真空断路器分合闸线圈电流特征值提取[J].高压电器,2020,56(12):116-123.  
ZHANG Jia, CHEN Zhiying, CHEN Li'an, et al. Feature extraction of vacuum circuit breaker's opening and closing coil current based on modified ensemble empirical mode decomposition[J]. High Voltage Apparatus, 2020, 56(12): 116-123.

[9] 万书亭,马晓棣,豆龙江,等.基于 VMD-MSE 的高压断路器故障诊断[J].中国工程机械学报,2019,17(5):444-449.  
WAN Shuting, MA Xiaodi, DOU Longjiang, et al. Fault diagnosis method of high-voltage circuit breaker based on VMD and MES[J]. Chinese Journal of Construction Machinery, 2019, 17(5): 444-449.

[10] 林琳,陈志英.基于粗糙集神经网络和振动信号的高压断路器机械故障诊断[J].电工技术学报,2020,35(增刊1):277-283.  
LIN Lin, CHEN Zhiying. Mechanical fault diagnosis of high voltage circuit breakers based on rough set neural networks and vibration signals[J]. Transactions of China Electrotechnical Society, 2020, 35(S1): 277-283.

[11] 李宾宾,柯艳国,田宇,等.基于小波包理论的高压断路器机械状态检测[J].合肥工业大学学报:自然科学版,2019,42(7):924-929.  
LI Binbin, KE Yanguo, TIAN Yu, et al. Mechanical condition detection of high voltage circuit breaker based on wavelet packet theory[J]. Journal of Hefei University of Technology: Natural Science, 2019, 42(7): 924-929.

[12] 文成林,吕菲亚.基于深度学习的故障诊断方法综述[J].电子与信息学报,2020,42(1):234-248.

- WEN Chenglin, LÜ Feiya. Review on deep learning based fault diagnosis[J]. Journal of Electronics & Information Technology, 2020, 42(1): 234-248.
- [13] 汪颖, 孙建风, 肖先勇, 等. 基于优化卷积神经网络的电缆早期故障分类识别[J]. 电力系统保护与控制, 2020, 48(7): 10-18.
- WANG Ying, SUN Jianfeng, XIAO Xianyong, et al. Cable incipient fault classification and identification based on optimized convolution neural network[J]. Power System Protection and Control, 2020, 48(7): 10-18.
- [14] 杨智伟, 刘灏, 毕天姝, 等. 基于长短期记忆网络的PMU不良数据检测方法[J]. 电力系统保护与控制, 2020, 48(7): 1-9.
- YANG Zhiwei, LIU Hao, BI Tianshu, et al. PMU bad data detection method based on long short-term memory network[J]. Power System Protection and Control, 2020, 48(7): 1-9.
- [15] 张鹏, 杨涛, 刘亚楠, 等. 基于CNN-LSTM的QAR数据特征提取与预测[J]. 计算机应用研究, 2019, 36(10): 2958-2961.
- ZHANG Peng, YANG Tao, LIU Yanan, et al. Feature extraction and prediction of QAR data based on CNN-LSTM[J]. Application Research of Computers, 2019, 36(10): 2958-2961.
- [16] 李春, 张代红, 李登武. 基于CNN-LSTM的配电网供电能力研究[J]. 国外电子测量技术, 2019, 38(9): 16-21.
- LI Chun, ZHANG Daihong, LI Dengwu. Study on power supply capacity of distribution network based on CNN-LSTM[J]. Foreign Electronic Measurement Technology, 2019, 38(9): 16-21.
- [17] AL-MASNI M A, KIM D-H, KIM T-S. Multiple skin lesions diagnostics via integrated deep convolutional networks for segmentation and classification[J]. Computer Methods and Programs in Biomedicine, 2020, 190: 105351.
- [18] DO H P, GUO Y, YOON A J, et al. Accuracy, uncertainty, and adaptability of automatic myocardial ASL segmentation using deep CNN[J]. Magnetic Resonance in Medicine, 2020, 83(5): 1863-1874.
- [19] BOGAERTS T, MASEGOSA A D, ANGARITA-ZAPATA J S, et al. A graph CNN-LSTM neural network for short and long-term traffic forecasting based on trajectory data[J]. Transportation Research Part C: Emerging Technologies, 2020, 112: 62-77.
- [20] SONG R, XIAO Z, LIN J, et al. CIES: cloud-based intelligent evaluation service for video homework using CNN-LSTM network[J]. Journal of Cloud Computing: Advances, Systems and Applications, 2020, 9: 7.
- [21] 杜小磊, 陈志刚, 许旭, 等. 基于小波卷积自编码器和LSTM网络的轴承故障诊断研究[J]. 机电工程, 2019, 36(7): 663-668.
- DU Xiaolei, CHEN Zhigang, XU Xu, et al. Fault diagnosis of bearing based on wavelet convolutional auto-encoder and LSTM network[J]. Journal of Mechanical & Electrical Engineering, 2019, 36(7): 663-668.
- [22] 杜小磊, 陈志刚, 许旭, 等. 基于小波、WAE和LSTM的压裂车故障诊断[J]. 石油机械, 2019, 47(10): 88-93, 106.
- DU Xiaolei, CHEN Zhigang, XU Xu, et al. Fracture truck fault diagnosis based on wavelet, WAE and LSTM[J]. China Petroleum Machinery, 2019, 47(10): 88-93, 106.
- [23] 徐艺文, 王芝燕, 李立春, 等. 基于卷积神经网络的水表故障检测算法[J]. 福州大学学报: 自然科学版, 2020, 48(3): 1-5.
- XU Yiwen, WANG Zhiyan, LI Lichun, et al. CNN-based fault detection algorithm for water meter[J]. Journal of Fuzhou University: Natural Science Edition, 2020, 48(3): 1-5.
- [24] 李向伟, 刘思言, 高昆仑. 基于双向长短时记忆网络和卷积神经网络的电力系统暂态稳定评估[J]. 科学技术与工程, 2020, 20(7): 2733-2739.
- LI Xiangwei, LIU Siyan, GAO Kunlun. Power system transient stability assessment based on bidirectional long short term memory network and convolutional neural network[J]. Science Technology and Engineering, 2020, 20(7): 2733-2739.
- [25] HOCHREITER S, SCHMIDHUNBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [26] 明彤彤, 王凯, 田冬冬, 等. 基于LSTM神经网络的锂离子电池荷电状态估算[J]. 广东电力, 2020, 33(3): 26-33.
- MING Tongtong, WANG Kai, TIAN Dongdong, et al. Estimation on state of charge of lithium battery based on LSTM neural network[J]. Guangdong Electric Power, 2020, 33(3): 26-33.

收稿日期: 2020-05-13; 修回日期: 2020-07-02

作者简介:

曹宇鹏(1995—), 男, 硕士研究生, 从事输变电装备在线监测与智能故障诊断的研究; E-mail: 12hgh@sina.com

罗林(1984—), 男, 通信作者, 博士, 讲师, 从事输变电装备在线监测与智能故障诊断的研究; E-mail: luolin@lnpu.edu.cn

王乔(1982—), 男, 博士, 讲师, 从事输变电装备在线监测与智能故障诊断的研究。E-mail: 63526336@qq.com

(编辑 魏小丽)