

智能电网中基于批标准化 LSTM 的 互感器故障诊断技术

曹志强, 陈 洁

(新疆大学电气工程学院, 新疆 乌鲁木齐 830046)

摘 要: 互感器是高压电力系统中的必备设备之一, 一旦互感器发生故障, 将会导致保护装置拒动误动, 造成电网瘫痪。传统的故障诊断和分类方法首先从原始过程数据中提取特征, 然后采用特定的分类器进行诊断, 缺乏对原始数据中动态信息的自适应处理。为了提高传统循环神经网络在诊断中的准确度, 并考虑到长短记忆神经网络诊断时间较长的缺陷, 提出一种基于批标准化的 LSTM 模型的故障诊断方法。该方法无需进行特征提取和分类器设计, 直接对故障进行分类, 并且能自适应学习动态故障数据。通过与其他故障诊断方法比较, 该方法的诊断精度和诊断性能较高, 在互感器故障诊断领域具有良好的应用价值。

关 键 词: 批标准化; LSTM 神经网络; 在线监测; 故障诊断; 智能电网; 互感器

DOI: 10.19781/j.issn.1673-9140.2023.06.016 中图分类号: TM933 文章编号: 1673-9140(2023)06-0152-07

Online monitoring and fault diagnosis technology of transformers based on the LSTM with batch normalization

CAO Zhiqiang, CHEN Jie

(School of Electrical Engineering, Xinjiang University, Urumqi 830046, China)

Abstract: As one necessary equipment in the high-voltage power system, once the transformer fails, protection devices may refuse to operate and cause the malfunction of power grids. Traditional current transformer fault diagnosis and classification methods firstly extract features from the input operation data, and then use a specific classifier to diagnosis, which lacks adaptive update processing for dynamic input information. In order to further improve the accuracy of traditional recursive neural networks, the process efficiency of long short-term memory neural networks, this paper proposes a fault diagnosis method based on the LSTM model of batch normalization (BN). This method does not require feature extraction and classifier design steps, where the fault can be classified directly, and can also be updated adaptively. Compared with other fault diagnosis methods, this method has higher diagnostic accuracy and diagnostic performance, which validating its good application value in the field of current transformer fault diagnosis.

Key words: batch standardization; LSTM neural network; online monitoring; fault diagnosis; smart grid; transformer

在电力系统中, 直接对高电压、大电流进行测量是非常危险的, 互感器既可以将其转变为低电

压、小电流, 不仅对人身及设备起到一定保护, 也可使得二次装置标准化、小型化^[1-3]。互感器作为智能

收稿日期: 2022-06-12; 修回日期: 2023-02-20

基金项目: 国家自然科学基金(61963034)

通信作者: 曹志强(1993—), 男, 硕士研究生, 主要从事电能计量和互感器故障智能检测的研究; E-mail: 1820421932@qq.com

电网中重要的部件之一,其工作状态将直接影响电网的正常运行^[4-7]。近年来,数据驱动统计已被广泛应用于工业过程操作和生产中的检测和故障诊断^[8-10],因此,针对智能电网中互感器故障诊断进行在线监测这一研究具有重大现实意义。

在以往的研究中,针对互感器进行故障诊断的方法少有提出。文献[11]设计了系统组成结构,对互感器进行在线监测,采用神经网络和粒子群算法对所涉及的故障进行诊断;文献[12]改进了全局平均池化的一维卷积神经网络故障诊断模型,应用于低压电流互感器在线监测,所提出的方法在训练时间、测试时间以及模型的测试精度等方面的表现都优于传统的卷积神经网络(convolutional neural networks, CNN)结构模型;文献[13]提出一种新的用于少样本故障诊断的智能故障诊断模型,该模型利用样本对的相似性对样本进行分类,而不是端到端分类;文献[14]提出了一种基于小波变换和 Wigner-Ville 分布(wigner-ville distribution, WVD)的互感器突变性故障协同诊断方法,以解决现有的突变性故障和系统信号异常干扰的问题;文献[15]提出了一种机械轴承故障诊断的故障脉冲提取与特征增强方法,该方法可以提高轴承故障特征频率,在机械轴承故障诊断中具有极高的可行性。

针对上述情况,本文提出一种基于批标准化的长短期记忆神经网络(long short-term memory neural network, LSTM)用于互感器故障诊断,采用端到端方式进行训练,从而提供一个同时学习原始输入数据和分类器表示的框架,其中 LSTM 可以自适应地利用和学习过程数据的动态信息。

1 在线监测方案概述

1.1 方案介绍

从功能上看,互感器在线监测系统可以对电路中的电流、电压数据进行实时监控,包括数据的采集、线路设备开关的控制等。在线监测技术可以对设备状态的观测频率带来一定的提升。在线监测系统的框架如图 1 所示,其中,数据采集层通过传感器、状态接入控制器采集数据,通过网络传输到接

入网关机,将数据进行规范化处理后再把数据发送到数据存储层;在数据分析层放入预训练好的模型,从而对数据进行分析 and 反馈结果;同时,数据展现层对用户进行辅助决策、统计查询、数据挖掘等功能展示^[16]。利用人工智能技术对故障进行学习和诊断,使用神经网络处理复杂和非线性问题是未来的方向,也将广泛用于故障诊断。




图 1 互感器在线监测平台框架

Figure 1 Framework of transformer online monitoring platform

1.2 检测参数选择

根据互感器的故障特征,可以对互感器的故障进行直接诊断和间接诊断。互感器系统框架如图 2 所示,通过对互感器系统框架^[17]进行分析,可以列举系统中电流互感器常见故障类型,如表 1 所示。在互感器二次回路加装传感器参数监测装置,再根据故障参数和获取到的参数确定其是否存在故障。测量的数据涉及到电路系统中的电压、电流、有功功率和无功功率等。




图 2 基于互感器的系统原理框架

Figure 2 System framework based on transformer

表 1 常见故障类别

Table 1 Common fault category

故障标签	故障现象	故障标签	故障现象
0	正常	4	CT ₁ 二次侧短路(后)
1	CT ₁ 一次侧短路	5	CT ₂ 二次侧短路(后)
2	CT ₂ 一次侧短路	6	CT ₁ 二次侧短路(前)
3	CT 二次相间短路	7	CT ₂ 二次侧短路(前)

2 故障诊断方法

2.1 循环神经网络

循环神经网络(recurrent neural network, RNN)能够一次处理一个样本的序列数据,其是一种具有环路的神经网络,自适应地允许信息长时间存在。RNN可以在多尺度上自适应地对序列数据的动态信息进行建模,标准RNN的体系结构如图3所示,节点 z_t 接收来自样本的输入 x_t 和隐藏层在先前状态下的隐藏状态值 h_{t-1} 。




图3 标准RNN架构

Figure 3 The architecture of standard recurrent neural network

给定一个输入序列 $X=[x_1, x_2, \dots, x_t]$, RNN定义隐藏层序列:

$$h_t = \psi(z_t) = \psi(W_h h_{t-1} + W_x x_t + b) \quad (1)$$

式中, $W_h \in \mathbb{R}^{d_h \times d_h}$, $W_x \in \mathbb{R}^{d_h \times d_x}$, $b \in \mathbb{R}^{d_h}$, 初始状态 $h_0 \in \mathbb{R}^{d_h}$, 激活函数 $\psi(\cdot)$ 为 \tanh , z_t 为样本序列值 x_t 的输出值。

标准RNN的前馈结构如图4所示,很容易发现一个RNN可以被认为是同一个网络的多个副本,每个副本都会将一段消息传递给它的后继者。




图4 标准RNN的前馈结构

Figure 4 The feedforward structure of standard recurrent neural network

RNN是为顺序数据建模而设计的,然而,使用随机梯度下降(stochastic gradient descent, SGD)训练RNN是非常困难的,因为梯度消失和梯度爆炸^[18]普遍存在。但是对于梯度爆炸来说,对梯度范数采取约束就能较好地解决这一问题。另一方面,

可以通过LSTM、遗忘门控循环单元(gated recurrent unit, GRU)和*i*RNN/*u*RNN等架构变化来缓解梯度消失问题。

2.2 LSTM概念

LSTM具有类似于RNN的链状结构,但其重复模块完全不同^[19]。LSTM的内部结构是基于一组连接的细胞,与直接覆盖小区信息的简单RNN不同, LSTM的每个小区都包含3个门,作为信息在网络中传播的控制器,其架构如图5所示。




图5 LSTM架构

Figure 5 The architecture of LSTM

$$\begin{bmatrix} z_t^o \\ z_t^i \\ z_t^f \\ z_t^c \end{bmatrix} = W_h h_{t-1} + W_x x_t + b \quad (2)$$

$$c_t = \sigma(z_t^f) \odot c_{t-1} + \sigma(z_t^i) \odot \tanh(z_t^c) \quad (3)$$

$$h_t = \sigma(z_t^o) \odot \tanh(c_t) \quad (4)$$

式(2)~(4)中, z_t^o, z_t^i, z_t^f 分别为遗忘门、输入门、输出门的输入值; $W_h \in \mathbb{R}^{4d_h \times d_h}$, $W_x \in \mathbb{R}^{4d_h \times d_x}$, $b \in \mathbb{R}^{4d_h}$; 网络参数初始状态 $h_0 \in \mathbb{R}^{d_h}$, $c_0 \in \mathbb{R}^{d_h}$; 运算符 \odot 表示矩阵乘法; $\sigma(\cdot)$ 为Sigmoid激活函数。

与简单的RNN不同, LSTM有一个额外的内存元素 c_t ,其更新近似于线性,允许梯度轻松地通过回流。而且,与RNN在每个时间步都覆盖细胞不同, LSTM的细胞更新由3个门调控:①遗忘门 $\sigma(z_t^f)$,控制信息从前一个时间步转移的程度;②输入门 $\sigma(z_t^i)$,确定当前输入数据的信息流 x_t ;③输出门 $\sigma(z_t^o)$,控制从单元格获得的信息。

这种设计允许LSTM在模型训练时通过“门”结构选择性删除或添加信息,经网络自动学习原始数据的特征和分类器,更适合故障诊断任务,从而提高性能。为了处理时间序列的动态信息, LSTM在包括信号处理、语音分类和视频字幕等应用场景中达到了很好的效果。LSTM可以通过非线性门控单元对时间序列的动态信息进行自适应学习,从

而调节记忆细胞的输入和输出。

2.3 批标准化

批标准化(batch normalization, BN)是最近提出的一种网络重参数化方法,以减少协变量移位问题^[20]。批标准化激活函数给每一层训练特征的样本提供经验估计的平均值 $\hat{E}(h)$ 和标准差 $\hat{V}_{ar}(h)$ 。批标准化转换为

$$BN(h; \eta; \rho) = \rho + \eta \odot \frac{h - \hat{E}(h)}{\sqrt{\hat{V}_{ar}(h) + \epsilon}} \quad (5)$$

式中, $h \in \mathbf{R}^d$ 为需要标准化的特征向量; $\eta \in \mathbf{R}^d$, $\rho \in \mathbf{R}^d$ 分别为确定标准化特征的均值和标准差的参数; $\epsilon \in \mathbf{R}$ 为一个正则化参数,将划分理解为按要素进行。

由于每一层训练特征的样本均值 $\hat{E}(h)$ 和标准差 $\hat{V}_{ar}(h)$ 都是估计出来的,因此,可以通过这些统计量推导出反向传播算法,并保持梯度下降的收敛性。

2.4 基于批标准化的LSTM

为了避免不必要的冗余和过拟合,在批量归一化设计中设置 $\rho = 0$,简化后的批量归一化表示为 $BN(\cdot; \eta)$ 。本文在普通LSTM中采用批量归一化的方法为

$$\begin{bmatrix} z_i^o \\ z_i^i \\ z_i^f \\ z_i^c \end{bmatrix} = BN(W_h h_{t-1}; \eta_h) + W_x x_t + b \quad (6)$$

$$h_t = \sigma(z_i^o) \odot \tanh(BN(c_i; \eta_c)) \quad (7)$$

由于训练过程数据在训练前已归一化,因此不对 $W_x x_t$ 进行归一化。本文设计中已规范化循环项 $W_h h_{t-1}$,对此项归一化的目的是使普通LSTM能够利用 η_h 参数更好地控制各项的相对贡献。为了保持LSTM的动态特性和通过 c_t 的梯度流, c_t 的更新没有进行批量归一化处理。本文将 η_h 和 η_c 都设为0.9。

对于LSTM,可以在每个时间步骤或任何时间步骤中获得输出。LSTM有4种类型:一对一、一对多、多对多、多对一。本文使用多对一类型的LSTM,在特定时间步骤后计算输出。计算输出 y_{t+2} ,即

$$y_{t+2} = \sigma(W_{y_k} h_{t+2} + b_y) \quad (8)$$

式中, $W_{y_k} \in \mathbf{R}^{d_y \times d_h}$, $b_y \in \mathbf{R}^{d_y}$ 。

在训练中估计每个时间步的样本均值和标准差,而测试时通过平均训练集上的估计来使用这些统计数据。

2.5 损失函数

令 $\omega_1, \omega_2, \dots, \omega_C$ 为故障类型,损失函数定义为

$$J(W_h, W_x, W_{y_h}, b, b_y) = -\frac{1}{T-2} \sum_{i=1}^{T-2} \sum_{j=1}^C 1\{X_{i+2} \in \omega_j\} \ln \frac{y_{i+2}^{(j)}}{\sum_{k=1}^C y_{i+2}^{(k)}} \quad (9)$$

其中, $1\{\cdot\}$ 为指标函数, $1\{\text{true}\} = 1$, $1\{\text{false}\} = 0$, T 为数据实例数量。本文令 $b_y = C$, $y_{t+2} = [y_{t+2}^{(1)}, y_{t+2}^{(2)}, \dots, y_{t+2}^{(C)}]^T \in \mathbf{R}^C$, 在故障检测中,使用自适应矩估计^[21]用于小批量随机梯度优化的损失函数,基于自适应估计低阶矩。

2.6 基于BN-LSTM的故障诊断

提出基于BN的LSTM对故障数据的诊断模型需要2个步骤,即离线建模和在线监测。该模型流程如图6所示,离线建模主要是训练数据,在线监测主要是预测数据。

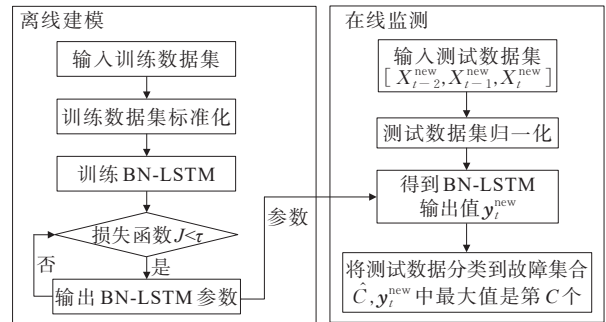


图6 基于BN-LSTM的故障诊断流程

Figure 6 The step of BN-LSTM based fault diagnosis method

针对离线建模和在线监测,具体步骤如下。

1) 离线建模。①收集过程数据作为训练数据集;②归一化训练数据的每个特征;③使用Adam训练BN-LSTM;④计算式(9)中的损失函数 J ,若 $J < \tau$ 或迭代次数 $l < \text{MaxIter}$,则转到步骤③(τ 为小正数,MaxIter为预定义的最大迭代次数);⑤输出BN-LSTM的参数。

2) 在线监测。①对扩充测试数据 $[X_{t-2}^{new}, X_{t-1}^{new}, X_t^{new}]$ ($t \geq 3$)进行抽样;②根据训练特征的均值和标准差对测试数据进行归一化;③ $y_t^{new} = [(y_t^{new})^{(1)}, (y_t^{new})^{(2)}, \dots, (y_t^{new})^{(C)}]^T$ 为得到的输出值;④故障 $\hat{C} = \text{argmax}_j \{(y_t^{new})^{(j)}\}$,将测试数据分类到其中。

3 实验评估

本文对所提出的基于BN-LSTM在线故障诊断方法进行评价。动态主成分分析(dynamic principal component analysis, DPCA)和直接线性判别分析(linear discriminant analysis, DLDA)是经典的动态特征提取方法。在DPCA和DLDA中的提取特征后,使用支持向量机(support vector machines, SVM)作为故障诊断的分类器。实验中使用480个训练样本和800个测试样本。

DPCA或DLDA法试图通过扩展向量来利用动态信息,然而,由于扩展的前缀结构,DPCA和DLDA法不能处理不同变量序列相关性的不同特征。传统深度学习基于特定条件数据训练的模型的性能可能无法得到满足,为了进一步验证所提方法的有效性,实验将与基于CNN和RNN的模型进行准确率比较。由于LSTM的递归结构和自适应训练策略,本文所提算法可以充分考虑不同变量的动态信息,用于进一步的故障诊断。

3.1 批标准化的影响

在深度学习中,如LSTM特征表现为网络的分布变化、协变量移位均是常见问题。协变量移位会降低训练效率,使LSTM无法有效学习。批标准化是最近提出的一种处理协变量移位问题的技术,它使LSTM更趋于稳定、更容易收敛^[22]。

实验中对传统的LSTM和BN-LSTM分别进行训练,训练中设置最小批量分别为30、60个训练周期,如图7所示。实验结果表明,基于BN-LSTM的收敛速度明显快于基线LSTM,与传统LSTM相比,训练中使用的故障模式越多,基于BN-LSTM的收敛速度越快。

3.2 故障分类结果分析

DPCA+SVM、DLDA+SVM、多层感知器(multi-layer perceptron, MLP)、CNN、RNN和BN-LSTM对不同故障数据的诊断结果如图8所示,对于DPCA,提供2~30不同降维数下的性能,并且提供MLP和BN-LSTM在隐藏层中不同节点数量下的性能;MLP和BN-LSTM的维数是隐藏层中的节点数。需要注意的是,由于DLDA的降维数不能超过C-1,因此,DLDA+SVM的诊断结果在很大程度

上受到降维特征维数的影响。CNN和RNN在维数增大的情况下基本保持一定程度上的稳定,精确度无法再提升。实验结果表明,所提出的BN-LSTM在所有故障模式下都能提供最好的性能。

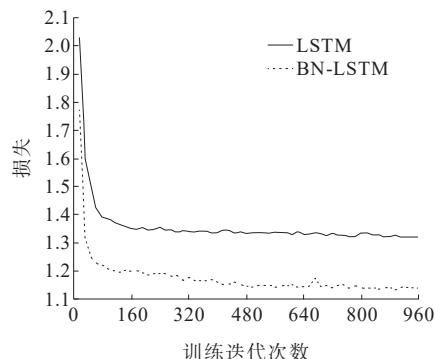


图7 LSTM和BN-LSTM在不同训练集上的收敛性比较

Figure 7 Convergence comparison between LSTM and BN-LSTM on different training sets

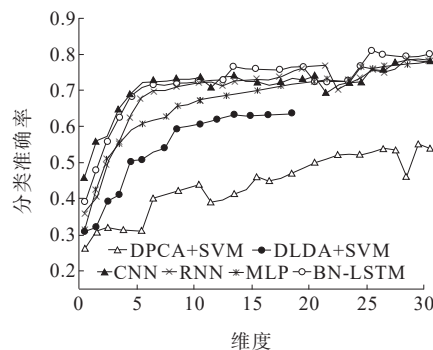


图8 DPCA+SVM、DLDA+SVM、MLP、CNN、RNN及BN-LSTM在不同故障中的诊断效果

Figure 8 Diagnostic outputs of DPCA + SVM, DLDA + SVM, MLP, CNN, RNN and BN-LSTM in different faults

为了对这6种测试方法进行更详细的分析,针对故障标签提供混淆矩阵,如图9所示。基于MLP和BN-LSTM,分别在具有30个隐藏节点的神经网络下得到混淆矩阵。混淆矩阵考虑了目标和输出数据,目标数据是真实数据标签,输出数据是执行分类的测试方法的输出。在混淆矩阵中,行表示预测的类,列表示基本情况。对角线单元格表示真实的类和预测的类匹配的位置;非对角线单元格显示测试算法出错的实例。混淆矩阵右边的列显示每个预测类的准确性,底部的行显示每个真实类的准确性;混淆矩阵右下角的单元格显示整体的准确性。从混淆矩阵的底部行可以看出不同算法在不同故障模式下的性能,也可以从混淆矩阵的右下单元中得到总体精度。通过对6种方法进行对比,很容易看出故障类别判定中BN-LSTM总体精度是最好的。

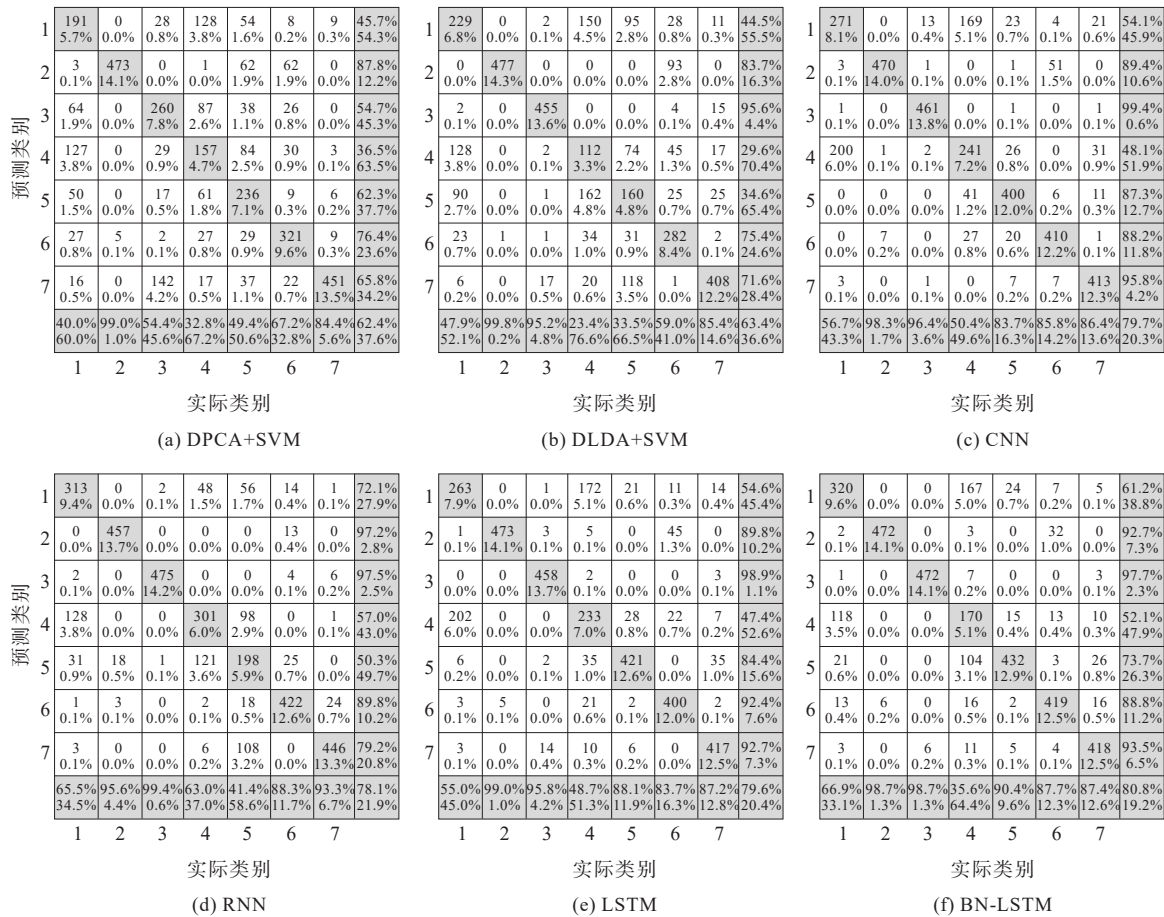


图 9 不同方法的混淆矩阵

Figure 9 Confusion matrix of different methods

4 结语

本文提出了基于批标准化的 LSTM 神经网络,该方法用于智能电网中互感器的在线故障诊断。与采用传统的“特征+分类器”策略进行故障分类的方法不同,该方法采用端到端方式进行训练,提供了一个同时学习原始输入数据和分类器表示的框架。此外,由于 LSTM 的使用,可以自适应地利用过程数据的动态信息。为了减少 LSTM 的内部协变量漂移,加快 LSTM 的收敛速度,设计了批标准化方法,并将其应用于 LSTM 神经网络中,实现故障诊断任务。

参考文献:

[1] 王欢,刘鹏,史强,等.大容量供电一体化电压互感器设计[J].高压电器,2020,56(4):113-117.
WANG Huan, LIU Kun, SHI Qiang, et al. Design of

integrated voltage transformer with large capacity power supply[J].High Voltage Apparatus,2020,56(4):113-117.
[2] 夏小飞,芦宇峰,苏毅,等.基于相空间重构与改进 GSA-SVM 的高压断路器机械故障诊断[J].中国电力,2021,54(10):169-176.
XIA Xiaofei, LU Yufeng, SU Yi, et al. Mechanical fault diagnosis of high voltage circuit breakers based on phase space reconstruction and improved GSA-SVM[J].Electric Power,2021,54(10):169-176.
[3] 朱梦梦,束洪春,何兆磊,等.接地极直流电流互感器宽频特性现场试验与分析[J].电力系统自动化,2022,46(6):166-172.
ZHU Mengmeng, SHU Hongchun, HE Zhaolei, et al. Field test and analysis of broadband characteristics of DC current transformer on earth electrode[J]. Automation of Electric Power Systems,2022,46(6):166-172.
[4] LI K, CHEN C, CHEN T, et al. A new approach for on-line open-circuit fault diagnosis of inverters based on current trajectory[J]. Journal of Central South University, 2019, 26(3):743-758.
[5] 黄梓欣,林湘宁,马啸,等.含风电继电保护应用中的电流

- 互感器饱和电流重构方法[J]. 电工技术学报, 2022, 37(19): 4823-4834.
- HUANG Zixin, LIN Xiangning, MA Xiao, et al. Reconstruction method of saturation current of current transformer in relay protection application related to wind power[J]. Transactions of China Electrotechnical Society, 2022, 37(19): 4823-4834.
- [6] 王守鹏, 赵冬梅. 电网故障诊断的研究综述与前景展望[J]. 电力系统自动化, 2017, 41(19): 164-175.
- WANG Shoupeng, ZHAO Dongmei. Research review and prospects for power grid fault diagnosis[J]. Automation of Electric Power Systems, 2017, 41(19): 164-175.
- [7] 唐登平, 蔡文嘉, 周翔宇, 等. 基于VMD和样本熵的电磁式电流互感器故障诊断[J]. 电力科学与技术学报, 2021, 36(6): 144-150.
- TANG Dengping, CAI Wenjia, ZHOU Xiangyu, et al. Fault diagnosis of current transformer based on VMD and sample entropy[J]. Journal of Electric Power Science and Technology, 2021, 36(6): 144-150.
- [8] 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, LV Feiya. Review on deep learning based fault diagnosis[J]. Journal of Electronics & Information Technology, 2020, 42(1): 234-248.
- [9] 蒋波涛, 张博, 黄新波. 基于支持向量机的电机故障诊断方法综述[J]. 微电机, 2018, 51(7): 58-61+67.
- JIANG Botao, ZHANG Bo, HUANG Xinbo. Review of motor fault diagnosis based on support vector machines[J]. Micromotors, 2018, 51(7): 58-61+67.
- [10] 苟超, 陈伯建, 吴翔宇, 等. 基于改进K-means算法的电力短期负荷预测方法研究[J]. 电力科学与技术学报, 2022, 37(1): 90-95.
- XUN Chao, CHEN Bojian, WU Xiangyu, et al. Research on short-term power load forecasting method based on improved K-means algorithm[J]. Journal of Electric Power Science and Technology, 2022, 37(1): 90-95.
- [11] 李振华, 郑严钢, 李振兴, 等. 基于传递熵和小波神经网络的电子式电压互感器误差预测[J]. 电测与仪表, 2021, 58(3): 146-152.
- LI Zhenhua, ZHENG Yangang, LI Zhenxing, et al. Error prediction of electronic voltage transformer based on transfer entropy and wavelet neural network[J]. Electrical Measurement & Instrumentation, 2021, 58(3): 146-152.
- [12] 唐登平, 蔡文嘉, 邹立, 等. 改进卷积神经网络在互感器故障诊断中的应用[J]. 计算机工程与应用, 2021, 57(11): 239-247.
- TANG Dengping, CAI Wenjia, ZOU Li, et al. Application of improved convolution neural network in fault diagnosis of transformer[J]. Computer Engineering and Applications, 2021, 57(11): 239-247.
- [13] WANG C, XU Z. An intelligent fault diagnosis model based on deep neural network for few-shot fault diagnosis[J]. Neurocomputing, 2021, 456: 550-562.
- [14] 刘尧, 韩伟, 刘芳冰, 等. 基于小波变换和WVD分布的电子式互感器突变性故障协同诊断方法[J]. 电力系统保护与控制, 2019, 47(21): 163-170.
- LIU Yao, HAN Wei, LIU Fangbing, et al. A collaborative diagnosis of abrupt-changing fault of electronic instrument transformer based on wavelet transform and WVD[J]. Power System Protection and Control, 2019, 47(21): 163-170.
- [15] CHEN Z, GUO L, GAO H, et al. A fault pulse extraction and feature enhancement method for bearing fault diagnosis[J]. Measurement, 2021: 109718.
- [16] 陈刚, 徐敏锐, 穆小星, 等. 基于大数据的电子式互感器设备状态在线监测设计[J]. 电力电容器与无功补偿, 2020, 41(6): 83-88.
- CHEN Gang, XU Minrui, MU Xiaoxing, et al. On-line monitoring design on electronic instrument transformer based on big data[J]. Power Capacitor & Reactive Power Compensation, 2020, 41(6): 83-88.
- [17] 王昕, 曹文彬, 曹敏, 等. 基于PCA-KELM和AT的互感器故障诊断[J]. 中国测试, 2019, 45(11): 72-78.
- WANG Xin, CAO Wenbin, CAO Min, et al. Transformer fault diagnosis based on PCA-KELM and AT[J]. China Measurement & Test, 2019, 45(11): 72-78.
- [18] SCHMIDHUBER J. Deep learning in neural networks: An overview[J]. Neural networks, 2015, 61: 85-117.
- [19] LINDEMANN B, MASCHLER B, SAHLAB N, et al. A survey on anomaly detection for technical systems using LSTM networks[J]. Computers in Industry, 2021, 131: 103498.
- [20] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [C]//32nd International Conference on Machine Learning (ICML), Lille, France, 2015.
- [21] XIAO P, YIN Y, LIU B, et al. Adaptive testing based on moment estimation[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2020, 50(3): 911-922.
- [22] 沈涛, 李舜韶. 针对滚动轴承故障的批标准化CNN-LSTM诊断方法[J]. 计算机集成制造系统, 2022, 28(12): 3946-3955.
- SHEN Tao, LI Shunming. CNN-LSTM method with batch normalization for rolling bearing fault diagnosis[J]. Computer Integrated Manufacturing Systems, 2022, 28(12): 3946-3955.