

基于TCN的车网耦合异常扰动辨识

钟杰¹, 闫晓夏¹, 胡华¹, 王召¹, 朱炳旭²

(1. 铁科院(深圳)研究设计院有限公司, 广东 深圳 518000;

2. 西南交通大学 电气工程学院, 四川 成都 610031)

摘要:电气化铁路系统是牵引供电系统与列车相互耦合的复杂系统, 为确保列车在复杂工况下安全运行, 必须对车网耦合系统的扰动进行及时准确的辨识。针对这一问题, 提出用时序卷积神经网络(TCN)对车网耦合系统扰动进行辨识。首先对系统各扰动类型特征进行分析, 根据分析搭建适合提取时域特征的TCN网络结构, 对列车主断路器处电压以1 s的时间窗进行采样, 送入模型后进行下采样操作减小数据尺寸以减小网络参数数量, 降低运算量, 提高算法鲁棒性, 并在TCN残差块中加入批量归一化操作以提高网络收敛速度, 防止过拟合。实验结果表明: 提出的TCN扰动辨识模型对车网耦合的各类扰动识别准确率达到96.90%以上, 与深度卷积神经网络训练效果相比, 能够更加可靠地实现对车网耦合扰动辨识。

关键词:电气化铁路; 车网耦合; 扰动辨识; 时序卷积神经网络; 残差快; BN层

中图分类号: TM992 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqcd26390

Identification of Abnormal Disturbances in Vehicle-network Coupling Based on TCN

ZHONG Jie¹, YAN Xiaoxia¹, HU Hua¹, WANG Zhao¹, ZHU Bingxu²

(1. Research and Design Institute Co., Ltd. of the Chinese Academy of Railway Sciences (Shenzhen),

Shenzhen 518000, Guangdong, China; 2. School of Electrical Engineering,

Southwest Jiaotong University, Chengdu 610031, Sichuan, China)

Abstract: The electrified railways system is a complex system of traction power supply system and train coupling. In order to ensure the safe operation of trains under complex working conditions, it is necessary to identify the disturbance of the vehicle-network coupling system in a timely and accurate manner. To solve this problem, a temporal convolutional neural network (TCN) was used to identify the disturbance of the vehicle-network coupling system. Firstly, the characteristics of each disturbance type of the system were analyzed, and a TCN network structure suitable for extracting time-domain features was built according to the analysis, the voltage at the main circuit breaker of the train was sampled with 1 s time window of, and the down-sampling operation was carried out to reduce the data size to reduce the number of network parameters, reduce the amount of calculation, improve the robustness of the algorithm, and add batch normalization operation to the TCN residual block to improve the network convergence speed and prevent overfitting. The experimental results show that the accuracy of the proposed TCN perturbation identification model for the identification of various disturbances of vehicle-network coupling reaches more than 96.90%, which can more reliably realize the identification of vehicle-network coupling disturbances compared with the training effect of deep convolutional neural network.

Key words: electrified railways; vehicle-network coupling; disturbances identification; temporal convolutional neural networks (TCN); residual block; BN(batch normalization) layer

电气化铁路中牵引网和电力机车之间的电气耦合关系构成车网耦合系统。单相移动非线性电力机车负荷在移动过程中会伴随各种扰动现象, 其中包括谐波谐振、低频振荡、接地短路、

励磁涌流等异常扰动, 威胁车网耦合系统的安全运行^[1]。

相比于电力系统扰动识别, 关于车网耦合网侧扰动辨识的研究较少, 现有文献关于电气化铁

基金项目: 中国铁道科学研究院集团有限公司科研项目(2024YJ037)

作者简介: 钟杰(1982—), 男, 硕士, 高级工程师, 主要研究方向为轨道交通牵引供电, Email: 20817477@qq.com

路系统的网侧扰动辨识方法多针对单一类型的扰动进行分析辨识^[2-7],缺乏能够有效辨识多种扰动类型的扰动辨识方法。

目前多种类扰动辨识方法主要分为模型驱动的方法^[8-9]和数据驱动的方法^[10-15]。模型驱动的方法需要利用系统参数和拓扑结构进行精密建模实现扰动识别。但对于复杂系统很难实现准确建模,且系统电气参数可能因老化等情况发生变化,导致扰动识别准确度下降。数据驱动的扰动识别方法通过分析系统中现有传感器或额外配置传感器采集的数据实现扰动辨识和分类,无需进行复杂建模,因此相比于基于模型的扰动辨识方法,有更好的泛用性和更强的鲁棒性,更加适合于电气扰动的辨识。

数据驱动方法的扰动辨识过程分为特征提取和分类识别,其中,特征提取又分为人工特征提取和算法自动特征提取。文献[10-11]采用傅里叶变换的方式进行特征提取,并根据专家经验或波形的统计学特征构造特征向量,特征向量送入浅层神经网络实现分类。但傅里叶变换只能得到频域特征,忽视了扰动信号中包含的丰富时域信息。文献[12-13]采用小波变换或S域变换的方式对信号进行特征提取,虽然能够提取到时频域特征,但人工提取得到的特征总是包含冗余信息,且各种信号分析方式往往是耗时的,不利于算法实现扰动的快速诊断。自动特征提取是利用深度学习网络的学习能力,避免了人工参与到特征提取的过程,且不需要其他特征提取算法就能够实现对扰动辨识。文献[14]利用深度卷积神经网络(deep convolutional neural networks, DCNN)实现了电气化铁路扰动的辨识,但没有考虑实际工况中信号质量的影响;文献[15]采用自组织编码器对信号进行编码,降低了测量单元输送数据质量对网络辨识结果的影响,有较好的效果。

基于上述问题,本文提出一种基于TCN辨识网络的多扰动辨识方法,对波形特征稳定的网侧电压数据进行特征提取。根据TCN网络特征,在归一化数据送入网络前进行下采样处理,减小数据尺寸,提高网络数据处理速度,同时滤除电压波形中冗余的谐波信息,提高了算法的鲁棒性,并且在TCN的残差块中加入BN(batch normalization)层,进一步防止过拟合,提高网络收敛速度。实验结果表明该算法具有较高的准确识别度和良好的鲁棒性。

1 电气化铁路扰动分析

电气化铁路系统中牵引变电所从电网取电,由馈线、接触网、轨道和大地、回流线等共同构成的牵引网给电力机车提供电能。电力机车运行期间会向牵引网输出大量高次谐波,当高次谐波频率与牵引系统谐振频率相匹配时将会引发谐振;电力机车在过分相时会经历主断路器断开—离线滑行—主断路器闭合的过程,引发过电压、铁磁谐振、分频谐振等扰动电气现象;多车同时升弓时可能会导致系统低频振荡;电缆头击穿或绝缘老化等会造成接地短路故障。这些异常电气现象可通过网侧电流和电压信号反映出来,由于实际工况下网侧电流信号中包含较多冗余谐波信息,特征提取较为困难,故选取网侧电压数据进行扰动辨识,四种工况下的电压波形如图1所示。




图1 各工况下网侧电压波形

Fig.1 Grid-side voltage waveforms under various operating conditions

2 基于TCN的车网耦合扰动辨识方法

随着基于人工智能的扰动辨识和故障预测技术不断发展,基于DCNN的故障诊断方法实现了扰动的辨识,但其无法考虑数据的时序性,容易产生误差。而时序卷积神经网络采用因果卷积和扩张卷积相配合的特殊卷积层结构,使网络能够更有效提取数据的时域特征。

2.1 网侧扰动识别方法框架

本文提出一种具有自动特征提取能力的鲁棒性扰动辨识方法,该方法可有效识别电气化铁路网侧扰动,所提方法网络架构如下:

1)数据预处理:首先对尺寸为 $25\ 600 \times 1$ 的电压时序序列进行归一化处理,提高算法泛化能力。其次对归一化数据序列进行下采样,将数据尺寸降为 $5\ 120 \times 1$,去除了大量电压序列中的冗余谐波信息,提高了算法的鲁棒性。

2)特征提取通道:采用三个残差块对信号进行特征提取,每个残差块由两个扩张卷积层和一个残差连接组成。

3)扰动类型辨识:由TCN网络提取得到的特征序列经过两层全连接层实现样本分类。

2.2 改进TCN的特征提取方法

2.2.1 电压序列时间窗选取

电气化铁路电网电压为工频单相交流电,而低频振荡的振荡频率为 $3 \sim 7\ \text{Hz}$,为有效提取扰动特征以实现准确辨识,选取长度为 $1\ \text{s}$ 的时间窗,采样设备采样频率为 $25\ 600\ \text{Hz}$,单个样本的尺寸为 $25\ 600 \times 1$,代表 $1\ \text{s}$ 时间段内的电压波形。

2.2.2 算法架构

基于TCN的车网耦合扰动辨识算法架构如

图2所示。算法在对输入网侧电压时间序列进行下采样操作后,采用由三个特征提取单元组成的特征提取通道捕获信号特征。每个特征提取单元由一个TCN残差块组成。分类器由一个特征再提取模块和分类模块组成,两者均由一个BN层和一个全连接层组成。特征再提取模块中BN层将特征向量中元素分布移动到中心区域,防止梯度消失,加快网络训练速度,同时提高网络泛化能力,特征再提取模块的全连接层将参数量庞大的高维特征向量降维压缩,根据相关性对特征进行整合得到尺寸为 258×1 的特征分布向量。分类模块中BN层对特征分布向量的元素分布进行调整,进一步提高网络泛化能力,并有效防止过拟合。分类模块输出尺寸为 4×1 的一维向量,分别代表样本属于各类别的概率。

2.2.3 因果卷积与扩张卷积

时序卷积神经网络是一种特殊的一维卷积神经网络,卷积层包括因果卷积和扩张卷积两种形式。因果卷积保证卷积输出结果只与当前时刻 t 的输入数据与历史数据有关,不会导致未来数据的泄露,因此形成更加适合处理时间序列的卷积结构。图3为因果卷积数据处理过程,其中各卷积层的卷积核大小均为2。

由于因果卷积每扩大一个元素的感受野就需要增加一个卷积层,TCN中各个卷积层输入序列长度均与输出序列相同,卷积层的叠加将显著增大网络参数和计算量,降低网络运行速度。为此在因果卷积的基础上引入扩张因果卷积,扩张因果卷积计算过程如图4所示,根据卷积层数改变卷积层扩张因子 d ,扩大因果卷积核输入之间的间隔以获得更大感受野。在 t 时刻时,扩张因

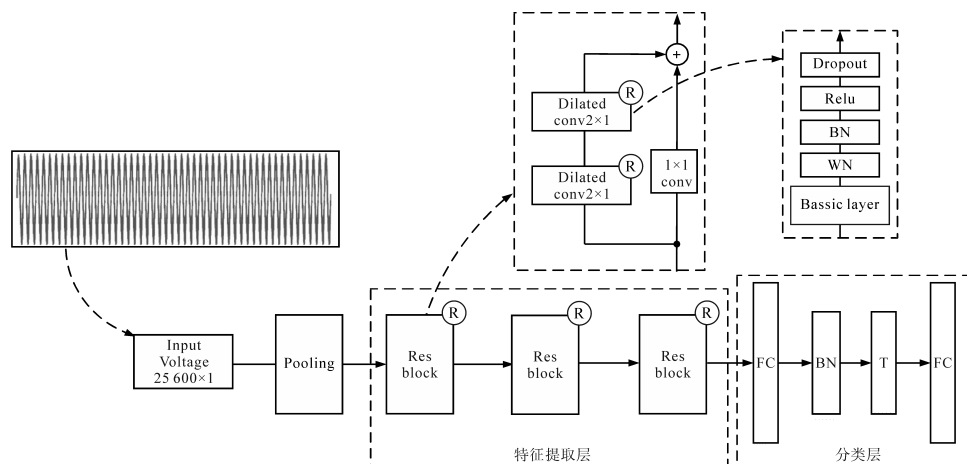


图2 基于TCN的扰动辨识网络架构

Fig.2 Disturbance identification network architecture based on TCN

果卷积的公式如下:

$$F(t) = (x *_{dc} f)(t) = \sum_{i=0}^{k-1} f(i) \cdot x_{t-i \cdot d} \quad (1)$$

式中: f 为滤波器; $f(i)$ 为卷积核的权重; x 为输入序列; $*_{dc}$ 为扩张卷积运算; k 为卷积核大小; d 为扩张因子; t 为当前时间点。




图3 卷积核为2的因果卷积

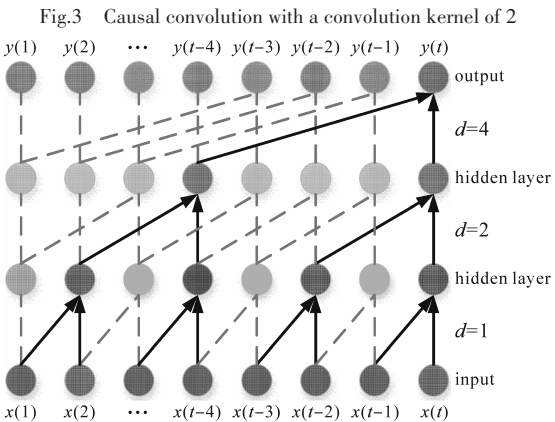


图4 卷积核大小 $k=2$,扩张因子 $d=1,2,4$ 的扩张因果卷积

Fig.4 Dilation causal convolution with convolution nucleus $k=2$ and dilation factor $d = 1, 2, 4$

扩张因子使得输出层的感受野随着层数的增加呈指数级增长,为使输出序列中单一元素对输入序列的感受野连续,扩张因子 d 与卷积层数 s 应满足:

$$d = 2^{s-1} \quad s = 1, 2, \dots, n \quad (2)$$

式中: s 为卷积层在网络中的层数; d 为第 s 层卷积层的扩张因子; n 为TCN网络卷积层总层数。

所提算法特征提取通道中包含3个残差块,其中的6个扩张因果卷积层的扩张因子 d 分别为1,2,4,8,16,32。最终得到特征序列中的一个元素包含了初始输入序列的64个元素的特征。由于经下采样后的电压序列长度为5 120,每个周期由102个点组成。特征提取通道的每个元素可以提取半个周波以上的局部特征,保证了电压序列特征提取的精度。

2.2.4 残差块与激活函数

TCN的感受野取决于网络深度 n 以及卷积核大小 k 和膨胀因子 d ,当对感受野要求较高时,TCN需要使用较为深层的网络结构。为此TCN引入残差连接,残差连接公式如下:

$$o = Activation [x + F(x)] \quad (3)$$

式中: x 为残差块的输入; $F(x)$ 为残差块内部两个卷积层对输入 x 的非线性变换; $Activation()$ 为非线性激活函数。

常用的非线性激活函数有ReLU激活函数(rectified linear unit)和Tanh激活函数(hyperbolic tangent),如图5所示。




图5 ReLU激活函数和Tanh激活函数

Fig.5 ReLU activation function and Tanh activation function

残差连接将前一个卷积层的输入与后一个卷积层的输出相连接组成残差块,残差块结构如图6所示,残差连接打破了网络的对称性^[6],提高了网络的表征能力。




图6 残差块示意图

Fig.6 Schematic diagram of the residual block

残差块中扩张因果卷积层均选用ReLU函数作为非线性激活函数。ReLU和Tanh函数的公式

如下式:

$$\begin{cases} f_{\text{Tanh}}(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \\ f_{\text{ReLU}}(x) = \max(0, x) \end{cases} \quad (4)$$

Tanh 函数的输出范围在-1~1,整体中心对称,保持了输入与输出之间的非线性单调关系,但 Tanh 函数在饱和区域中可能存在梯度消失等问题。相比于 Tanh 函数,ReLU 函数在正区间内克服了梯度消失的问题并且计算速度快、收敛速度快,当输入为负值,ReLU 函数完全不激活,增强了网络的稀疏性,适用于稳定且波形对称的网侧电压数据。因此选取 ReLU 函数作为 TCN 卷积层的激活函数。

2.2.5 BN层

本文算法在特征提取通道的每个残差块中第二个卷积层的激活函数前与分类器的全连接层中加入 BN 层以改善特征提取过程中的特征分布,BN 层将特征向量中元素分布移动到中心区域,防止梯度消失,能够有效加快网络训练速度,同时提高网络泛化能力,有效防止过拟合。输入为小批次数据中对应的特征值 x_1, x_2, \dots, x_m ,BN 层的输出 $BN(x_i)$ 可表示为

$$BN(x_i) = \gamma \hat{x}_i + \beta \quad (5)$$

其中

$$\begin{aligned} \hat{x}_i &= \frac{x_i - \mu}{\sqrt{\sigma^2 + \varepsilon}} \\ \mu &= \frac{1}{m} \sum_{i=1}^m x_i \\ \sigma^2 &= \frac{1}{m} \sum_{i=1}^m (x_i - \mu)^2 \end{aligned}$$

式中: ε 为常数; γ, β 为可更新的网络参数。

3 仿真实验

通过仿真模拟建立训练集,由样本数据和标签组成,样本标签类别分别对应谐波谐振、低频振荡、接地短路、正常工况,每种样本类型均包含 500 组训练样本。采集四种工况下的实测数据建立测试数据集以确保网络的泛化能力。测试数据集中每种样本类型均包含 80 组测试样本。

训练过程中以 128 组数据为一批次将训练集送入网络中进行训练。为验证所提方法的有效性,对不加 BN 层的 TCN 网络和加入 BN 层的 TCN 网络的训练过程进行对比,并将所提方法与传统 DCNN 算法的训练过程进行对比。本文采用 11th Gen Intel(R) Core(TM) i7-11800H 处理器、机带

RAM 为 8 GB 的计算机进行实验。

3.1 BN层有效性验证

为验证在残差块中加入 BN 层的合理性和有效性,将残差块包含 BN 层的网络和不包含 BN 层的网络在训练过程中的损失和准确率变化进行对比,如图 7 所示。




图7 不同残差块结构的网络模型训练对比

Fig.7 Comparison of network model training with different residual block structures

由图 7 可以看出,加入 BN 层后的网络的收敛速度显著快于未加 BN 层的网络,所提网络模型在训练步数达到 14 时准确率就达到了 95% 以上,之后快速收敛于 99% 附近。所提网络损失在训练步数达到 77 时下降到 0.1 以下,而未加 BN 层的网络结构始终保持较低的收敛速度,在训练步数达到 265 时网络准确率首次高于 90%,且训练过程中准确率波动较大,网络损失最终降低到 0.3 左右且损失波动较大。未加 BN 层的网络结构收敛速度和可靠性远不如所提网络方法。

3.2 算法对比

为验证 TCN 网络结构在处理时序信息时相比于 DCNN 网络结构的优越性,将本文算法与 DCNN 算法在训练过程中准确率和损失的变化进行对比,如图 8 所示。

从损失下降速度可以看出基于改进 TCN 的网络结构具有更快的收敛速度,在训练前期,本文所提算法能够以更快的速度提高准确率和降低损失,在训练步数达到 14 时准确率就达到了 95.25%,DCNN 网络在训练步数达到 24 时准确率首次达到 95% 以上。在训练后期,相比于 DCNN 算法,本文所提算法波动更小,维持在 99% 左右。

为进一步评估网络模型的性能,采用召回率 R (Recall)、精确率 P (Precision) 两个指标来评估网络模型的综合表现,计算公式如下:

$$R = \frac{TP}{TP + FN} \times 100\% \quad (6)$$

$$P = \frac{TP}{TP + FP} \times 100\% \quad (7)$$

式中: TP 表示将正样本预测为正样本; FN 表示将正样本预测为负样本; FP 表示将负样本预测为正样本。




图8 TCN与DCNN网络模型训练效果

Fig.8 Training effect of TCN and DCNN network models

本文算法与DCNN算法的综合对比如表1所示,可知,本文所提算法识别准确率优于DCNN算法,尤其在对正常波形和低频振荡的识别上准确率有明显的提高。

表1 本文算法与DCNN算法综合对比

Tab.1 The Comprehensive comparison between the proposed algorithm and the DCNN algorithm

扰动类型	本文算法		DCNN算法	
	R/%	P/%	R/%	P/%
正常波形	96.72	94.00	27.69	88.02
谐波谐振	100	100	100	100
低频振荡	95.63	97.24	66.81	98.82
接地短路	97.12	99.21	92.15	75.48

3.3 鲁棒性测试

根据实际工况中测量单元输送到算法中的信号信噪比可能较低的情况,将不同信噪比下的信号输入本文扰动辨识通道与竞争算法DCNN通道,算法辨识准确度如表2所示。可以看出,当信噪比分别为30 dB和25 dB时,TCN通道准确率保持较高的值,分别为98.56%和96.90%,比DCNN通道高。当信噪比为20 dB时,TCN通道测试集准确率为93.92%,仍然比DCNN通道高。综合比较,所提TCN扰动辨识通道的综合准确率较高,

鲁棒性相比于DCNN扰动辨识通道更强。

表2 不同噪声下输入数据测试准确率

Tab.2 The accuracy of the input data test under different noises

输入信号信噪比 SNR/dB	TCN通道测试集 准确率/%	DCNN通道测试集 准确率/%
30	98.56	95.50
25	96.90	94.33
20	93.92	91.52

3.4 算法准确率的影响参数

本文算法在辨识过程中除了受信号质量和噪声的影响外(见3.3节),还会受网络层数、训练超参数(如 learning rate, epoch等)等参数的影响。为探究不同参数变化对准确率的影响,基于现有数据集进行实验,得出参数变化对算法辨识准确率的影响如表3所示。

表3 参数变化下准确率变化情况

Tab.3 Accuracy changes under parameter changes

网络层数	准确率%	learning rate	准确率%	epoch	准确率%
3	62	0.000 1	76.2	10	89.1
6	96.2	0.001	96.5	20	96.6
12	92.6	0.01	90.1	50	96.9

由实验结果可看出,适当增加卷积层数能够捕捉到更多的时序特征,可能会使准确率得到升,但过高时会造成过拟合,造成准确率下降。和卷积层数变化情况相似,当学习率较低时,收敛速度慢且准确度不高,随着学习率的提升,准确率也会随之增大,但当学习率选择过高时,会导致过拟合或无法收敛的情况,反而使准确率下降。随着epoch的增加,准确率会升高,但是当达到一定次数后,再增加次数也基本无法使准确率继续提高,考虑到对训练时间情况的影响,一般选择适中的epoch,避免出现过拟合,也能节省部分训练时间。

除了上述影响之外,算法准确率还受训练样本数量和样本多样性的影响,一般来说,当样本数量越多时,算法辨识的准确率也会随之变得更高。

3.5 实时性验证

选择实测重庆某牵引变电所电气异常状态的网压信号波形来验证本文算法,数据使用E6500电能质量测试仪测得,为了体现实时性,选用测试任意1s的网压信号来进行电气异常辨识。网压波形如图9所示。




图9 监测网压信号波形

Fig.9 Waveform of monitoring network voltage signal

此时网压信号为振荡频率在4 Hz左右的低频振荡,本文算法辨识结果如图10所示。




图10 监测时段电气异常辨识结果

Fig.10 Identification results of electrical anomalies during the monitoring period

对监测1 s数据信号辨识耗时43 ms,识别准确率为96.12%,通过对随机选择实测信号的辨识可验证所提算法在处理电气信号时的实时性。但是目前还未搭建实时网压信号辨识平台,未来可根据需求进行搭建,实现对电气异常现象的实时在线辨识。

4 结论

本文根据网侧电压的时序特征实现车网耦合扰动的辨识。相比传统CNN网络,时序卷积神经网络更适于时序特征的提取,但其卷积操作不改变序列长度的特点使TCN网络参数量更大,网络训练困难,为此在原有TCN网络结构的基础上,在每个残差块第二层卷积层的激活函数前加入BN层以提高收敛速度和网络性能,取得了良好效果。经实验验证,相比于传统DCNN算法,该算法的鲁棒性更强,能够根据网侧电压时序数据准确可靠地实现扰动辨识,测试集扰动辨识综合准确率达到96.90%,且通过验证可满足对实时性的需求。

本文算法辨识准确率仍存在提升的空间,未来研究中需要考虑提升算法架构对于瞬时故障

的敏感度,加入注意力机制和新的数据处理办法,并提高数据集质量,且随着算法的上线运行加入更多实测数据,使算法准确度得到进一步的提高。

参考文献

- [1] 李琦,李强,李晋,等. 树形双边贯通供电电网电气耦合特性分析[J]. 电气化铁道,2021,32(S1):6-10,15.
LI Qi, LI Qiang, LI Jin, et al. Shuxing shuangbian guantong gongdian chuang dianqi ouhe texing fenxi[J]. Electric Railway, 2021, 32(S1): 6-10, 15.
- [2] 张虹,张梭宁,徐志豪,等. 基于SSEWT与经验包络解调技术的低频、超低频混合振荡信号参数辨识[J]. 高电压技术, 2022, 48(11):4445-4454.
ZHANG Hong, ZHANG Anning, XU Zhihao, et al. Parameter identification of low-frequency and ultra-low-frequency mixed oscillation signals based on second-order synchro extraction wavelet transform and empirical envelope demodulation[J]. High Voltage Engineering, 2022, 48(11): 4445-4454.
- [3] 雷志勇,江灏,李中胜. 基于MEEMD-Prony联合算法的电力系统低频振荡模式辨识[J]. 东北电力大学学报, 2022, 42(4):50-55.
LEI Zhijun, JIANG Hao, LI Zhongsheng. Low frequency oscillation mode identification of power system based on MEEMD-Prony joint algorithm[J]. Journal of Northeast Electric Power University, 2022, 42(4): 50-55.
- [4] 刘鹏辉,焦兵豪,郭向伟. 考虑CT饱和和干扰的电力变压器励磁涌流识别方法[J]. 电网技术, 2022, 46(9):3633-3641.
LIU Penghui, JIAO Binghao, GUO Xiangwei. Magnetizing inrush identification method of power transformer considering CT saturation interference[J]. Power System Technology, 2022, 46(9): 3633-3641.
- [5] 李清,孟潇潇,王强钢,等. 柔性直流输电系统接入交流电网的高频谐振风险运行方式辨识[J]. 电力自动化设备, 2022, 42(8):206-214.
LI Qing, MENG Xiaoxiao, WANG Qianggang, et al. Identification of high-frequency resonance risk operation mode for flexible DC transmission system connected to AC grid[J]. Electric Power Automation Equipmen, 2022, 42(8): 206-214.
- [6] 沈春城,严柏平,黄大卓,等. 基于波形复杂特性的励磁涌流快速识别算法研究[J]. 电气工程学报, 2024, 19(1):243-253.
SHEN Chuncheng, YAN Baiping, HUANG Dazhuo, et al. Research on fast identification algorithm of inrush current based on complex characteristics of waveform[J]. Journal of Electrical Engineering, 2024, 19(1): 243-253.
- [7] 张驰,张慧芬,孙刚,等. 基于电压变化特征的配电网故障类型及铁磁谐振辨识方法[J]. 广东电力, 2022, 35(6):50-59.
ZHANG Chi, ZHANG Huifen, SUN Gang, et al. Identification method of distribution network fault types and ferroresonance

- based on voltage variation characteristics[J]. *Guangdong Electric Power*, 2022, 35(6): 50-59.
- [8] 苑仁腾,王晨竹,项乔君,等. 轨迹数据驱动的车辆换道意图识别模型[J]. *华南理工大学学报(自然科学版)*, 2024, 52(6): 34-44.
- YUAN Renteng, WANG Chenzhu, XIANG Qiaojun, et al. Trajectory data-driven model for vehicle lane change intention recognition[J]. *Journal of South China University of Technology (Natural Science Edition)*, 2024, 52(6): 34-44.
- [9] 张振宇,张明龙,高源,等. 基于多域特征的扰动辨识方法研究[J]. *电力系统保护与控制*, 2021, 49(22): 137-144.
- ZHANG Zhenyu, ZHANG Minglong, GAO Yuan, et al. Power disturbance identification research based on multi-domain features[J]. *Power System Protection and Control*, 2021, 49(22): 137-144.
- [10] 尹文哲,夏虹,朱少民,等. 基于深度学习的核电站泵类电机故障诊断方法[J]. *哈尔滨工程大学学报*, 2024, 45(12): 2350-2357.
- YIN Wenzhe, XIA Hong, ZHU Shaomin, et al. Deep learning-based fault diagnosis method for pump motors in nuclear power plants[J]. *Journal of Harbin Engineering University*, 2024, 45(12): 2350-2357.
- [11] 陈诺,吕干云,叶加星. 基于SVM级联决策树的复合电能质量扰动识别[J]. *电气工程学报*, 2023, 18(2): 149-156.
- CHEN Nuo, LÜ Ganyun, YE Jiaying. Recognition of complex PQ disturbances based on SVM cascaded decision tree[J]. *Journal of Electrical Engineering*, 2023, 18(2): 149-156.
- [12] GUAN Zhaoxiong, HUANGFU Hancong, PANG Weilin. Wavelet transform-based composite disturbance detection method for power quality in distribution networks[J]. *Journal of Physics: Conference Series*, 2024, 2835(1): 012032.
- [13] MACHADO J G S, GOMES S, ASSIS T M L, et al. Small-signal stability assessment of power systems with multiple transport delays based on s-domain modelling[J]. *International Journal of Electrical Power and Energy Systems*, 2021, 131(1): 107111.
- [14] 周福林,刘飞帆,杨瑞轩,等. 电气化铁路车网电气耦合异常辨识[J]. *中国电机工程学报*, 2021, 41(23): 7937-7950.
- ZHOU Fulin, LIU Feifan, YANG Ruixuan, et al. Identification of abnormal phenomenon of vehicle-network coupling in electrified railway[J]. *Proceedings of the CSEE*, 2021, 41(23): 7937-7950.
- [15] 李子康,刘灏,毕天姝,等. 基于数据驱动的鲁棒性电力系统扰动识别[J]. *中国电机工程学报*, 2021, 41(21): 7261-7275.
- LI Zikang, LIU Hao, BI Tianshu, et al. Data-driven robust power system disturbance identification[J]. *Proceedings of the CSEE*, 2021, 41(21): 7261-7275.
- [16] WANG Yujie, ZHANG Xiu, ZHANG Xin, et al. A model for electroencephalogram emotion recognition: residual block-gated recurrent unit with attention mechanism[J]. *Review of Scientific Instruments*, 2024, 95(8): 085110.

收稿日期:2024-12-31

修改稿日期:2025-02-27