

基于递归图和预训练迁移学习的电能质量扰动分类

王继东¹, 王泽平¹, 张迪²

(1. 智能电网教育部重点实验室(天津大学), 天津 300072; 2. 国网沈阳供电公司, 沈阳 110000)

摘要: 电能质量扰动 (power quality disturbances, PQDs) 分类任务中深度学习方法的应用越来越广泛。针对实测标签数据不足而仿真数据可以批量生成的特点, 提出了一种基于递归图理论和预训练迁移学习的扰动分类方法。首先, 使用递归图算法将 PQDs 信号转换为二维递归图像。接着, 使用大量仿真数据对 VGG-16 深度学习网络进行预训练, 并保存模型权重参数。最后, 通过迁移学习方法, 使用少量实测数据对模型的全连接层进行微调, 实现在训练样本数量受限情况下对 PQDs 信号的深度特征提取和分类。仿真和实测数据验证表明, 该方法在标签数据不足情况下训练得到的模型仍具有较高的分类准确率。

关键词: 电能质量扰动分类; 递归图; 预训练; 迁移学习; 时间序列分类; 深度学习

Power Quality Disturbance Classification Based on Recursive Graph and Pre-Trained Transfer Learning

WANG Jidong¹, WANG Zeping¹, ZHANG Di²

(1. Key Laboratory of Smart Grid Ministry of Education, Tianjin University, Tianjin 300072, China; 2. State Grid Shenyang Power Supply Company, Shenyang 110000, China)

Abstract: Applications of deep learning methods in the classification task of power quality disturbances (PQDs) are becoming increasingly popular. Aiming at the limited availability of measured label data compared to the ability to generate simulated data in large batches, a disturbance classification method is proposed based on recursive graph theory and pre-trained transfer learning. Firstly, the PQDs signals are transformed into two-dimensional recursive images using the recursive graph algorithm. Then, a VGG-16 deep learning network is pre-trained using a large amount of simulated data, and the model's weight parameters are saved. Finally, through transfer learning method, the fully connected layer of the model is fine-tuned using a limited amount of measured data, enabling deep feature extraction and classification of PQDs signals under the constraint of limited training samples. Simulation and measured data validation demonstrate that the proposed method achieves high classification accuracy even with limited labeled data.

Key words: classification of power quality disturbances; recursive graph; pre-trained; transfer learning; time series classification; deep learning

0 引言

为了解决电力系统存在的种种问题, 直流输电与柔性交流输电技术不断投入实际工程应用、分布式能源并网规模不断扩大, 这使得电网中电压和电流波形畸变越来越严重^[1]。与此同时, 随着电网中

精密电能用户的增多, 要求电网必须提供与用户所要求的质量指标相适应的电能^[2]。因此, 提高电能质量至关重要。

想要解决电能质量的波动问题, 首先要了解电能质量波动的本质, 以便后续寻找原因和制定解决方案。PQDs 识别与分类一般分为特征提取和扰动分类两个步骤。特征提取方法主要包括傅里叶变换^[3]、小波变换^[4]、希尔伯特黄变换^[5]、S 变换^[6]等, 这些分析方法都有着各自的特点: 傅里叶变换

基金项目: 国家重点研发计划资助项目(2022YFB4200703)。

Foundation item: Supported by the National Key Research and Development Program of China (2022YFB4200703).

主要适用于平稳信号的分析,但在应用中会出现局部特征的丢失,在非平稳信号的分析中效果不佳^[7];小波变换克服了这一问题,适用于非平稳信号的分析,但受噪声影响较大,实际效果并不稳定^[8];希尔伯特黄变换有较好的抗噪性能,且分析精度高,但是会受模态混叠和端点效应影响;S变换能够很好地表征电能质量时域扰动特征和频域扰动特征^[9],但是其时频分辨率相对固定,不适合于多扰动信号的特征提取^[10]。以上特征提取方法在分类过程中常用决策树^[11]、支持向量机、深度学习^[12]等方法进行分类。其中决策树容易出现过拟合和局部最优现象;支持向量机算法对异常数据不敏感,效果受最优核函数和参数的选取影响较大^[13];深度学习算法准确率更高效果更好,但是其需要更多计算资源和足够的数据以避免过拟合。

由于深度学习方法具有较高的自适应特征提取能力和分类准确率,且不需要手动提取特征,越来越多的研究者开始将深度学习技术应用于电能质量扰动分类问题中,并取得了许多令人瞩目的成果。目前卷积神经网络(convolutional neural networks, CNN)和循环神经网络(recurrent neural networks, RNN)应用最为广泛。

基于CNN的分类方法主要采用卷积和池化操作提取特征,然后使用全连接层进行分类,具有较高的特征提取能力和分类准确率,且不需要手动设计特征提取方法。但是由于CNN的卷积操作是基于局部邻域的,在面对时间序列时容易忽略时间维度的依赖关系,因此常用于图像分类。在时间序列分类中可以先使用其他特征提取方法将时间序列转化为图片,再用CNN进行分类,例如文献[14]提出一种基于Gram矩阵和改进卷积神经网络T-CNN的时间序列分类方法。

基于RNN的方法主要使用循环神经网络对信号的时间序列特征进行建模和分类,具有较好的序列建模能力和时序信息的处理能力,能够捕捉信号的动态特征和时间序列特征。目前应用较多的是长短期记忆网络(long short time memory, LSTM),它在RNN的基础上进行了改进,解决了梯度消失/爆炸的问题。例如,文献[15]使用LSTM网络对信号进行分类,并基于Bagging理论整合多个LSTM网络的训练结果以提高网络的泛化能力。

在实测数据分类任务中,需要面对可用标签数

据不足的问题。迁移学习能将训练好的模型应用于新任务上,通过微调模型的部分权重来适应新任务,从而减少对大量标注数据的依赖^[16]。

本文首先使用递归图算法把PQDs信号转变为二维的递归图像,然后从图像分类的角度出发,使用结构简单且具有一定深度的VGG-16模型进行分类,以保证本文所提深度迁移学习方法的泛用性。模型分类过程为:使用由MATLAB生成的十五类仿真数据对模型所有层参数进行预训练,然后迁移模型卷积层及池化层参数及权重,使用少量实测数据训练模型的全连接层,从而实现实测数据不足情况下电能质量扰动信号深度特征提取以及网络模型优化。

1 递归图理论

1.1 相空间重构及递归图原理

递归图(recurrent plot, RP)是一种图形结构,它可以体现时间序列的不稳定性和时序相关性,对时序数据中隐含的规律具有较强的识别能力。根据时序数据生成递归图,首先要进行相空间重构。相空间重构将混沌时间序列转换到高维相空间,在高维相空间掌握时间序列的性质和规律^[17]。递归图法通过相空间重构的方法将时间序列转换为二维图片,通过大量相互连接的节点来描述时间序列。构建的递归图的结构可以充分反映所描述时间序列的特征,如平稳性、周期性、可预测性等。根据嵌入理论,重构后的向量 X_i 为:

$$X_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}), i = 1, 2, \dots, n - (m-1)\tau \quad (1)$$

式中: n 为时间序列长度; τ 为延迟时间; m 为嵌入维数;定义重构后任意两点间的距离 $D_{i,j}$ 为:

$$D_{i,j} = |X_i - X_j|, i, j = 1, 2, \dots, n - (m-1)\tau \quad (2)$$

选取合适的阈值 ε ,可得递归矩阵 $R_{i,j}$ 为:

$$R_{i,j} = \theta(\varepsilon - D_{i,j}) \quad (3)$$

式中 $\theta(\cdot)$ 为Heaviside函数,其表达式为式(4)。

$$\theta(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4)$$

1.2 递归参数的选取

在相空间重构中,首先要合理选择延迟时间和嵌入维数,这两个参数决定了是否能构建高维相空间。互信息法是最为常用的延迟时间选取方法,它

的具体方法是基于信息理论计算信号的互信息函数,并选择函数的首个极小值点作为相空间重构的延迟时间。

假设有两组信号,分别为 $\mathbf{X}=(x_1, x_2, \dots, x_i, \dots, x_N)$ 和 $\mathbf{Y}=(y_1, y_2, \dots, y_i, \dots, y_N)$, N 为递归矩阵的维度,当给定 $\mathbf{X}$ 一个测量值,预测 $\mathbf{Y}$ 的平均信息量为互信息函数。

$$I(x, y) = H(x) + H(y) - H(x, y) \quad (5)$$

式中: $I(x, y)$ 为两组信号之间相关性的度量; $H(x)$ 、 $H(y)$ 分别为信号 X 、 Y 的熵; $H(x, y)$ 为联合熵。计算扰动信号的 x_n 和 $x_{n+\tau}$ 的互信息函数 $I(x(n), x(n+\tau))$ 。一般选取使得互信息函数取得第一个极小值时的 τ 为最佳延迟时间。

根据塔肯斯定理,为了保证相空间能够容纳原状态空间吸引子的拓扑特征,该吸引子嵌入的相空间维数必须多于原状态空间维数的两倍^[18],即嵌入维数 m 须满足式(6)所示条件。

$$m \geq 2D + 1 \quad (6)$$

式中 D 为原状态空间的维数。嵌入维数若小于这个值相空间将不能完全保留原信号的所有信息,嵌入维数越大计算复杂度越大,因此需要合理取值。

1.3 递归量化分析

递归图将一维时序数据升到二维从而直观展示系统的递归特性,但其无法定量地描述数据中隐含的规律。对此,Zbilut 和 Webber 等人提出了定量递归分析法^[19]。通过一套量化分析递归图的参数来定量刻画递归图特征,对递归图进行分析。目前常用的递归图特性参数如下所示。

1) 递归度(r_{RR}): 递归图中黑色递归点占递归点总数的百分比。

$$r_{RR} = \frac{1}{N^2} \sum_{i,j=1}^N R_{i,j} \quad (7)$$

式中 N 为递归矩阵的维度。

2) 确定性(r_{DEF}): 与主对角线相平行的线段上,黑色递归节点数与总节点数的比值,通常以百分比形式表示。

$$r_{DEF} = \frac{\sum_{l=l_{\min}}^N lP(l)}{\sum_{i,j=1}^N R_{i,j}} \quad (8)$$

式中: $l_{\min}$ 为递归图中对角线长度的最小阈值; $P(l)$

为递归图中长度为 l 的对角线分布概率。

3) 最长对角线($L_{\max}$): 递归图中与主对角线平行的最长线段的长度。

$$L_{\max} = \max\{l_i; i = 1, 2, \dots, N_i\} \quad (9)$$

式中: l_i 为第 i 条对角线的长度; N_i 为对角线的数量。

4) 递归熵(r_{ENT}): 指递归图中沿对角线方向线段的香农熵。

$$r_{ENT} = - \sum_{l=l_{\min}}^N P(l) \ln P(l) \quad (10)$$

5) 递归趋势(r_{RT}): 用于衡量系统的稳定性。

$$r_{RT} = \frac{\sum_{k=1}^K [k - (K+1)/2](r_k - \bar{r})}{\sum_{k=1}^K [k - (K+1)/2]^2} \quad (11)$$

式中: K 为递归图对角线的数量; k 为对角线的索引; r_k 为第 k 条对角线的长度; $\bar{r}$ 为对角线平均长度。

递归图的递归量化分析能够反映出原始信号隐含的规律。PQDs 信号具有周期性、非线性和突变性等特点,递归图的量化递归分析可以更加直观地描述扰动信号,反映不同类型扰动信号的特征信息。

2 VGG-16 神经网络与预训练迁移学习

2.1 基于深度模型的迁移学习

深度学习算法往往需要在大量数据中学习如何挖掘数据的深层特征,数据量是深度学习的重要支撑,在某些领域时常会出现所需训练数据不足的情况^[20]。迁移学习通过迁移已有知识来提高目标领域中的学习能力,从而解决目标领域仅有少量标签数据的学习问题^[21]。根据迁移内容可将迁移学习可以分为 3 类,即基于样本、基于特征和基于模型的迁移学习^[22]。其中基于模型的迁移学习是指通过对源域中的模型进行调整和优化,来适应目标域的分类、回归等任务。这种方法通常需要选择合适的预训练模型,然后通过微调等技术进行优化^[23]。由于基于模型的迁移学习具有更好的泛化能力,其在各个领域的应用最为广泛。

在进行迁移学习时,如果源域与目标域之间的语义鸿沟过大会出现“负迁移”现象^[24],而迁移学习常用的 ImageNet 训练模型与波形特征图差异过大,直接迁移效果可能会较差。在 PQDs 分类问题中仿

各层网络参数, 参数修正过程为:

$$\begin{cases} W_i = W_i - \alpha \frac{\partial}{\partial W_i} J(W, b) \\ b_i = b_i - \alpha \frac{\partial}{\partial b_i} J(W, b) \end{cases} \quad (13)$$

式中: W 、 b 分别为网络权重及偏置; α 为学习率; $J(W, b)$ 为损失函数。对于输出层为 Softmax 层, $J(W, b)$ 可采用交叉熵函数。

3) 重复步骤 1) 及步骤 2) 过程, 直到网络符合预期, 得到模型 A。

基于 PQDs 信号递归图集 D_i 及迁移学习理论构建模型 B, 其主要步骤如下。

1) 构造模型 B。在 VGG-16 基础上将模型的全连接层 FC3 和输出层神经元数量改为 5。全连接层特征维度分别为 1×512 、 1×64 及 1×5 。

2) 固定模型 A 卷积层和池化层的参数, 并迁移至模型 B 对应位置。如图 2 所示, 本文这里将 VGG-16 网络中较早的层保持固定, 而仅对网络的更高级别部分进行微调。

3) 输入实测数据 D_i 进行训练, 基于前向传播和反向传播优化更新模型 B 全连接层和输出层的参数。在这次训练过程中通过实测 PQDs 信号递归图像的反向传播来更新预训练的权值以达到微调模型的效果, 同时避免过拟合。

3 仿真数据验证

3.1 电能质量扰动信号的递归图片

通过递归化的方法将仿真生成的 15 种扰动信号转化为二维递归图像, 此方法转化成的二维图像能够充分反映原始数据的时域和频域的特征。使用递归图法构建电能质量扰动信号递归图像, 延迟时间 τ 取 3。采用 G-P 关联维数法求得关联维数为 1, 本文电能质量扰动信号的最佳嵌入维数取 $m=3$ 。图 3 为部分 PQDs 信号的递归图。

递归图清晰地体现了各种信号的特征信息, 正弦谐波信号为周期信号, 因此其图形都呈规律的网格形状, 带有明显周期性。而中断信号则带有突变特征, 因此其递归图中都呈现黑白明显分块形态。

相同的 PQDs 信号在参数不同时其对应的递归图像也会有相应的变化。图 4 是电压暂降信号在固定参数 t_1 、 t_2 , 仅改变参数 a 时的递归图。从图 4 可




图 3 电能质量扰动信号递归图

Fig. 3 Recursion diagram of power quality disturbance signal

以看出, 当扰动发生的时间相同时, 信号所对应的递归图像的十字型区域起始位置和宽度将不会发生变化, 参数 a 决定了递归图中十字型区域的结构。




图 4 不同参数暂升信号递归图 ($t_1=0.05$ s, $t_2=0.12$ s)

Fig. 4 Recursion diagram of swell signals with different parameters ($t_1=0.05$ s, $t_2=0.12$ s)

图 5 是暂降信号在固定参数 a , 改变 t_1 、 t_2 的递归图。由图 5 可知, 当固定参数 a 时十字型区域的结构也会固定, 扰动的发生时间决定十字型区域的起始位置和宽度。由信号生成的递归图像能对参数 a 和时间 t_1 、 t_2 的变化作出相应的反馈, 这说明了递归图的图形特征可以反映出原始信号的特征, 这种表示法具有定义良好的视觉纹理模式, 其图形能够刻画电能质量扰动信号不同类别的区别特征。

3.2 仿真数据结果验证

首先使用仿真数据验证本文所提出的基于递归图与 VGG-16 神经网络的 PQDs 分类方法的效果。训练环境参数如表 1 所示。

通过 MATLAB 生成 15 类扰动信号, 其中包括正常信号、7 类单一扰动信号和 7 类复合扰动信号。




图 5 不同参数暂降信号递归图($\alpha=0.5$)

Fig. 5 Recursion diagram of sag signals with different parameters($\alpha=0.5$)

表 1 训练环境参数

Tab. 1 Training environment parameters

硬件/软件	模型/版本
操作系统	Windows10 (64bit)
CPU	12 vCPU Intel(R) Xeon(R) Platinum 8 255 C CPU @ 2.50 GHz
GPU	RTX 2080 Ti
Cuda	12.0
Python	3.9
tensorflow	2.9.0

每类信号生成 250 个随机样本, 共 3 750 个样本。叠加信噪比(signal-to-noise ratio, SNR)为 50 dB, 40 dB, 30 dB 和 20 dB 的高斯白噪声模拟真实信号。每类扰动选取 150 个构成训练集, 50 个作为验证集, 其余构成测试集。

根据 VGG-16 模型训练的要求, 电能质量扰动信号递归图的尺寸为 $227 \times 227 \times 3$, 网络模型训练采用 Adam 优化器, 初始学习率为 0.001, 迭代批次大小为 16, 每次训练最大 epoch 设置为 15。

通过递归图理论将扰动信号转化为递归图像, 作为 VGG-16 迁移网络模型的输入, 并采用 ImageNet 参数对模型进行初始化。表 2 为 VGG-16 迁移模型对 15 种扰动信号的分类效果。

由表 2 可以看出, VGG-16 网络模型对电能质量扰动信号的总体准确率较高, 在信噪比高于 30 dB 时准确率能够达到 99 % 以上, 在信噪比达到 20 dB 时准确率仍能够达到 95 % 以上。这说明本文中方法具有良好的分类性能。

图 6 为信噪比为 20 dB 情况下模型在测试集数据上的混淆矩阵。从图 6 可以看出, 电压中断、暂态震荡、电压暂升分类准确率较高, 表明这几种信号经过相空间重构得到的递归图形特征明显。在高噪声环境下脉冲暂态信号和正常信号的区分变得困难, 主要是因为过高的噪声干扰掩盖了脉冲信号的

表 2 VGG-16 迁移模型各个类型分类效果

Tab. 2 Classification effects of each type of VGG-16 migration model

扰动类型	准确率/%			
	20 dB	30 dB	40 dB	50 dB
正常 C1	85.08	97.73	100	100
电压暂升 C2	99	100	100	100
电压暂降 C3	84.76	99	99	99.01
电压中断 C4	100	100	100	100
脉冲暂态 C5	85.94	97.59	100	100
暂态振荡 C6	100	100	100	100
谐波 C7	95.87	99.67	100	100
闪变 C8	98.30	100	100	100
暂降+震荡 C9	87.14	99	99	98.99
暂升+震荡 C10	100	100	100	100
暂降+谐波 C11	95.81	100	99.66	100
暂升+谐波 C12	99.66	99.66	100	100
闪变+谐波 C13	100	100	99.67	100
暂降+闪变 C14	98.65	100	100	100
暂升+闪变 C15	99.66	100	100	100
平均	95.32	99.51	99.82	99.87

特征, 尤其是在脉冲信号较弱的情况下两者的波形图很难被准确地区分开来。




图 6 信噪比为 20 dB 时分类结果的混淆矩阵

Fig. 6 Confusion matrix of classification results at 20 dB SNR

4 实测数据验证

4.1 预训练模型

对模型进行预训练时, 为保证得到的参数能够有较高的泛用性及鲁棒性, 需要足够多且特征更为丰富的训练数据。本文使用 MATLAB 生成 15 类正

常与扰动信号, 每一类包含信噪比分别为 50、40、30 和 20 dB 的信号各 250 个, 共 1 000 个。每类扰动选取 600 个构成训练集, 200 个作为验证集, 其余为测试集。

为了确保所得参数的鲁棒性, 将训练模型的最大迭代次数设置为 50 个 epoch。通过递归图理论将扰动信号转化为递归图像, 输入 VGG-16 网络模型进行预训练。训练过程如图 7 所示。




图 7 预训练模型训练过程

Fig. 7 Training processes of pre-trained model

由图 7 可以看出, 随着迭代次数的增加准确率曲线已经趋于平稳, 因此实验中所迭代次数已经足够, 得到的模型已经具备较好的特征提取和分类功能。

预训练模型在测试集上的准确率为 98.67%, 其混淆矩阵如图 8 所示。




图 8 预训练模型在测试集上的混淆矩阵

Fig. 8 Confusion matrix of the pre-trained model on the test set

根据混淆矩阵的分析结果, 观察到预训练模型在测试集分类过程中存在两个主要问题。首先, 正常数据与脉冲暂态之间容易产生混淆。其次, 少量电压暂降数据被错误地分类为暂降与暂态震荡的复合扰动。根据表 2 中的数据推测, 这些问题主要受到较低信噪比数据的影响。

上述实验结果说明预训练得到的模型在 PQDs 分类问题中表现出良好的性能, 模型能够有效地提取波形的特征并进行分类。因此该模型及其参数可以用于相关领域的任务中, 通过微调的方式获得更好的性能。

4.2 实测 PQDs 信号分类

为了验证本文方法在实际信号中的可行性, 在这部分中, 采用一组实际信号来测试本文方法的性能。数据由 IEEE PES 数据库提供, 用于电能质量扰动分类。实测信号采样率为每周周期 256 个点, 每个信号的总长度为 1 536。图 9 为实测中断信号和谐波信号的递归图表示。




图 9 实测信号递归图

Fig. 9 Recursion graph of measured signals

虽然迁移学习一定程度上缓解了对标签数据量的要求, 但部分实测数据仍然数量过少, 所以我们仍对数据进行数据增强处理。增强后的数据集训练集样本为 400, 验证集为 200。使用增强后的数据集来训练本章网络模型。

根据初始化参数的选择以及是否冻结部分参数, 分为 5 种情况进行训练。初始化参数可选择随机初始化, 使用 ImageNet 参数和使用本文预训练模型得到的参数。其中使用后两者作为初始化参数时网络初始就已经具备良好的特征提取能力, 因此可以选择冻结卷积层和池化层, 只训练全连接层对模型进行微调。

随机初始化时学习率设置为 0.005, 其他 4 种情况学习率设置为 0.001, 训练最大 epoch 设置为 15。由于增强后的数据集仍然较小加上模型本身具

有不稳定性, 单次实验结果可能会有较大误差, 因此实验重复10次, 训练结果取平均值。

上述5种方法的训练过程如图10—11所示, 训练结果如表3所示。




图10 不同方法的验证集准确率

Fig. 10 Validation accuracies of different methods




图11 不同方法的验证集损失

Fig. 11 Validation loss of different methods

由图11和表3数据可以看出, 随机初始化效果最差, 使用ImageNet参数初始化时有不错的效果, 而使用预训练参数进行初始化时初始就能有较高的准确率, 且最终也能达到更高的准确率。使用预训练模型参数相比直接迁移ImageNet参数有明显优势。

在冻结卷积层后准确率有所下降损失有所增加, 在迁移ImageNet参数时此现象更为严重。但是

表3 实测数据验证结果

Tab. 3 Validation results of experimental data

使用方法	验证集准确率/%	验证集损失/%	训练速度/(ms·step ⁻¹)
随机初始化	76.5	67.4	110
ImageNet初始化	90.2	41.1	11
ImageNet初始化+冻结参数	88.4	55.4	56
预训练模型初始化	95.2	16.2	110
预训练模型初始化+冻结参数	94.2	20.4	56

冻结底层权重能大幅提高训练速度, 降低训练所需算力资源。这表明在本文的实验中递归图对参数敏感问题并未对模型性能产生较大负面影响。

5 结论

针对使用深度学习对PQDs进行分类时实测带标签扰动信号不足的问题, 本文引入了迁移学习和预训练的方法, 降低了深度学习模型对数据量的依赖, 使模型在数据较少的情况下仍能达到较高的准确率。通过仿真和实测数据的验证, 得出以下结论。

1) 使用递归图算法将PQDs信号转换为二维递归图像, 并使用这些图像来训练卷积神经网络模型VGG-16。仿真数据的验证结果表明, 这种方法具有良好的分类效果。

2) 采用迁移学习方法可以降低模型对大量标签数据的需求。实测数据的验证结果表明, 在训练数据不足的情况下迁移学习能够提高模型的性能。

3) 与直接迁移ImageNet参数相比, 使用预训练的参数效果更好。通过迁移仿真数据预训练得到的参数可以进一步提高模型的性能。

本研究主要验证了递归图、迁移学习和预训练在PQDs分类任务中的实际效果。为了进一步提高模型的准确率和降低算力需求, 可以考虑使用更先进的网络结构并增加降噪模块。

参考文献

- [1] 于浩, 贾清泉, 李珍国, 等. 基于时间序列模式匹配的电能质量区域化治理[J]. 中国电机工程学报, 2019, 39(13): 3788 - 3799.
YU Hao, JIA Qingquan, LI Zhenguo, et al. Regionalization control for power quality based on time series pattern matching [J]. Proceedings of the CSEE, 2019, 39(13): 3788 - 3799.

- [2] 曹梦舟, 张艳. 基于卷积-长短期记忆网络的电能质量扰动分类[J]. 电力系统保护与控制, 2020, 48(2):86-92.
CAO Mengzhou, ZHANG Yan. Classification for power quality disturbances based on CNN-LSTM network [J]. Power System Protection and Control, 2020, 48(2):86-92.
- [3] SATPATHI K, YEAP Y M, UKIL A, et al. Short-time fourier transform based transient analysis of VSC interfaced point-to-point DC system[J]. IEEE Transactions on Industrial Electronics, 2018, 65(5):4080-4091.
- [4] 姚望, 张英, 王明伟, 等. 基于WPT和SSA-BP的直流充电桩充电模块故障诊断[J]. 南方电网技术, 2023, 17(9): 85-93.
YAO Wang, ZHANG Ying, WANG Mingwei, et al. Fault diagnosis of charging module of DC charging pile based on WPT and SSA-BP [J]. Southern Power System Technology: 2023, 17(9): 85-93.
- [5] KIRUTHIGA B, BANU R N, DEVARAJ D. Detection and classification of power quality disturbances or events by adaptive NFS classifier[J]. Soft Computing, 2019(24):1-12.
- [6] 赵俊, 杨洪耕, 李伟. 利用S变换与变尺度模板标准化的短时电能质量扰动分类[J]. 南方电网技术, 2010, 4(3):72-76.
ZHAO Jun, YANG Honggeng, LI Wei. Classification of short duration power quality disturbance using S-transform and scale zooming standardization [J]. Southern Power System Technology, 2010, 4(3):72-76.
- [7] 冯杰, 王大兴, 赵兴虹, 等. 基于Pisarenko谐波分解的电力电缆缺陷定位方法[J/OL]. 南方电网技术, 1-7[2025-01-18]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20240627.1607.007.html>.
FENG Jie, WANG Daxing, ZHAO Xinghong, et al. Defect location method of power cable based on pisarenko harmonic decomposition [J/OL]. Southern Power System Technology, 1-7[2025-01-18]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20240627.1607.007.html>.
- [8] 杨晓梅, 郭林明, 肖先勇, 等. 基于可调品质因子小波变换和随机森林特征选择算法的电能质量复合扰动分类[J]. 电网技术, 2020, 44(8):3014-3020.
YANG Xiaomei, GUO Linming, XIAO Xianyong, et al. Classification of multiple power quality disturbances based on TQWT and random forest feature selection algorithm [J]. Power System Technology, 2020, 44(8):3014-3020.
- [9] 黄南天, 彭华, 蔡国伟, 等. 电能质量复合扰动特征选择与最优决策树构建[J]. 中国电机工程学报, 2017, 37(3):776-786.
HUANG Nantian, PENG Hua, CAI Guowei, et al. Feature selection and optimal decision tree construction of complex power quality disturbances [J]. Proceedings of the CSEE, 2017, 37(3):776-786.
- [10] 李建文, 秦刚, 李永刚, 等. 基于布莱克曼窗S变换与数据库查询的电能质量扰动识别与分类新方法[J]. 电网技术, 2020, 44(12):4734-4743.
LI Jianwen, QIN Gang, LI Yonggang, et al. Recognition and classification new method of power quality disturbances based on blackman window S transform and database query [J]. Power System Technology, 2020, 44(12):4734-4743.
- [11] ACHLERKAR P D, SAMANTARAY S R, MANIKANDAN M S. Variational mode decomposition and decision tree based detection and classification of power quality disturbances in grid-connected distributed generation system[J]. IEEE Transactions on Smart Grid, 2018, 9(4):3122-3132.
- [12] 奚鑫泽, 邢超, 覃日升, 等. 基于深度卷积去噪网络的电能质量扰动识别方法[J]. 南方电网技术, 2022, 16(12):118-125.
XI Xinze, XING Chao, TAN Risheng, et al. Power quality disturbance identification method based on deep convolutional denoising network [J]. Southern Power System Technology, 2022, 16(12):118-125.
- [13] 宋晓芳, 陈劲操. 基于支持向量机的动态电能质量扰动分类方法[J]. 电力自动化设备, 2006(4):39-42.
SONG Xiaofang, CHEN Jincao. Classification method of dynamic power quality disturbances based on SVM [J]. Electric Power Automation Equipment, 2006(4):39-42.
- [14] 姜天. 基于Gram矩阵的T-CNN时间序列分类方法研究[D]. 沈阳:辽宁大学, 2021.
- [15] 张迪. 基于深度学习的电能质量扰动识别分类[D]. 天津:天津大学, 2021.
- [16] 李宝琴, 吴俊勇, 张若愚, 等. 融合多类型深度迁移学习的电力系统暂态稳定自适应评估[J]. 电力自动化设备, 2023, 43(1):184-192.
LI Baoqin, WU Junyong, ZHANG Ruoyu, et al Adaptive assessment of power system transient stability based on multi type deep transfer learning [J]. Electric Power Automation Equipment, 2023, 43(1):184-192.
- [17] 武昭旭. 基于深度学习的电能质量扰动识别[D]. 淮南:安徽理工大学, 2020.
- [18] 陈伟, 何家欢, 裴喜平. 基于相空间重构和卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2018, 46(14):87-93.
CHEN Wei, HE Jiahuan, PEI Xiping. Classification for power quality disturbance based on phase-space reconstruction and convolution neural network [J]. Power System Protection and Control, 2018, 46(14):87-93.
- [19] WEBBER C L J, ZBILUT J P. Dynamical assessment of physiological systems and states using recurrence plot strategies [J]. Journal of Applied Physiology, 1994, 76(2):965-73.
- [20] 程凯, 彭小圣, 徐其友, 等. 基于特征选择与多层级深度迁移学习的风电场短期功率预测[J]. 高电压技术, 2022, 48(2):497-503.
CHENG Kai, PENG Xiaosheng, XU Qiyu, et al. Short-term wind power prediction based on feature selection and multi-level deep transfer learning [J]. High Voltage Engineering, 2022, 48(2):497-503.
- [21] 孟子超, 杜文娟, 王海风. 基于迁移学习深度卷积神经网络的配电网故障区域定位[J]. 南方电网技术, 2019, 13(7):25-33.
MENG Zichao, DU Wenjuan, WANG Haifeng. Distribution network fault area location based on deep convolution neural network with transfer learning [J]. Southern Power System Technology, 2019, 13(7):25-33.
- [22] 梁振隆. 基于递归图和卷积神经网络的结构损伤识别研究[D]. 合肥:合肥工业大学, 2020.
- [23] 赵晨浩, 焦在滨, 李程昊, 等. 基于主动迁移学习的电力系统暂态稳定自适应评估[J]. 中国电力, 2025, 58(1):70-77.
ZHAO Chenhao, JIAO Zaibin, LI Chenghao, et al. Adaptive assessment of power system transient stability based on active transfer learning [J]. China Electric Power, 2025, 58(1):70-77.

(下转第 114 页 Continued on Page 114)