

DOI: 10.12158/j.2096-3203.2024.03.011

# 基于 SCG 优化 SSAE-FFNN 的电能质量复合扰动深度特征提取与分类

丁皓月<sup>1</sup>, 吕千云<sup>1</sup>, 史明明<sup>2</sup>, 费骏韬<sup>2</sup>, 俞明<sup>3</sup>, 吴启宇<sup>3</sup>

(1. 南京工程学院电力工程学院, 江苏 南京 211167;

2. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211103;

3. 国网江苏省电力有限公司南京市溧水区供电分公司, 江苏 南京 211200)

**摘要:**随着智能电网的发展,电能质量问题已遍布电网并威胁着电网的安全稳定,且电能质量监测数据日渐庞大,因此实现大规模系统中电能质量扰动(power quality disturbances, PQDs)的深度特征提取及智能分类识别对电力系统污染检测与管理具有重要意义。为此,文中提出一种基于堆叠稀疏自编码器(stacked sparse auto encoder, SSAE)和前馈神经网络(feedforward neural network, FFNN)的电能质量复合扰动分类方法。首先,基于 IEEE 标准构建 PQDs 仿真模型。然后,建立基于 SSAE-FFNN 的 PQDs 分类模型,并引入缩放共轭梯度(scaled conjugate gradient, SCG)算法对模型进行优化,以提高梯度下降速度和网络训练效率。接着,为有效降低堆叠网络的重构损失同时提取出深度的低维特征,构建 SSAE 的逐层训练集及微调策略。最后,通过算例分析验证文中方法的分类效果、鲁棒性、泛化性和适用场景规模。结果表明,文中方法能够有效识别电能质量复合扰动,对含误差扰动和某地市电网的 21 组实测扰动录波数据也有较高的分类准确率。

**关键词:**电能质量;复合扰动分类;堆叠稀疏自编码器(SSAE);深度特征提取;缩放共轭梯度(SCG);前馈神经网络(FFNN)

中图分类号:TM732

文献标志码:A

文章编号:2096-3203(2024)03-0099-12

## 0 引言

近年来,交直流混合输电设备、大量分布式电源、电力电子设备及大规模新型负荷接入电网<sup>[1]</sup>,导致系统等效惯量降低,动态特性愈加复杂,并带来了谐波、电压暂降等电能质量问题,给电网、用户以及诸多关联方带来安全、经济等方面的危害<sup>[2-3]</sup>。电能质量扰动(power quality disturbances, PQDs)分析是电力系统污染检测和治理的前提,实际电网中,PQDs种类繁多,包括单一型和混合型。因此,快速准确识别 PQDs 具有重要意义。

现有 PQDs 识别通常由特征提取和分类识别组成<sup>[4]</sup>。特征提取是指利用信号处理等数学方法结合优化技术提取出扰动信号特征,常用方法有短时傅里叶变换(short-time fourier transform, STFT)<sup>[5-7]</sup>、小波变换(wavelet transform, WT)<sup>[8-10]</sup>、小波包变换(wavelet packet transform, WPT)<sup>[11-13]</sup>、S 变换<sup>[14-16]</sup>、希尔伯特黄变换(hilbert-huang transform, HHT)<sup>[17-19]</sup>等。以上方法都是时频分析方法,可以同时时在时域和频域对 PQDs 信号进行分析,能够得到持续时间、幅值、频率等特征。PQDs 分类识别是指将提取出的特征量输入分类器实现扰动分类。当前常用分

类方法有基于经验规则的分类方法,如模糊逻辑(fuzzy logic, FL)<sup>[20]</sup>、决策树(decision tree, DT)<sup>[21-22]</sup>等,以及基于机器学习的分类方法,如支持向量机(support vector machine, SVM)<sup>[23-24]</sup>、人工神经网络(artificial neural network, ANN)<sup>[25-26]</sup>等。其中,基于 FL 和 DT 的分类方法都具有建模、分析简单,分类精度高等优点,但是针对新的 PQDs,分类器的性能会有所降低。SVM 算法简单,但标准的 SVM 只能解决两分类问题,解决 PQDs 问题时须将多分类转换为多个两分类,因此,对于复杂 PQDs, SVM 算法存在空间复杂度较高、训练难度增大等问题<sup>[4]</sup>。

上述特征提取和分类识别方法均能达到相当的分精度,但传统特征提取方法大都依靠人工经验进行选择,在特征提取的过程中须注重细节,浪费时间和人工成本。且依靠经验获取的特征组合大都没有统一的理论依据,很难提取到深度的 PQDs 特征,往往缺乏普遍性。此外,随着新型电力系统的发展,实际电网中的 PQDs 往往为混合多种扰动的复合扰动,分类难度更大。而大多数方法只在小样本数据集中取得较好效果,在大规模系统中的应用效果受限。因此,为解决 PQDs 特征自动提取及大规模系统中复合扰动分类的问题,部分学者提出采用通用性的非机理方法代替传统扰动特征提取

收稿日期:2023-12-27;修回日期:2024-02-19

方法。文献[27]利用压缩感知理论得到扰动信号的稀疏向量,形成隐式扰动特征,然后利用深度置信网络(deep belief network, DBN)实现扰动分类,但这种稀疏表示未能有效表征深度特征。文献[28]则在一维 PQDs 信号转化得到的二维图像的基础上,利用残差神经网络(residual neural network, ResNet)提取图像的深度特征,能更好地捕捉信号特征,提高分类精度,但会增加计算成本,影响效率。

自编码器(autoencoder, AE)作为一种无监督的深度神经网络,已应用于异常检测、图像生成、分类识别等领域。利用 AE 提取 PQDs 特征不需要依靠先验知识,其具有输入等于输出的特性,所以能够一次性提取 PQDs 深度特征,并且解决了由于神经网络随机初始化权值造成每次训练结果不同的问题。因此,文中从 PQDs 特征自动提取及大规模系统中 PQDs 分类的角度出发,提出一种基于堆叠稀疏自编码器(stacked sparse auto encoder, SSAE)和前馈神经网络(feedforward neural network, FFNN)的电能质量复合扰动分类模型。首先,使用多层稀疏自编码器(sparse auto encoder, SAE)逐层处理含复合扰动的高维 PQDs 数据,通过稀疏正则项限制特征层的稀疏性以提出更具普遍性的低维深度特征。此外,考虑到 SAE 中不同的参数需要不同的学习率,引入缩放共轭梯度(scaled conjugate gradient, SCG)算法进行网络参数的自适应调整。通过无监督微调进一步降低整体重构损失,并通过 SSAE 实现 PQDs 特征的自动提取。然后,采用 FFNN 对 PQDs 类型进行分类识别。最后,通过 MATLAB 仿真得到 PQDs 原始数据集,并确定 SSAE-FFNN 模型的网络结构,验证其可行性及有效性。此外,利用含粗差、噪声、基频波动及不同样本数和采样频率的数据对所提模型的鲁棒性、泛化性及适用场景规模进行验证,并采用实测数据验证文中方法在实际电力系统中的适应性。

## 1 PQDs 模型

IEEE Std 1159-2019<sup>[29]</sup>将 PQDs 划分为 9 种:电压暂升(swell)、电压暂降(sag)、电压中断(outage)、电压闪变(flicker)、暂态振荡(oscillatory)、暂态脉冲(impulse)、谐波/间谐波(harmonics)、电压缺口(notch)、电压尖峰(spike)。PQDs 模型如下:

(1) 正常信号  $V(t)$ 。

$$V(t) = \sin(\omega t) \quad (1)$$

式中:  $\omega$  为额定角频率。

(2) 电压暂升  $v_1(t)$ 。

$$v_1(t) = [1 + \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t) \quad (2)$$

式中:  $\alpha$  为附加扰动幅值,  $0.1 \leq \alpha < 0.8$ ;  $t_1$ 、 $t_2$  分别为扰动开始和结束时间,  $T \leq t_2 - t_1 \leq 9T$ ,  $T$  为扰动信号周期;  $u$  为阶跃函数。

(3) 电压暂降  $v_2(t)$ 。

$$v_2(t) = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t) \quad (3)$$

式中:  $0.1 \leq \alpha \leq 0.9$ ;  $T \leq t_2 - t_1 \leq 9T$ 。

(4) 电压中断  $v_3(t)$ 。

$$v_3(t) = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t) \quad (4)$$

式中:  $0.9 \leq \alpha \leq 1$ ;  $T \leq t_2 - t_1 \leq 9T$ 。

(5) 电压闪变  $v_4(t)$ 。

$$v_4(t) = (1 + \alpha \sin(\beta \omega t)) \sin(\omega t) \quad (5)$$

式中:  $0.1 \leq \alpha \leq 0.2$ ;  $\beta$  为闪变频率相对系数,  $0.1 \leq \beta \leq 0.2$ 。

(6) 暂态振荡  $v_5(t)$ 。

$$v_5(t) = \sin(\omega t) + \alpha e^{-(t-t_1)/\tau} \sin(\beta \omega (t - t_1)) \times (u(t - t_2) - u(t - t_1)) \quad (6)$$

式中:  $0.1 \leq \alpha \leq 0.2$ ;  $\tau$  为振荡衰减系数,  $0.008 \leq \tau \leq 0.04$ ;  $6 \leq \beta \leq 18$ ;  $0.05T \leq t_2 - t_1 \leq 3T$ 。

(7) 暂态脉冲  $v_6(t)$ 。

$$v_6(t) = \alpha(u(t - t_1) - u(t - t_2)) + \sin(\omega t) \quad (7)$$

式中:  $1 \leq \alpha \leq 3$ ;  $0.05T \leq t_2 - t_1 \leq 3T$ 。

(8) 谐波  $v_7(t)$ 。

$$v_7(t) = \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t) + \alpha_{11} \sin(11\omega t) \quad (8)$$

式中:  $\alpha_3, \alpha_5, \alpha_7, \alpha_{11}$  分别为 3、5、7、11 次谐波的幅值;  $0.05 \leq \alpha_i \leq 0.15, i = 3, 5, 7, 11$ 。

(9) 电压缺口  $v_8(t)$ 。

$$v_8(t) = -\operatorname{sgn}(\sin(\omega t)) \sum_{d=0}^{10} \alpha(u(t - (t_1 + 0.02d)) - u(t - (t_2 + 0.02d))) + \sin(\omega t) \quad (9)$$

式中:  $d$  为时间间隔个数;  $0.1 \leq \alpha \leq 0.4$ ;  $0.01T \leq t_2 - t_1 \leq 0.05T$ 。

(10) 电压尖峰  $v_9(t)$ 。

$$v_9(t) = \operatorname{sgn}(\sin(\omega t)) \sum_{d=0}^{10} \alpha(u(t - (t_1 + 0.02d)) - u(t - (t_2 + 0.02d))) + \sin(\omega t) \quad (10)$$

式中:  $0.1 \leq \alpha \leq 0.4$ ;  $0.01T \leq t_2 - t_1 \leq 0.05T$ 。

单一型 PQDs 波形如图 1 所示。

从单一型 PQDs 模型的数学形式可以看出,扰动模型是在标准波形的基础上添加乘法型或加法

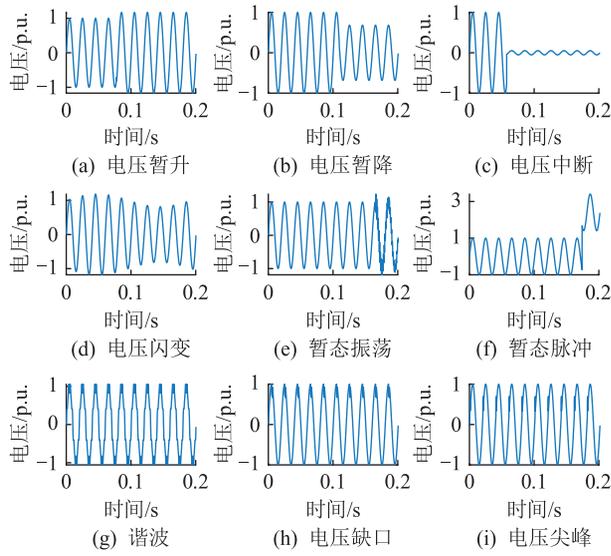


图1 单一型 PQDs 波形

Fig.1 Single PQDs waveforms

型影响形成的<sup>[30]</sup>。复合型 PQDs 的数学模型可以看作由多个单一型 PQDs 组成,由此得到复合型 PQDs 的数学模型如下:

$$V_{PQDs}(t) = (y_{\text{sag}}(t)/y_{\text{swell}}(t)/y_{\text{outage}}(t))y_{\text{flicker}}(t) \times (\sin(t) + y_{\text{harmonics}}(t)/y_{\text{notch}}(t)/y_{\text{spike}}(t)/y_{\text{noise}}(t)) + y_{\text{oscillatory}}(t)/y_{\text{impulse}}(t) \quad (11)$$

式中:  $\sin(t)$  为标准正弦函数;  $y_{\text{sag}}(t)$ 、 $y_{\text{swell}}(t)$ 、 $y_{\text{outage}}(t)$  分别为电压暂降、暂升和中断的扰动因子;  $y_{\text{flicker}}(t)$  为电压闪变的扰动因子;  $y_{\text{notch}}(t)$ 、 $y_{\text{spike}}(t)$ 、 $y_{\text{oscillatory}}(t)$ 、 $y_{\text{impulse}}(t)$  分别为电压缺口、电压尖峰、暂态振荡、暂态脉冲的扰动因子;  $y_{\text{noise}}(t)$  为噪声扰动因子;  $y_{\text{harmonics}}(t)$  为谐波扰动因子。

常见复合型 PQDs 为谐波、闪变与各种暂态扰动的复合。表 1 为几种常见的复合型 PQDs 数学模型,对应的扰动波形如图 2 所示。

表 1 复合型 PQDs 数学模型

Table 1 Mathematical model composite PQDs

PQDs 类别	数学模型
谐波+暂升	$v_{10}(t) = y_{\text{swell}}(t)(\sin(t) + y_{\text{harmonics}}(t))$
谐波+暂降	$v_{11}(t) = y_{\text{sag}}(t)(\sin(t) + y_{\text{harmonics}}(t))$
谐波+中断	$v_{12}(t) = y_{\text{outage}}(t)(\sin(t) + y_{\text{harmonics}}(t))$
谐波+闪变	$v_{13}(t) = y_{\text{flicker}}(t)(\sin(t) + y_{\text{harmonics}}(t))$
闪变+暂升	$v_{14}(t) = y_{\text{swell}}(t)y_{\text{flicker}}(t)\sin(t)$
闪变+暂降	$v_{15}(t) = y_{\text{sag}}(t)y_{\text{flicker}}(t)\sin(t)$

## 2 PQDs 分类模型

### 2.1 自编码器 (AE)

AE 属于 FFNN,关于中央层对称,即其输出层神经元与输入层相同,且隐藏层大小没有限制。AE

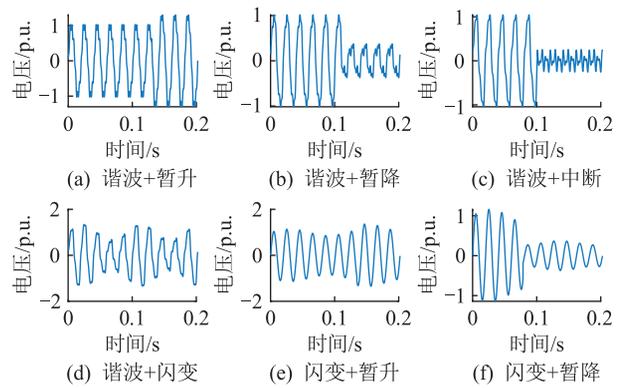


图 2 复合型 PQDs 波形

Fig.2 Composite PQDs waveforms

可看作由编码器和解码器两部分组成,并使用反向传播算法训练使输出尽可能再现输入数据,结构参见图 3。

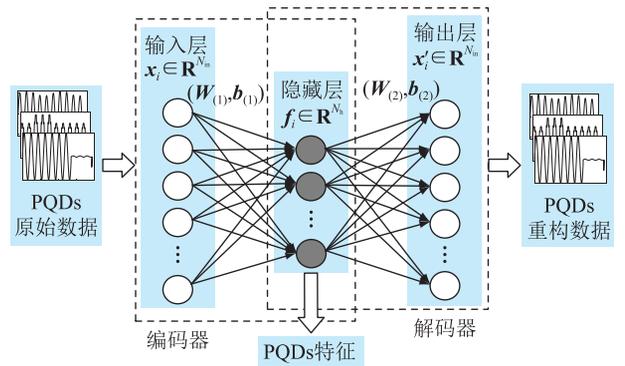


图 3 用于 PQDs 分类的 AE 结构

Fig.3 Structure of AE for PQDs classification

给定一组无标签的 PQDs 数据集  $X$ ,  $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ ,  $\mathbf{x}_i \in \mathbf{R}^{N_{in}}$ ,  $n$  为训练样本数,  $N_{in}$  为 AE 输入层和输出层的神经元数。设定隐藏层神经元数为  $N_h$ ,隐藏层输出为  $F = \{f_1, f_2, \dots, f_n\}$ ,  $f_i \in \mathbf{R}^{N_h}$ ;输出层的输出为  $X' = \{\mathbf{x}'_1, \mathbf{x}'_2, \dots, \mathbf{x}'_n\}$ ,  $\mathbf{x}'_i \in \mathbf{R}^{N_{in}}$ 。且有  $\theta = (W_{(1)}, W_{(2)}, b_{(1)}, b_{(2)})$  为网络参数,  $W_{(1)} \in \mathbf{R}^{N_h \times N_{in}}$ 、 $W_{(2)} \in \mathbf{R}^{N_{in} \times N_h}$  分别为编码器和解码器的权值矩阵;  $b_{(1)} \in \mathbf{R}^{N_h}$ 、 $b_{(2)} \in \mathbf{R}^{N_{in}}$  分别为编码器和解码器的偏置向量。则隐藏层和输出层的输出表达式分别:

$$f_i = h_{(1)}(W_{(1)}\mathbf{x}_i + b_{(1)}) \quad (12)$$

$$\mathbf{x}'_i = h_{(2)}(W_{(2)}f_i + b_{(2)}) \quad (13)$$

式中:  $h_{(1)}$ 、 $h_{(2)}$  分别为编码器和解码器的传递函数,通常选择 S 型函数(Sigmoid)。

由于 AE 的训练目的是尝试将输入复制到输出,因此 AE 的学习过程可以描述为最小化一个损失函数  $E_{AE}$ ,以惩罚  $X$  与  $X'$  的差异。文中采用均方误差(mean squared error, MSE)作为损失函数(即 AE 的重构误差):

$$E_{AE} = \frac{1}{2n} \sum_{i=1}^n \| \mathbf{x}_i - \mathbf{x}'_i \|^2 \quad (14)$$

## 2.2 PQDs 深度特征提取

普通 AE 往往是欠完备的(隐藏层大小小于输入层),提取特征是通过限制隐藏层的大小强制提取,不能确保网络学习到有效的特征。为防止这种情况,文中使用 SAE,SAE 在更高维的空间上编码,并在反向传播输入中加入一个稀疏正则项,使得在同一时间只有部分隐藏的神经元是活跃的,以防止 AE 退化为复制器。在损失函数中加入 Kullback-Leibler 离散度作为稀疏正则项  $\Omega_{\text{sparsity}}$  :

$$\Omega_{\text{sparsity}} = \sum_{j=1}^{N_h} K_{\text{KL}}(\rho \| \rho'_j) = \sum_{j=1}^{N_h} \rho \ln\left(\frac{\rho}{\rho'_j}\right) + (1 - \rho) \ln\left(\frac{1 - \rho}{1 - \rho'_j}\right) \quad (15)$$

$$\rho'_j = \frac{1}{n} \sum_{i=1}^n f_{(1),j}(\mathbf{x}_i) = \frac{1}{n} \sum_{i=1}^n h_{(1)}(\mathbf{W}_{(1),j}^T \mathbf{x}_i + \mathbf{b}_{(1),j}) \quad (16)$$

式中:  $K_{\text{KL}}(\rho \| \rho'_j)$  为引入的 Kullback-Leibler 相对熵,  $\rho$  为期望的神经元平均激活值,称为稀疏比例参数,  $\rho'_j$  为隐藏层第  $j$  个神经元的平均激活值;  $f_{(1),j}(\mathbf{x}_i)$  为隐藏层第  $j$  个神经元在训练样本  $\mathbf{x}_i$  上的激活度;  $\mathbf{W}_{(1),j}$  为权值矩阵  $\mathbf{W}_{(1)}$  的第  $j$  行;  $\mathbf{b}_{(1),j}$  为偏置向量  $\mathbf{b}_{(1)}$  的第  $j$  项。  $\rho'_j$  与  $\rho$  相等时,  $\Omega_{\text{sparsity}}$  为 0;  $\rho'_j$  与  $\rho$  越偏离,  $\Omega_{\text{sparsity}}$  值越大。

此外,在训练 SAE 时,可能会出现为了降低稀疏正则项而使权值增大,并导致 SAE 过拟合的情况,在损失函数中增加一个权值正则项可避免这种情况。权值正则项  $\Omega_{\text{weights}}$  是各层权值矩阵的平方之和,称为 L2 正则项。

$$\Omega_{\text{weights}} = \frac{1}{2} \sum_{k=1}^2 \sum_{j=1}^{N_h} \sum_{m=1}^{N_{in}} (w_{(k),j,m})^2 \quad (17)$$

式中:  $w_{(k),j,m}$  为权值矩阵  $\mathbf{W}_{(k)}$  的第  $j$  行第  $m$  列元素。

引入稀疏正则项和 L2 正则项之后,SAE 的损失函数为:

$$E_{\text{SAE}} = E_{\text{AE}} + \lambda_1 \Omega_{\text{weights}} + \lambda_2 \Omega_{\text{sparsity}} \quad (18)$$

式中:  $\lambda_1$  为 L2 正则项的系数;  $\lambda_2$  为稀疏正则项的系数。

SSAE 为多个 SAE 级联,逐层提取特征,最终得到的特征更有深度、更具代表性,并且维度更小。SSAE 的训练过程是多个 SAE 按顺序训练,将第一个 SAE 的隐藏层输出作为第二个 SAE 的输入,并以此类推,最后得到 PQDs 的特征数据集  $F_M = \{\mathbf{f}_{M,1}, \mathbf{f}_{M,2}, \dots, \mathbf{f}_{M,n}\}$ ,其中  $M$  为 AE 个数(参见图 4,其中隐藏层节点的透明度与激活值相对应,  $N_{in,l}$ 、 $N_{h,l}$  分

别为编码器  $l$  的输入层和隐藏层神经元数,  $l = 1, 2, \dots, M$ )。相比于传统 PQDs 特征提取方法,SSAE 作为一种无监督的机器学习方法,无须依靠经验及人工,避免了选取的特征量不具普遍性的问题。

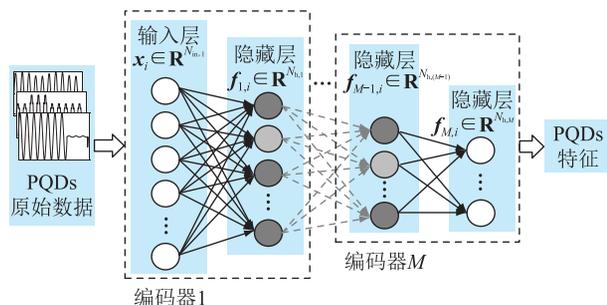


图 4 用于 PQDs 分类的 SSAE 结构

Fig.4 Structure of SSAE for PQDs classification

在 SSAE 网络中存在稀疏约束,因此希望在训练网络时可以减少部分参数的更新频率,即对不同的参数采用不同的学习率。但传统的梯度下降算法通常使用固定常数作为学习率,并沿性能函数梯度的负值方向调整参数。虽然函数沿着梯度的负值下降最快,但这并不一定会产生最快的收敛,且容易陷入局部最优。因此,为了训练出更好的网络,文中选择共轭梯度(conjugate gradient, CG)算法作为 SSAE-FFNN 的训练算法。

CG 算法每次迭代都会调整学习率,并沿着 CG 的方向执行搜索,通常收敛速度比最速下降法快。且 CG 算法不需要像牛顿法那样存储、求值和求逆海森矩阵,因此降低了每次迭代的计算成本。CG 算法具有相对适中的内存要求,在具有大量权值的神经网络中表现良好。利用 CG 算法训练神经网络的流程如下。

首先,设初始参数为  $\theta_0$ ,定义初始训练方向  $d_0$  为目标函数梯度  $g_0$  的负数,即  $d_0 = -g_0 = -\partial E / \partial \theta_0$ ,  $E$  为目标函数。然后,更新网络参数:

$$\theta_{t+1} = \theta_t + \alpha_t d_t \quad (19)$$

式中:  $\alpha_t$  为学习率,通过线性搜索得到。然后确定下一个搜索方向  $d_{t+1}$ ,使其与先前的搜索方向共轭:

$$d_{t+1} = g_{t+1} + \beta_t d_t \quad (20)$$

式中:  $\beta_t$  为共轭参数,是一个标量,在不同版本的 CG 算法中有所不同。

## 2.3 SSAE-FFNN 模型及训练算法

文中设计的 PQDs 分类模型由 SSAE 和 FFNN 2 种网络组成。FFNN 结构与 AE 相似,区别只在于各层的神经元数不同。SSAE 和 FFNN 组成的 PQDs 分类模型如图 5 所示。模型分为 3 个阶段:第一阶段为数据处理,将 PQDs 波形处理为高维矩阵;第二

阶段是基于SSAE的特征提取,将高维的PQDs数据转化为低维的深度特征矩阵;第三阶段是基于FFNN的扰动分类,输出PQDs的预测标签作为分类结果。

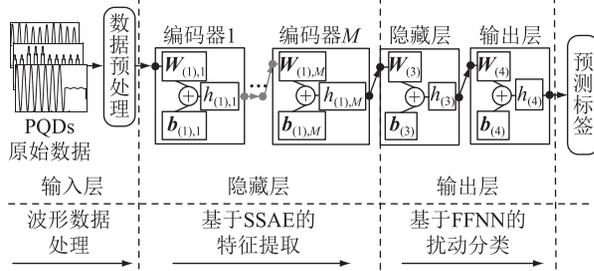


图5 基于SSAE-FFNN的PQDs分类模型

Fig.5 Classification model for PQDs based on SSAE-FFNN

利用SSAE提取PQDs特征,并通过FFNN实现扰动分类。SSAE-FFNN的分类流程如图6所示。

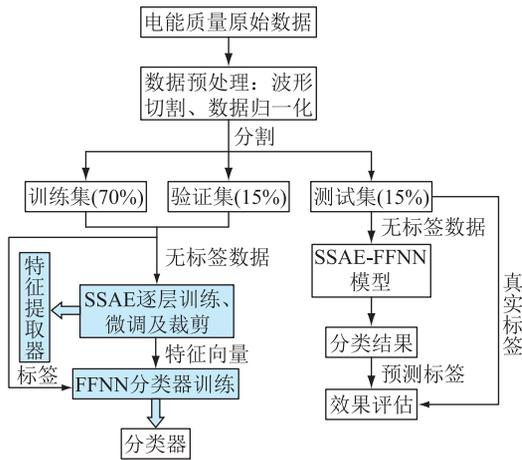
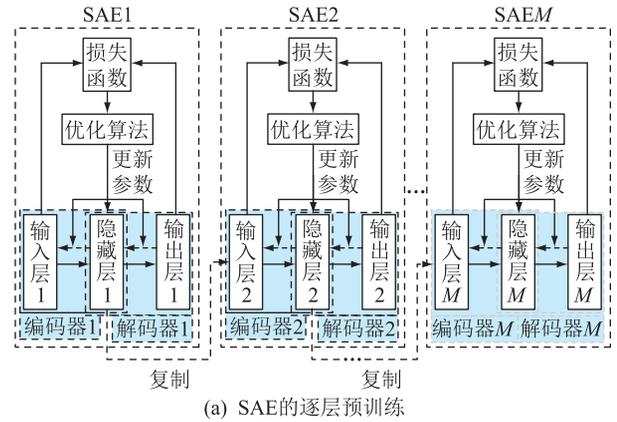


图6 SSAE-FFNN分类流程

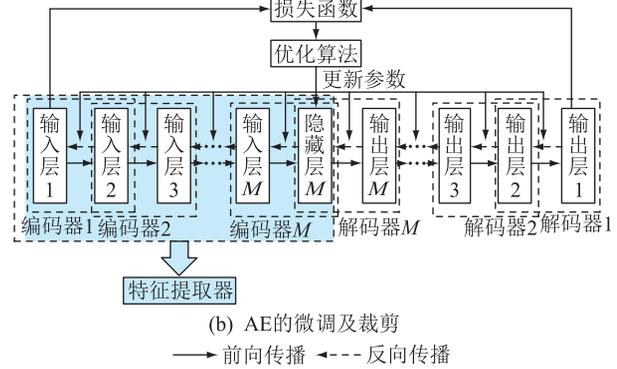
Fig.6 Flow chart of SSAE-FFNN based classification

为了实现PQDs特征的自动提取,同时能够完成大规模系统中的特征提取任务,文中对SSAE进行逐层预训练、微调及裁剪操作,流程如图7所示。在特征提取阶段,采用贪婪分层方法逐层预训练SAE,如图7(a)所示。首先,将无标签的原始PQDs数据输入SAE1,通过编码器将其编码至隐藏层,再通过解码器将隐藏层数据重构为PQDs数据。整个训练过程通过缩放共轭梯度(scaled conjugate gradient, SCG)算法优化编码器的参数以最小化损失 $E_{SAE}$ ,最终得到训练好的SAE1。将SAE1的隐藏层输出作为SAE2的输入,并继续训练SAE2。以此类推,逐层训练SAE。

由于采用贪婪分层方法训练,每个SAE只优化了一层隐藏层,因此每个SAE的参数只是局部最优。逐层预训练后,将多层SAE堆叠起来,如图7



(a) SAE的逐层预训练



(b) AE的微调及裁剪

图7 SSAE预训练、微调及裁剪

Fig.7 Pre-training, fine tuning and tailoring of SSAE

(b)所示,以逐层训练后的网络参数为堆叠网络的初始值。将多层SAE作为一个整体进行微调,微调过程的损失函数为:

$$E_{SSAE} = E_{AE} + \lambda_1 \sum_{l=1}^M \Omega_{weights, (l)} + \lambda_2 \sum_{l=1}^M \Omega_{sparsity, (l)} \quad (21)$$

式中:  $\Omega_{weights, (l)}$ 、 $\Omega_{sparsity, (l)}$  分别为编码器 $l$ 的权值正则项和稀疏正则项。

微调后,对各层SAE进行裁剪,即省去SAE的解码器,保留各层SAE的编码器及最后一层SAE的隐藏层。最终实现PQDs的自动提取,输入PQDs无标签数据,输出PQDs低维特征数据集。

在分类阶段,利用上一步得到的PQDs特征和原始PQDs的标签训练FFNN,训练过程中采用SCG反向传播算法调整网络的权值和阈值,使输出端的预测标签结果逐渐接近真实标签。最后,将SSAE与FFNN堆叠成一个整体网络,并对其进行有监督的微调,得到基于SSAE-FFNN的PQDs分类模型。

## 2.4 模型性能评估指标

SSAE-FFNN模型最终目的是实现PQDs分类识别,因此使用基于混淆矩阵的指标来评价其分类效果。评价指标有分类准确率(accuracy, ACC)  $r_{ACC}$ , 宏精确率(macro-average precision, macroP)  $r_{macroP}$ ,

宏召回率 (macro-average recall, macroR)  $r_{\text{macroR}}$ 。记扰动种类数为  $K$ , 各类扰动的集合分别记为  $C_1, C_2, \dots, C_K$ , 则可计算各项指标如下:

$$r_{\text{ACC}} = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{TN}} + N_{\text{FP}} + N_{\text{FN}}} \quad (22)$$

$$r_{\text{macroP}} = \frac{1}{K} \sum_{k=1}^K \frac{N_{\text{TP}, C_k}}{N_{\text{TP}, C_k} + N_{\text{FP}, C_k}} \quad (23)$$

$$r_{\text{macroR}} = \frac{1}{K} \sum_{k=1}^K \frac{N_{\text{TP}, C_k}}{N_{\text{TP}, C_k} + N_{\text{FN}, C_k}} \quad (24)$$

式中:  $N_{\text{FP}}, N_{\text{FN}}, N_{\text{TP}}, N_{\text{TN}}$  分别为数据集中假阳性、假阴性、真阳性和真阴性样本个数;  $N_{\text{FP}, C_k}, N_{\text{FN}, C_k}, N_{\text{TP}, C_k}$  为属于扰动集合  $C_k$  的各类样本个数。

对于 PQDs 分类问题, 宏精确率和宏召回率同样重要, 引入宏 F1 (macro-average F1 score, macroF1)  $r_{\text{macroF1}}$  同时考察这 2 个指标。macroF1 越高, 表明 macroP 和 macroR 两指标都很高的同时两者也能取得平衡。

$$r_{\text{macroF1}} = \frac{2r_{\text{macroP}}r_{\text{macroR}}}{r_{\text{macroP}} + r_{\text{macroR}}} \quad (25)$$

为定性评估 SSAE 的特征提取性能, 使用评估因子  $S_{\text{SS}}^{[31]}$  进行类别可分性测度:

$$S_{\text{SS}} = S_b / S_w \quad (26)$$

$$S_b = \sum_{k=1}^K N_k \|\boldsymbol{\mu}_{f,k} - \bar{\boldsymbol{\mu}}_f\|^2 \quad (27)$$

$$S_w = \sum_{k=1}^K \sum_{f \in C_k} \|\boldsymbol{f} - \boldsymbol{\mu}_{f,k}\|^2 \quad (28)$$

式中:  $S_b$  为类间距离;  $S_w$  为类内距离;  $\boldsymbol{f} = (f_1, f_2, \dots, f_{N_h})$  为特征向量;  $\boldsymbol{\mu}_{f,k}$  为第  $k$  类扰动的平均特征向量;  $\bar{\boldsymbol{\mu}}_f = \frac{1}{K} \sum_{k=1}^K \boldsymbol{\mu}_{f,k}$  为所有类别的总平均特征向量;  $N_k$  为第  $k$  类扰动的样本数。

### 3 算例分析

#### 3.1 PQDs 数据集

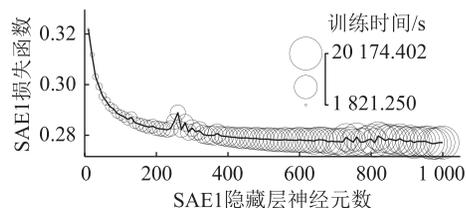
文中参考 PQDs 模型, 在 MATLAB 中生成文中所需的 PQDs 数据。通过随机改变模型中  $\alpha, \beta, t, \tau$  等参数的数值获取多组不同 PQDs 数据。文中扰动信号的额定频率  $f$  为 50 Hz, 额定角频率为  $\omega = 2\pi f$ , 采样频率  $f_s$  为 12.8 kHz。每种扰动信号的采样周期为 10 周期, 每个周期采样 256 个点, 即每种扰动信号采样 2 560 个点。15 种扰动, 每种扰动信号分别生成 1 000 组数据, 总样本规模为 15 000 组。将这些数据随机打乱作为输入数据集, 其中, 70% 的数据作为训练集, 15% 作为验证集, 15% 作为测试集。训练集用于训练模型; 验证集用于微调模型, 调整模

型参数并防止模型过拟合; 测试集用于测试模型分类效果及泛化能力。

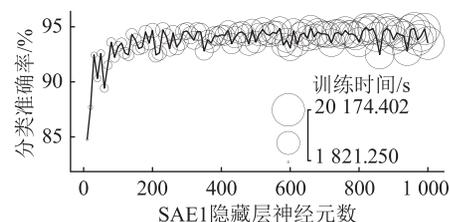
#### 3.2 PQDs 特征提取

##### 3.2.1 SSAE 逐层预训练

SSAE 采用贪婪分层训练, 各层 SAE 的网络结构单独确定。通过实验得到 SAE1 网络在验证集上训练过程, 如图 8 所示 ( $\rho$  设置为 0.6)。由图 8(a) 可知, SAE1 的损失函数随隐藏层神经元数的增加而减小, 隐藏层神经元数高于 400 后, 损失函数几乎不变。图 8(b) 展示了 SAE1 提取特征的分类效果, 为控制变量, 采用相同参数的 Softmax 分类器接在各 SAE1 后。由结果可知, 隐藏层神经元数高于 100 后, 分类准确率基本不再增加且产生波动。此外, 随着隐藏层神经元数的增加, 模型训练时间也逐渐增大。因此, SAE1 的神经元数选择范围为 100~400 (文中选择 100)。



(a) SAE1 隐藏层神经元数与损失函数及训练时间的关系



(b) SAE1 隐藏层神经元数与分类准确率及训练时间的关系

图 8 SAE1 训练过程

Fig.8 Training process of SAE1

SAE 通过稀疏比例参数  $\rho$  来控制隐藏层神经元的平均激活值。通过实验得到 SAE1 稀疏比例参数与损失函数、重构误差的关系, 如图 9 所示。可知,  $\rho$  在 0.4~0.6 范围内, 损失函数与重构误差不再减小且几乎没有波动。因此,  $\rho$  可设置为 0.4~0.6 (文中选择 0.6)。确定 SAE1 的结构之后, 训练第二个 SAE, 得到 SAE2 隐藏层神经元数与损失函数的关系, 如图 10 所示。综合考虑损失函数及训练时间, 选择 SAE2 的隐藏层神经元数为 50。

##### 3.2.2 SSAE 网络结构

SSAE 的网络结构没有固定的确定方法, 图 11 展示了不同网络结构的 SSAE 对分类效果的影响。为控制变量, 将不同结构的 SSAE 与同一个 Softmax 分类器连接, 且其他参数保持一致。由图 11 可知, 采用 2 个 SAE 能够达到最好的分类效果, 当 SAE 大

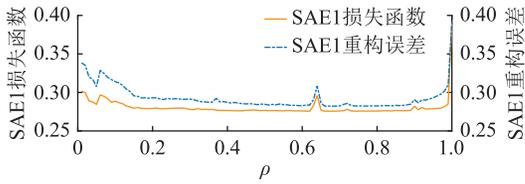


图 9 SAE1 稀疏比例参数与损失函数及重构误差的关系  
Fig.9 Relationship between sparsity proportion and loss function, reconstruction error of SAE1

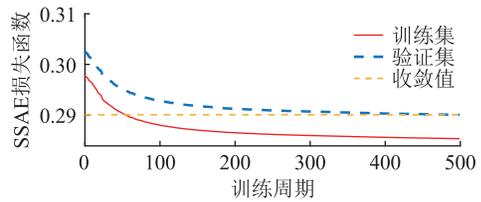


图 12 SSAE 微调损失函数与训练周期的关系  
Fig.12 Relationship between loss function and epochs of SSAE fine-tuning

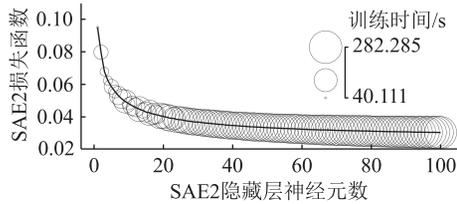


图 10 SAE2 隐藏层神经元数与损失函数及训练时间关系  
Fig.10 Relationship between hidden\_size and loss function, training time of SAE2

于 2 个时,分类精度会产生波动,且模型训练时间会大大增加。故选择 2 层 SAE 组成的 SSAE 用于提取特征。

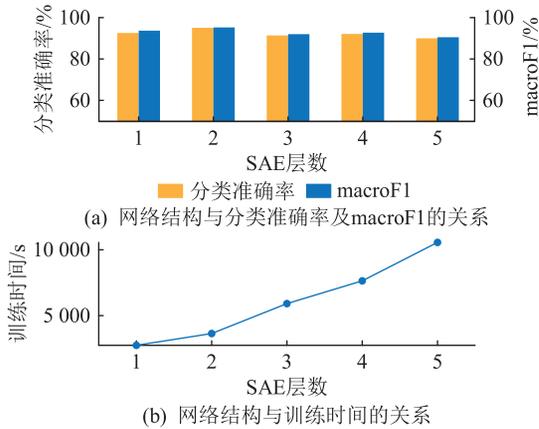


图 11 SSAE 网络结构与分类效果的关系  
Fig.11 Relationship between SSAE network structure and classification effect

### 3.2.3 SSAE 无监督微调与裁剪

在 SAE 预训练后对 SSAE 网络进行微调,其误差与训练周期的关系如图 12 所示。在训练过程中,验证集与训练集损失同步降低,故模型没有过拟合。经过微调,训练集的重构误差由 0.297 8 降至 0.285 3,验证集的重构误差由 0.302 3 降至 0.290 0,由此可见 SSAE 无监督微调方法有效降低了堆叠网络的整体重构损失,提高了混合扰动特征提取的有效性。微调结束后,对堆叠网络进行裁剪,将编码器部分提取出,构成各层网络的神经元数分别为 2 560、100、50 的 PQDs 特征提取网络。

为验证 PQDs 特征提取效果,文中随机选择 9 种 PQDs,分别采用上述 SSAE 和主成分分析

(principal component analysis, PCA)将原始数据降至二维,结果如图 13 所示。可知,相较于 PCA 算法,SSAE 所提取的特征基本都按类别分开,具有更好的特征提取效果。

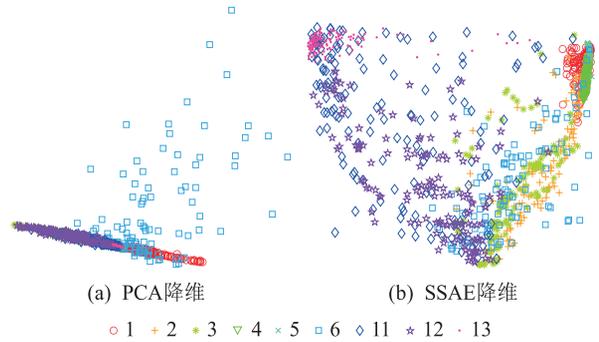


图 13 SSAE 和 PCA 特征降维

Fig.13 Feature dimensionality reduction of SSAE and PCA

不同特征提取算法的对比如图 14 所示,其中 ICA 为独立成分分析。图中 SSAE 的评估因子最大,说明使用 SSAE 提取的特征其类别可分性最好。综上所述,文中基于 SSAE 的特征提取策略能有效提取 PQDs 深度特征。

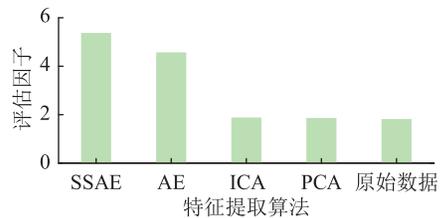


图 14 不同特征提取算法对比

Fig.14 Comparison of different feature extraction algorithms

### 3.3 PQDs 分类

将所提取的 50 维 PQDs 特征及原始扰动标签数据作为 FFNN 的输入数据,并采用 SCG 算法优化训练。图 15 为 FFNN 隐藏层神经元数与分类准确率的关系,可知,神经元数为 50 时分类效果最佳。故设置 FFNN 的隐藏层神经元数为 50。

综上所述,得到 SSAE-FFNN 模型的结构及参数如表 2 所示。

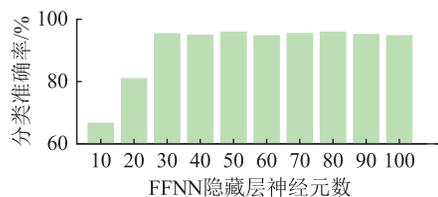


图 15 FFNN 隐藏层神经元数与分类准确率的关系

Fig.15 Relationship between hidden\_size of FFNN and classification accuracy

表 2 模型结构及参数

Table 2 Model structure and parameters

算法	参数	取值
SSAE-FFNN	输入层神经元数	2 560
	第一层隐藏层神经元数	100
	第二层隐藏层神经元数	50
	第三层隐藏层神经元数	50
	输出层神经元数	15
	$\rho$	0.6
	$\lambda_1$	0.004
SCG	$\lambda_2$	4
	Sigma	$5 \times 10^{-5}$
	Lamba	$5 \times 10^{-5}$

为验证 SSAE-FFNN 模型分类效果及泛化性,将测试集输入训练好的模型中,得到分类混淆矩阵,如图 16 所示。可知,分类准确率为 96.04%,宏精确率为 96.69%,宏召回率为 96.04%,macroF1 为 96.37%。

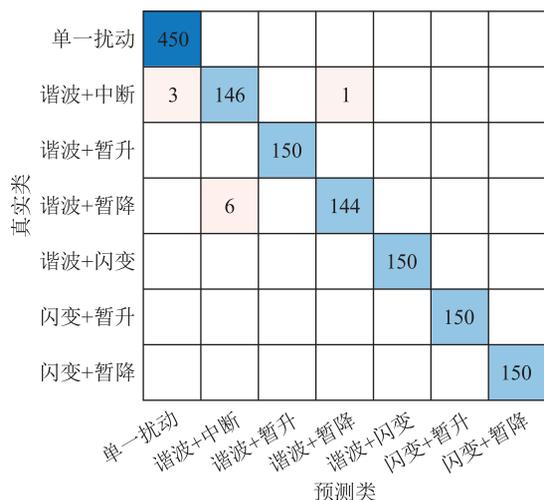


图 16 分类结果的混淆矩阵

Fig.16 Confusion chart of classification results

### 3.4 模型性能分析

#### 3.4.1 鲁棒性验证

(1) 考虑基波频率波动的分类效果。在实际中,电网的基波频率总是在一定范围内波动,会导致非同步采样,并造成测量误差。为此,在无粗差、信噪比 50 dB、采样频率 12.8 kHz 的基础上,采用文

中方法进行分析,得到不同基频下的分类效果,如图 17 所示。可知,在不同的基频下,文中方法均能取得较高的分类精度,即基频波动对分类效果的影响较小。

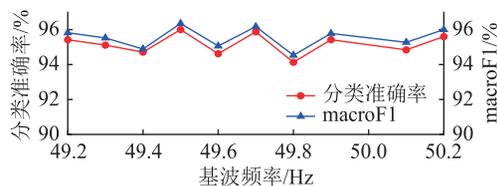


图 17 考虑基波频率波动的分类效果

Fig.17 The classification effects considering fundamental frequency fluctuation

(2) 考虑测量噪声的分类效果。在实际中,监测设备受干扰会使测量信号掺杂噪声,影响测量数据精度。为此,在无粗差、基频 50 Hz、采样频率 12.8 kHz 的基础上,在采样数据中加入白噪声模拟含噪声的扰动信号,用上述训练好的模型进行分析,得到考虑测量噪声的分类效果,如表 3 所示。可知,PQDs 信号含噪声越少,分类精度越高,虽然噪声误差对分类效果有一定影响,但在不同等级的信噪比下,文中模型均有较好的分类效果。

表 3 考虑测量噪声的分类效果

Table 3 The classification effects considering measurement noise

信噪比/dB	分类准确率/%	macroF1/%
30	94.31	94.73
40	95.33	95.68
50	96.31	96.53
60	95.16	95.49

(3) 考虑测量粗差的分类效果。在实际中,由于测量过程中外界条件突变、设备缺陷及人为疏忽等因素的影响,会使测量数据中含有粗差。因此,在基频 50 Hz、信噪比 40 dB、采样频率 12.8 kHz 的基础上,加入大小为扰动信号幅值的 3%~10% 的粗差,用上述训练好的模型分析,得到考虑粗差的分类效果,如图 18 所示。分类精度随着粗差含有率的增加而降低,但在各含量的粗差下,文中模型均能取得较高的分类精度。

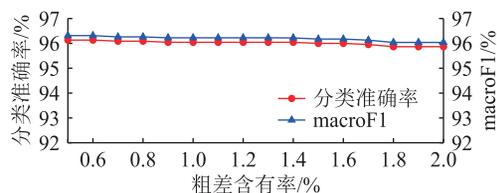


图 18 考虑测量粗差的分类效果

Fig.18 The classification effects considering gross error

(4) 考虑场景规模的分类效果。为验证文中所提方法的适用场景规模,分别考虑样本数和采样频率对分类效果的影响。不同样本数下的分类结果如图 19 所示。可知,分类精度总体上随着样本数的增加而提高,同时训练和测试时间随样本数增加而升高,单一扰动样本数低于 100 时分类精度低(90%),当样本数达到 500 及以上时分类精度可超过 95%,测试时间在 0.05 s 左右,达到一般场景的应用要求。因此,在忽略训练时间的情况下,文中所提方法适用于样本数较多的场景,能用于大规模电力系统的 PQDs 分类识别。

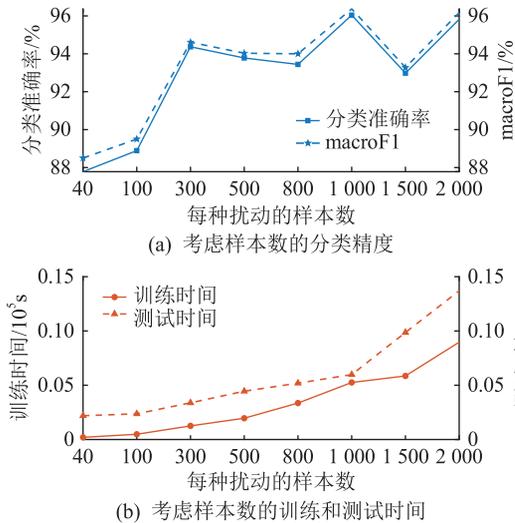


Fig.19 The classification effects considering sample size

不同采样频率下的分类结果如图 20 所示。可知,在不同采样频率下,文中所提方法均能取得较好的分类效果,同时训练和测试时间随采样频率的增加而增加。总体上,文中方法适用于较宽范围的采样频率。

(5) 考虑多扰动的分类效果。为验证文中方法对于更复杂的三重及以上复合扰动的识别能力,对谐波+暂升+闪变(样本标签为 16)、谐波+暂降+闪变(样本标签为 17)这 2 种三重扰动进行分类识别测试。结果发现,2 种三重扰动的分类精度均达到 100%。总样本集(17 种扰动)的  $r_{ACC}$  为 96.75%,  $r_{macroP}$  为 97.27%,  $r_{macroR}$  为 95.75%,  $r_{macroF1}$  为 97.01%。因此文中方法对三重及以上的扰动同样具有良好的分类效果。

### 3.4.2 实测数据验证

为进一步验证文中方法在实际电力系统中的适用性,采用华东某地市电网提供的 21 组实测暂降/暂升录波数据进行验证,录波系统的采样频率为 12.8 kHz,其中 4 组波形如图 21 所示。

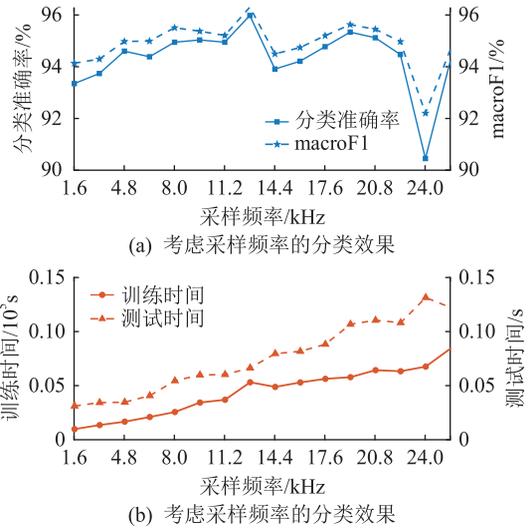


图 20 考虑采样频率的分类效果

Fig.20 The classification effects considering frequency of sample

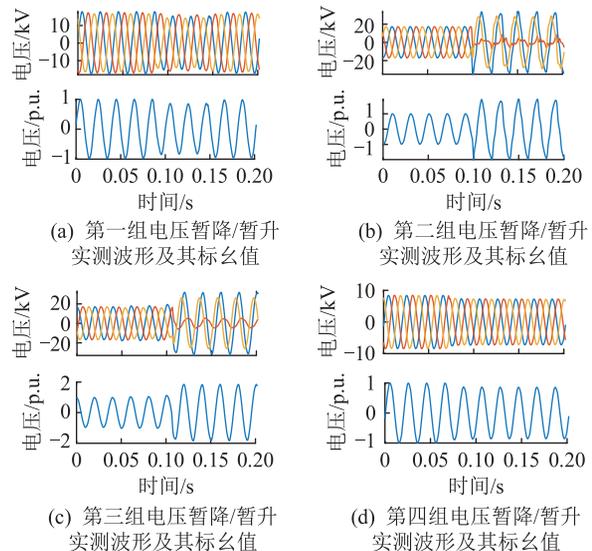


图 21 电压暂降/暂升实测波形及其标么值

Fig.21 Voltage sag and voltage swell measured waveform and its standard value

为有效识别实测波形,将实际数据进行标准化处理(即采用标么值形式表示),并进行波形分割,使其与训练模型匹配。实测数据分类识别结果如表 4 所示,分类准确率为 90.48%。其中 8 号、9 号样本为误判,主要原因是这 2 个样本的暂降深度与中断比较接近,且持续时间较训练模型偏大。总体看,文中方法在实际的电能质量应用中具有较好的适用性。

### 3.4.3 不同算法的对比

以分类准确率、macroF1 及测试时间为指标,比较文中所提 SSAE-FFNN 方法与其他 PQDs 常用特征提取及分类算法的效果,结果如表 5 所示。结果表明,相比于使用原始数据和 S 变换,文中基于

SSAE 的特征提取方法所提取的特征具有更好的分类效果。同时,文中所提 SSAE-FFNN 方法的分类精度及泛化能力也优于 SVM 和决策树。

表 4 实测数据分类结果

Table 4 Classification results of measured data

样本序号	实际扰动类别	模型分类结果	样本序号	实际扰动类别	模型分类结果
1	电压暂升	电压暂升	12	电压暂降	电压暂降
2	电压暂降	电压暂降	13	电压暂降	电压暂降
3	电压暂升	电压暂升	14	电压暂降	电压暂降
4	电压暂升	电压暂升	15	电压暂降	电压暂降
5	电压暂升	电压暂升	16	电压暂降	电压暂降
6	电压暂降	电压暂降	17	电压暂降	电压暂降
7	电压暂降	电压暂降	18	电压暂降	电压暂降
8	电压暂降	电压中断	19	电压暂降	电压暂降
9	电压暂降	电压中断	20	电压暂升	电压暂升
10	电压暂降	电压暂降	21	电压暂降	电压暂降
11	电压暂降	电压暂降			

表 5 不同算法结果对比

Table 5 Comparison of different algorithms

方案	$r_{ACC}/\%$	$r_{macroF1}/\%$	测试时间/s
原始数据+FFNN	87.20	87.73	0.025 7
S 变换+FFNN	89.63	89.84	0.061 0
SSAE+SVM	91.38	91.57	0.086 2
SSAE+DT	90.67	90.77	0.000 9
SSAE+FFNN	96.04	96.37	0.059 8

#### 4 结语

文中提出一种基于 SSAE-FFNN 的 PQDs 分类方法,并采用 SCG 优化网络,从而提高了网络训练效率。通过 SSAE 网络的逐层训练及无监督微调降低堆叠网络的整体重构损失,提高所提取特征的有效性,从而实现 PQDs 深度特征的自动提取。仿真结果表明,文中所提的 PQDs 分类识别方法具有较高的分类精度和泛化能力,实现了 PQDs 自动特征提取和大规模系统 PQDs 分类,对于含误差数据也具有一定的识别能力,适用场景规模广泛,实测数据验证也表明文中方法具有较好的应用前景。

#### 致 谢

本文得到江苏省高等学校自然科学研究重大项目“含高渗透率分布电源配电网电压暂降鲁棒状态估计及应用”(19KJA510012),江苏省南京工程学院校基金(YKJ202209)资助,谨此致谢!

#### 参考文献:

[1] 周孝信,陈树勇,鲁宗相,等. 能源转型中我国新一代电力系统的技术特征[J]. 中国电机工程学报,2018,38(7):1893-

1904,2205.  
 ZHOU Xiaoxin, CHEN Shuyong, LU Zongxiang, et al. Technology features of the new generation power system in China[J]. Proceedings of the CSEE, 2018, 38(7):1893-1904, 2205.  
 [2] 任大伟,肖晋宇,侯金鸣,等. 双碳目标下我国新型电力系统的构建与演变研究[J]. 电网技术,2022,46(10):3831-3839.  
 REN Dawei, XIAO Jinyu, HOU Jinming, et al. Construction and evolution of China's new power system under dual carbon goal[J]. Power System Technology, 2022, 46(10):3831-3839.  
 [3] 董旭柱,华祝虎,尚磊,等. 新型配电系统形态特征与技术展望[J]. 高电压技术,2021,47(9):3021-3035.  
 DONG Xuzhu, HUA Zhuhu, SHANG Lei, et al. Morphological characteristics and technology prospect of new distribution system[J]. High Voltage Engineering, 2021, 47(9):3021-3035.  
 [4] 汪飞,全晓庆,任林涛. 电能质量扰动检测与识别方法研究综述[J]. 中国电机工程学报,2021,41(12):4104-4121.  
 WANG Fei, QUAN Xiaoqing, REN Lintao. Review of power quality disturbance detection and identification methods[J]. Proceedings of the CSEE, 2021, 41(12):4104-4121.  
 [5] 刘水,钟振鑫,陈鸣,等. 基于改进的经验傅里叶分解电能质量扰动检测方法[J]. 现代电力,2023,40(4):465-473.  
 LIU Shui, ZHONG Zhenxin, CHEN Ming, et al. Detection method of power quality disturbance based on improved EFD[J]. Modern Electric Power, 2023, 40(4):465-473.  
 [6] 黄传金,周铜. 基于变分模态分解的电能质量扰动检测新方法[J]. 电力自动化设备,2018,38(3):116-123.  
 HUANG Chuanjin, ZHOU Tong. A new detection method of power quality disturbance based on VMD[J]. Electric Power Automation Equipment, 2018, 38(3):116-123.  
 [7] 窦嘉铭,马鸿雁. 基于复调制细化和 Adaline 网络的谐波检测方法[J]. 中国测试,2022,48(5):43-50.  
 DOU Jiaming, MA Hongyan. Harmonic detection method based on complex modulation refinement and adaptive linear network[J]. China Measurement & Test, 2022, 48(5):43-50.  
 [8] 吴建章,梅飞,郑建勇,等. 基于改进经验小波变换和 XGBoost 的电能质量复合扰动分类[J]. 电工技术学报,2022,37(1):232-243,253.  
 WU Jianzhang, MEI Fei, ZHENG Jianyong, et al. Recognition of multiple power quality disturbances based on modified empirical wavelet transform and XGBoost[J]. Transactions of China Electrotechnical Society, 2022, 37(1):232-243, 253.  
 [9] 袁莉芬,张成林,尹柏强,等. 基于最优 Bohman 窗的改进 S 变换电能质量扰动特征精确快速提取方法[J]. 电子与信息学报,2022,44(11):3796-3805.  
 YUAN Lifan, ZHANG Chenglin, YIN Baiqiang, et al. Accurate and fast feature extraction method of power quality disturbances based on modified S-transform of optimal Bohman window[J]. Journal of Electronics & Information Technology, 2022, 44(11):3796-3805.  
 [10] 吴建章,梅飞,潘益,等. 基于改进经验小波变换的电能质量扰动检测新方法[J]. 电力自动化设备,2020,40(6):142-151.

- WU Jianzhang, MEI Fei, PAN Yi, et al. Novel detection method of power quality disturbance based on IEWT[J]. *Electric Power Automation Equipment*, 2020, 40(6):142-151.
- [11] BHUIYAN S M A, KHAN J, MURPHY G. WPD for detecting disturbances in presence of noise in smart grid for PQ monitoring[J]. *IEEE Transactions on Industry Applications*, 2018, 54(1):702-711.
- [12] 马杰, 孙宁, 任志强, 等. 基于多特征组合的电能质量扰动识别方法[J]. *电力电容器与无功补偿*, 2019, 40(2):125-130.
- MA Jie, SUN Ning, REN Zhiqiang, et al. Disturbance identification method on power quality based on multi-feature combination[J]. *Power Capacitor & Reactive Power Compensation*, 2019, 40(2):125-130.
- [13] TIWARI V K, UMARIKAR A C, JAIN T. Fast amplitude estimation of harmonics using undecimated wavelet packet transform and its hardware implementation[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67(1):65-77.
- [14] 叶筱怡, 刘海涛, 吕干云, 等. 基于 BAS-BP 分类器模型的电压暂降源识别[J]. *电力工程技术*, 2022, 41(1):77-83.
- YE Xiaoyi, LIU Haitao, LYU Ganyun, et al. Identification of voltage sag source based on BAS-BP classifier model[J]. *Electric Power Engineering Technology*, 2022, 41(1):77-83.
- [15] 王鹏飞, 任丽佳, 高燕. 基于不完全 S 变换和改进 SVM 的电能质量分类方法[J]. *制造业自动化*, 2023, 45(1):115-119.
- WANG Pengfei, REN Lijia, GAO Yan. Power quality classification method based on incomplete S transform and improved SVM[J]. *Manufacturing Automation*, 2023, 45(1):115-119.
- [16] 伊慧娟, 高云鹏, 朱彦卿, 等. 基于自适应不完全 S 变换与 LOO-KELM 算法的复合电能质量扰动识别[J]. *电力自动化设备*, 2022, 42(1):199-205.
- YI Huijuan, GAO Yunpeng, ZHU Yanqing, et al. Recognition of composite power quality disturbance based on improved incomplete S transform and LOO-KELM algorithm[J]. *Electric Power Automation Equipment*, 2022, 42(1):199-205.
- [17] 徐佳雄, 张明, 王阳, 等. 基于改进 Hilbert-Huang 变换的电能质量扰动定位与分类[J]. *现代电力*, 2021, 38(4):362-369.
- XU Jiexiong, ZHANG Ming, WANG Yang, et al. Location and classification of power quality disturbances based on improved Hilbert-Huang transform[J]. *Modern Electric Power*, 2021, 38(4):362-369.
- [18] 罗雪莲, 刘桂英, 刘香银. 基于小波变换与希尔伯特-黄变换的微电网暂态电能质量扰动检测及辨识研究[J]. *电力电容器与无功补偿*, 2020, 41(3):182-188.
- LUO Xuelian, LIU Guiying, LIU Xiangyin. Study on detection and identification of transient power quality disturbances of microgrid based on wavelet transform and Hilbert-Huang transform[J]. *Power Capacitor & Reactive Power Compensation*, 2020, 41(3):182-188.
- [19] 李新, 武利会, 范心明, 等. 基于希尔伯特黄变换和决策树的电压暂降源识别方法[J]. *科学技术与工程*, 2019, 19(34):198-205.
- LI Xin, WU Lihui, FAN Xinming, et al. Voltage sag sources identification method based on Hilbert-Huang transform and decision tree[J]. *Science Technology and Engineering*, 2019, 19(34):198-205.
- [20] 陈向群, 杨茂涛, 刘谋海, 等. 基于模糊聚类分析的电能质量扰动模式识别方法[J]. *电力科学与技术学报*, 2022, 37(2):79-85.
- CHEN Xiangqun, YANG Maotao, LIU Mouhai, et al. Disturbance pattern recognition method of power quality based on the fuzzy clustering analysis[J]. *Journal of Electric Power Science and Technology*, 2022, 37(2):79-85.
- [21] 李祖明, 吕干云, 陈诺, 等. 基于混沌集成决策树的电能质量复合扰动识别[J]. *电力系统保护与控制*, 2021, 49(21):18-27.
- LI Zuming, LÜ Ganyun, CHEN Nuo, et al. Recognition of hybrid PQ disturbances based on a chaos ensemble decision tree[J]. *Power System Protection and Control*, 2021, 49(21):18-27.
- [22] MAHELA O P, SHARMA U K, MANGLANI T. Recognition of power quality disturbances using discrete wavelet transform and fuzzy C-means clustering[C]//2018 IEEE 8th Power India International Conference (PIICON). Kurukshetra, India. IEEE, 2018:1-6.
- [23] 张明龙, 张振宇, 罗翔, 等. 基于多核支持向量机的混合扰动波形辨识算法研究[J]. *电力系统保护与控制*, 2022, 50(15):43-49.
- ZHANG Minglong, ZHANG Zhenyu, LUO Xiang, et al. Complex disturbance waveform recognition based on a multi-kernel support vector machine[J]. *Power System Protection and Control*, 2022, 50(15):43-49.
- [24] 陈晓华, 王志平, 吴杰康, 等. 基于 IHHO-SVM 的电能质量扰动信号识别方法[J]. *浙江电力*, 2023, 42(8):115-124.
- CHEN Xiaohua, WANG Zhiping, WU Jiekang, et al. Identification method for disturbance signal of power quality based on improve Harris Hawks optimization-support vector machine[J]. *Zhejiang Electric Power*, 2023, 42(8):115-124.
- [25] 王磊, 张磊, 牛荣泽, 等. 基于 CNN+D-S 证据理论的多维信息源局部放电故障识别[J]. *电力工程技术*, 2022, 41(5):172-179.
- WANG Lei, ZHANG Lei, NIU Rongze, et al. Partial discharge fault identification of multi-dimensional information sources based on CNN+D-S evidence theory[J]. *Electric Power Engineering Technology*, 2022, 41(5):172-179.
- [26] 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, QIN Risheng, et al. Power quality disturbance identification method based on deep convolutional denoising network[J]. *Southern Power System Technology*, 2022, 16(12):118-125.
- [27] 陈伟, 何家欢, 裴喜平. 深度信念网络在电能质量复合扰动

识别中的应用[J]. 电力系统及其自动化学报, 2018, 30(9):75-82.

CHEN Wei, HE Jiahuan, PEI Xiping. Application of deep belief network in power quality compound disturbance identification[J]. Proceedings of the CSU-EPSSA, 2018, 30(9):75-82.

[28] 贺才郡, 李开成, 杨王旺, 等. 基于双通道 GAF 和深度残差网络的电能质量复合扰动识别[J]. 电网技术, 2023, 47(1):369-379.

HE Caijun, LI Kaicheng, YANG Wangwang, et al. Power quality compound disturbance identification based on dual channel GAF and depth residual network[J]. Power System Technology, 2023, 47(1):369-379.

[29] IEEE recommended practice for monitoring electric power quality: IEEE 1159-2019[S]. 2019.

[30] 王伟. 基于深度学习的电能质量复合扰动分类研究[D]. 武汉:华中科技大学, 2021.

WANG Wei. Study on recognition of complex power quality

disturbances based on deep learning[D]. Wuhan: Huazhong University of Science and Technology, 2021.

[31] 胡旭峰. 基于无监督学习的故障诊断算法研究[D]. 济南: 山东大学, 2022.

HU Xufeng. Research on fault diagnosis algorithm based on unsupervised learning[D]. Jinan: Shandong University, 2022.

作者简介:



丁皓月

丁皓月(1998),女,硕士在读,研究方向为电能质量分析和控制(E-mail: 2690916807@qq.com);

吕干云(1976),男,博士,教授,研究方向为电能质量分析和控制、综合能源建模与优化、人工智能技术在电力系统中的应用;

史明明(1986),男,博士,高级工程师,从事新能源与分布式发电相关工作。

## Power quality composite disturbance deep feature extraction and classification based on SCG optimized SSAE-FFNN

DING Haoyue<sup>1</sup>, LYU Ganyun<sup>1</sup>, SHI Mingming<sup>2</sup>, FEI Juntao<sup>2</sup>, YU Ming<sup>3</sup>, WU Qiyu<sup>3</sup>

(1. School of Electric Power Engineering, Nanjing Institute of Technology, Nanjing 211167, China;

2. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China;

3. State Grid Nanjing Lishui Power Supply Company of Jiangsu Electric Power Co., Ltd., Nanjing 211200, China)

**Abstract:** With the development of the smart grid, power quality issues have been widespread in the power grid and it threaten the safety and stability of the power grid. The monitoring data of power quality disturbances (PQDs) increase rapidly, and it is of great significance to achieve deep feature extraction and intelligent classification of PQDs in large-scale systems for power system pollution detection and management. To this end, stacked sparse auto encoder (SSAE) and feedforward neural network (FFNN) based method for composite PQDs classification is proposed in this paper. Firstly, a PQDs simulation model is constructed based on IEEE standard. Then, a PQDs classification model based on SSAE-FFNN is established, and the scaled conjugate gradient (SCG) algorithm is used to optimize the model, in order to accelerate gradient descent and improve training efficiency. Next, to reduce the reconstruction loss of the stacked network and extract deep low-dimensional features, the layer-wise training and fine-tuning strategy of SSAE are constructed. Finally, the examples are used to verify the classification effect, robustness, generalization and applicable scenario scale of the proposed method. The results show that the method can effectively identify composite PQDs and it has a high accuracy even for both error-containing disturbances and 21 sets of measured disturbance data of a local municipal grid.

**Keywords:** power quality; composite disturbance classification; stacked sparse auto encoder (SSAE); deep feature extraction; scaled conjugate gradient (SCG); feedforward neural network (FFNN)

(编辑 方晶)