

基于稀疏自动编码器深度神经网络的电能质量扰动分类方法

屈相帅^{1,2}, 段 斌^{1,2}, 尹桥宣^{1,2}, 晏寅鑫², 钟 颖²

(1. 湘潭大学 智能计算与信息处理教育部重点实验室, 湖南 湘潭 411105;
2. 湘潭大学 湖南省风电装备与电能变换协同创新中心, 湖南 湘潭 411105)

摘要:针对智能电网日益突出的电能质量扰动问题,提出了一种基于稀疏自动编码器(SAE)深度神经网络的电能质量扰动分类方法。利用 SAE 对电能质量扰动原始数据进行无监督特征学习,自动提取数据特征的稀疏特征表达;通过堆栈式稀疏自动编码器(SSAE)进行逐层学习,获得电能质量扰动数据的深层次特征;将其连接到 softmax 分类器进行微调训练,并输出电能质量扰动事件分类结果。利用已添加高斯白噪声的数据对 SSAE 进行训练,以提高其特征表达的抗噪声能力。仿真结果表明,所提方法能够准确地识别包含 2 种复合扰动在内的 9 种电能质量扰动信号,并且具有很好的鲁棒性。

关键词:电能质量;扰动分类;特征提取;扰动识别;稀疏自动编码器;深度学习

中图分类号:TM 761

文献标识码:A

DOI:10.16081/j.issn.1006-6047.2019.05.023

0 引言

近年来,随着智能电网的快速发展以及大量新能源发电装置和冲击性、非线性、波动性负荷接入电网,电力系统的电能质量问题日益突出,各种电能质量扰动事件对工业生产和居民生活造成了非常严重的影响^[1-2]。另一方面,随着科学技术的不断进步,越来越多的用电设备对电能质量提出了更高的标准。而电能质量扰动的准确识别和有效分类能为电能质量的管理和治理提供辅助决策^[3],对最终解决电能质量问题是十分必要的。

目前,国内外学者已经提出的电能质量扰动分类方法通常包括特征提取和扰动识别 2 个步骤^[4]。特征提取主要是对电能质量扰动波形信号进行变换和重构,然后从中提取可以实现扰动分类的特征量,目前常用的特征提取方法包括 S 变换、小波变换(WT)、快速傅里叶变换(FFT)和希尔伯特-黄变换(HHT)等^[5-6]。其中,S 变换在时频的表现比较直观,具有良好的时频分析和特征提取特性,在高频部分的分解也更加细致,但 S 变换对信号奇异点的检测不敏感,且计算量较大;WT 具有良好的时域局部化特征,但易受噪声影响,对低频扰动的分析效果不明显,且小波基的选择比较困难;而 FFT 主要反映信号所分析时段上的整体信息,无法准确地反映信号的局部特性;HHT 方法能自适应地分析非平稳信号,具有检测精度高、抗噪性能好的特点,但存在端点效应和模态混叠现象^[7],而且经验模态分解不彻底会导致出现虚假分量,影响检测的准确性。扰动识别主要用于确定扰动信号的类别,现有扰动识别

方法有决策树(DT)、支持向量机(SVM)、聚类算法和人工神经网络(ANN)等^[8-9]。其中,DT 主要通过制定规则和模仿人类的逻辑思维完成分类,但某些类别的特征阈值确定易受噪声影响^[10];SVM 能识别的扰动种类较多且分类精度较高,但设计难度大且计算量也比较大;ANN 的结构简单,求解问题的能力较强,并且可较好地处理噪声数据,但训练时间较长且准确性也有待提高。

上述特征提取方法已在电能质量扰动分类方面取得了较好的结果,但是这些方法的实现均需要相关的先验知识,并且确定实现细节的过程通常需要反复的修改和调整,十分耗时且很难获得电能质量扰动数据的深度特征。同时,上述特征提取和扰动识别方法的组合几乎是任意的,很难从大量的组合之中选出最理想的类型,因此这种传统的手工特征设计过程可以被具有通用性的自动特征学习方法所替代。深度学习作为机器学习中的一种能从大量数据中自动提取具有多级抽象的特征的方法,已经在图像识别、语音识别等领域取得了显著的成果^[11-12]。其中稀疏自动编码器 SAE(Sparse Auto-Encoder)作为一种无监督的深度神经网络,可以对无标签数据进行特征学习和提取,从高维的原始数据中获得低维的特征表达,简化了分类工作,并且克服了传统神经网络中的权重系数初始化存在随机性的缺点。基于此,本文将深度学习理论应用到电能质量扰动信号的识别中,利用 SAE 从未标记的电能质量扰动数据中自动提取特征,然后通过 softmax 分类器对扰动信号进行分类。本文利用 MATLAB 仿真软件生成电能质量扰动电压信号数据集,验证了 SAE 进行扰动数据特征提取和分类的可行性,并通过有监督微调进行了参数优化。此外,本文利用已添加高斯白噪声的电能质量扰动数据对 SAE 进行训练,提高了其特征表达的抗噪声能力。仿真结果表明,本文所

收稿日期:2018-06-22;修回日期:2019-02-23

基金项目:国家自然科学基金资助项目(61379063)

Project supported by the National Natural Science Foundation of China(61379063)

提方法能够准确地识别包含 2 种复合扰动在内的 9 种电能质量扰动信号,并且具有良好的鲁棒性。

1 SAE 与 softmax 分类器

1.1 SAE

SAE 是一种对称的 3 层神经网络,分为输入层、隐含层和输出层 3 层^[13]。它通过隐含层对输入数据进行编码,然后由输出层进行数据重构,要求在训练过程中保证输出数据尽可能地等于输入数据,使得重构误差最小。与传统的自动编码器不同的是,SAE 在损失函数中增加了稀疏约束项,提高了特征学习能力,使隐含层能获得更有效的特征表示。

给定一个无标签的电能质量扰动数据集 $\{x_1, x_2, \dots, x_m\}$,其中 m 为训练样本的个数。在编码阶段,训练样本 x_i 经过编码能得到隐含层的特征表达 a_i ,如式(1)所示;在解码阶段,网络将对数据进行重构,以获取与原始电能质量扰动数据最接近的输出 z_i ,如式(2)所示。

$$a_i = f_{\theta}(x_i) = f(W_1 x_i + b_1) \quad (1)$$

$$z_i = f_{\theta}(a_i) = f(W_2 a_i + b_2) \quad (2)$$

其中, $f(x)$ 为激活函数,在编码阶段通常选择 sigmoid 函数,而在解码阶段可以选择 sigmoid 函数或者 ReLU 函数,采用 ReLU 函数可以使训练得到的模型更容易应用,而且 SAE 对参数的变化也更鲁棒^[14]; $\theta = [W_1, W_2, b_1, b_2]$ 为网络参数; $W_1 \in \mathbf{R}^{n_h \times n_{in}}$ 、 $W_2 \in \mathbf{R}^{n_{in} \times n_h}$ 分别为输入层与隐含层、隐含层与输出层之间的关联权值矩阵, n_{in} 为输入层节点数, n_h 为隐含层节点数,且有 $W_1 = W_2^T$; $b_1 \in \mathbf{R}^{n_h}$ 、 $b_2 \in \mathbf{R}^{n_{in}}$ 分别为输入层与隐含层、隐含层与输出层的偏置项。

SAE 的损失函数可以表示为:

$$J_{\text{sparse}}(\mathbf{x}, \mathbf{z}) = \frac{1}{2m} \sum_{i=1}^m \|z_i - x_i\|^2 + \frac{\lambda}{2} \sum_{i=1}^2 \|W_i\|_F^2 + \beta \sum_{j=1}^{n_h} k_{\text{KL}}(\rho \| \hat{\rho}_j) \quad (3)$$

$$\hat{\rho}_j = \frac{1}{m} \sum_{i=1}^m a_j^{(1)}(x_i) \quad (4)$$

其中, $k_{\text{KL}}(\rho \| \hat{\rho}_j)$ 为引入的 Kullback-Leibler 相对熵, ρ 为稀疏性参数,正常情况下其是一个近似为 0 的值, $\hat{\rho}_j$ 为隐含层神经元 j 在训练集上的平均激活度; $a_j^{(1)}(x_i)$ 为隐含层神经元 j 在训练集 x_i 上的激活度; λ 和 β 分别为权重衰减项和稀疏惩罚项的系数。式(3)等号右边的第一项为 SAE 输入数据与输出数据的方差;第二项为权重衰减项,用于限制权重的大小,防止 SAE 出现过拟合;第三项为稀疏惩罚项,用于惩罚 ρ 与 $\hat{\rho}_j$ 存在显著差异的情况,以使隐含层神经元的平均激活度保持在合理的范围内,确保特征单元足够稀疏。

为了确保隐含层获得有效的特征表示,在整个网络训练过程中应尽量地减小损失函数 $J_{\text{sparse}}(\mathbf{x}, \mathbf{z})$ 。本文利用 L-BFGS-B 优化算法训练得到最优的参数 θ' ,该过程通过反向传播算法完成,在每次迭代过程中采用批梯度下降法更新权值。在得到最优的参数 θ' 之后,将输入的数据 x_i 转换成新的特征表示 $h_i(\mathbf{x}) \in \mathbf{R}^{n_h}$,则电能质量扰动数据 $\{x_1, x_2, \dots, x_m\}$ 可以表示为 $\{h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_m(\mathbf{x})\}$ 。

1.2 堆栈式稀疏自动编码器

为了解决单个 SAE 函数构造能力不足的问题,将多个 SAE 依次堆叠构成深度神经网络结构,即堆栈式稀疏自动编码器 SSAE (Stacked Sparse Auto-Encoder)^[13],以此获取数据的深度特征,构造表达能力更强的函数。SSAE 是分层编码结构,后面各层的训练过程与第一层 SAE 类似,不同的是后面各层的输入是前一层 SAE 的隐含层输出,经过逐层训练后即可获得电能质量扰动数据的多层抽象特征表示,有效地解决了传统神经网络训练方法不适用于多层网络训练的问题^[15]。SSAE 的整个训练过程由无监督训练和有监督微调 2 个阶段构成。在训练阶段逐层训练每个 SAE 获得原始电能质量扰动数据的深层特征表达,在微调阶段将网络中所包含的多个 SAE 作为一个整体来构造损失函数,然后利用反向传播算法调整各层的权值,实验证明经过有监督的微调后,电能质量扰动分类准确度和抗干扰能力都得到了显著的提高。

1.3 softmax 分类器^[16]

电能质量扰动数据经过 SAE 提取特征后,将其输入 softmax 分类器进行分类。softmax 分类器是在 Logistic 回归的基础上发展而来的多分类回归模型^[16],适用于类标签取值大于 2 的分类问题。softmax 分类器的输入是 SSAE 最后一层的输出,本文中为第二层 SAE 的输出 $h_i^{(2)}(\mathbf{x})$ 。第 i 个输入向量属于第 j 类扰动类型的概率为 $P(Y=j | h_i^{(2)}(\mathbf{x}))$,其计算公式如下:

$$P(Y=j | h_i^{(2)}(\mathbf{x})) = \frac{e^{\theta_j^T h_i^{(2)}(\mathbf{x})}}{\sum_{l=0}^{k-1} e^{\theta_l^T h_i^{(2)}(\mathbf{x})}} \quad (5)$$

其中, Y 为 $h_i^{(2)}(\mathbf{x})$ 对应的输出类别; k 为类别数量,本文中 k 取值为 9; $\theta_j \in \mathbf{R}^{n_h}$ 为类别 $j(j=0, 1, \dots, k-1)$ 对应的参数向量。softmax 分类器的输出为一个包含 9 个概率值 $P(Y=j | h_i^{(2)}(\mathbf{x}))$ 的 9 维向量,表示第 i 个输入样本属于每一类别的概率。根据最大概率原则得到 $h_i^{(2)}(\mathbf{x})$ 所对应的预测电能质量扰动类别 y_i^{pred} 为:

$$y_i^{\text{pred}} = \underset{j}{\text{argmax}} P(Y=j | h_i^{(2)}(\mathbf{x})) \quad (6)$$

softmax 分类器的损失函数为:

$$J_s(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=0}^{k-1} I(y_i=j) \lg \frac{e^{\theta_j^T h_i^{(2)}(x)}}{\sum_{l=0}^{k-1} e^{\theta_l^T h_i^{(2)}(x)}} \right] + \frac{\lambda_s}{2} \sum_{i=0}^{k-1} \|\theta_i\|^2 \quad (7)$$

其中, $I(y_i=j)$ 为示性函数,当括号内的等式为假时, $I=0$, 否则 $I=1$; λ_s 为权重衰减参数,用于平衡损失函数 $J_s(\theta)$ 中的 2 项,从而使得函数为凸函数; y_i 为 $h_i^{(2)}(x)$ 所对应的真实类别。

此外, softmax 分类器还需通过随机梯度下降算法进行微调^[17],对整个网络中的权值和偏置项做进一步的全局调整,训练得到最优的参数 $\theta'' \in \mathbf{R}^{k \times n_{h2}}$,将参数 θ'' 重塑成 $\mathbf{W}^{(3)} \in \mathbf{R}^{n_{h2} \times k}$,其中 n_{h2} 为第二层隐含层的节点数。微调结束后,保留 SAE 的隐含层,撤销输出层及权重。微调网络参数能较大程度地提升 SAE 和 SSAE 的电能扰动事件分类性能。

2 基于 SAE 的电能质量扰动特征提取与分类

2.1 电能质量扰动数据获取与预处理

本文参考文献[7,10]中的电能质量扰动信号仿真模型,在 MATLAB 仿真中产生本文所需使用的数据。选取电压暂降、电压暂升、电压中断、振荡暂态、谐波、电压缺口、电压尖峰、谐波+电压暂降和谐波+电压暂升这 9 种扰动信号,其中包括 2 种复合电能质量扰动信号,扰动模型如附录中的表 A1 所示。表 A1 中, $u(\cdot)$ 和 $\text{sgn}(\cdot)$ 分别为单位阶跃函数和符号函数; T, t_1, t_2 分别为扰动的信号周期、起始时刻和结束时刻; ω 为额定角频率。为了验证本文所提方法的适用性,仿真实验中通过随机改变 A, h_i, K 等参数值生成了多组电能质量扰动信号数据,并且运用本文所提方法对不同参数条件下的各组电能质量扰动信号进行了分类实验,都取得了很好的分类效果。限于篇幅,本文只列出了其中 1 种参数条件下的扰动信号。

本文的扰动信号基波频率 f 选取为 50 Hz, 振幅 $A=1$ p.u., $\omega=2\pi f$, 扰动信号采样频率 $f_s=12.8$ kHz, 每个扰动信号基频周期采样 256 个点,采集时长为 10 个基频周期,即共采样 2 560 个点,每个扰动信号生成 266 组数据,共计 2 394 组数据,并随机打乱顺序。9 种电能质量扰动信号波形如图 1 所示(图中幅值为标么值)。

2.2 电能质量扰动特征提取与分类框架

SAE 中隐含层的实际数量由电能质量扰动的特性和复杂程度决定^[18],本文中所采用的 SAE 和 2 层 SSAE 都能够很好地提取电能质量扰动的特征信息。在如图 2 所示的电能质量扰动特征提取与分类框架(包含 2 个隐含层)中,首先对电能质量扰动原始数

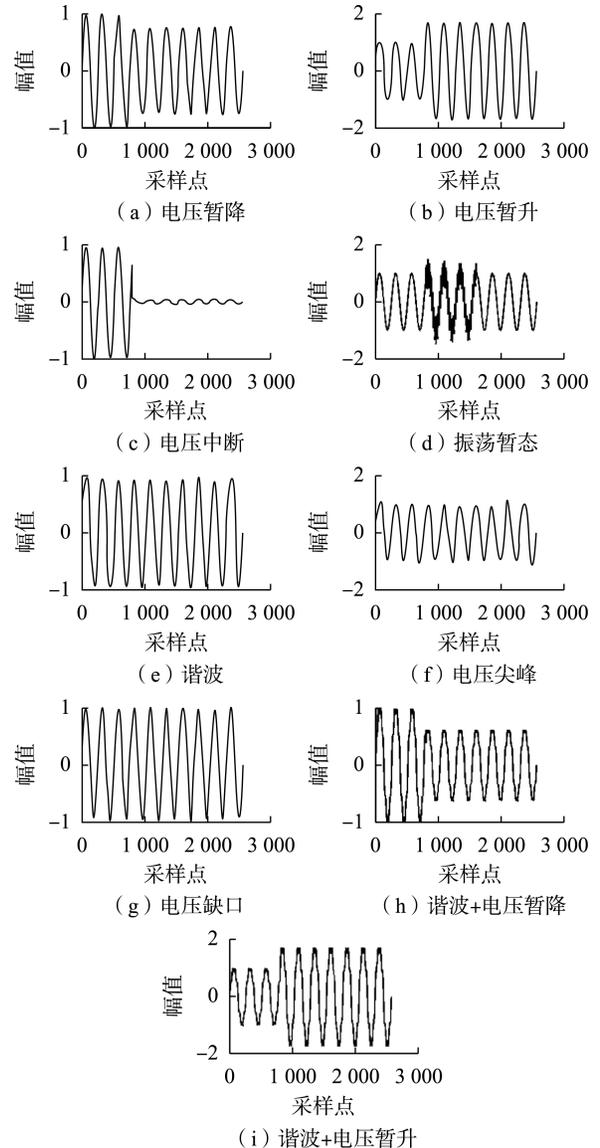


图 1 9 种电能质量扰动信号波形图

Fig.1 Waveforms of nine types of power quality disturbance signals

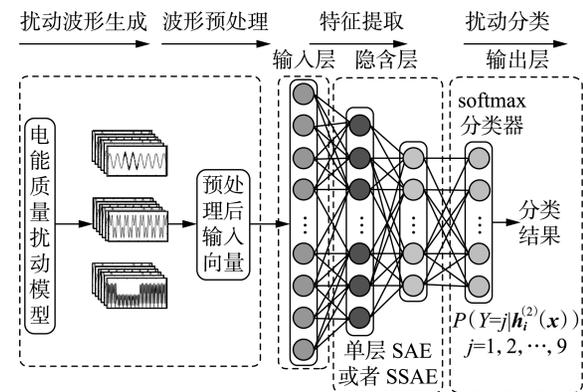


图 2 电能质量扰动特征提取与分类框架

Fig.2 Framework of power quality disturbance feature extraction and classification

据集进行预处理,包括数据标准化、切割波形长度两部分;然后将预处理后的数据样本输入 2 层 SSAE

中进行自动特征学习;最后将提取到的特征表达传递给 softmax 分类器进行有监督的微调,对网络参数做进一步调整后得到训练好的分类模型,此时即可将测试样本输入此模型进行电能质量扰动分类。

2.3 SAE 特征提取的可行性分析

为了验证 SAE 能够从电能质量扰动数据中提取到有用的特征,本文分别采用 SAE 和主成分分析法(PCA)对电能质量扰动数据进行降维,将波形特征映射到 2 维子空间,对特征提取结果进行可视化分析。每条波形由最初的 2 400 维向量经特征提取后变成一个 2 维向量,该过程有 2 种处理方法:方法①是利用 SAE 将向量维数从 2 400 降到 50,再由 PCA 降到 2;方法②是直接利用 PCA 将向量维数从 2 400 降到 2。2 种方法的特征提取结果如附录中的图 A1 所示。结果表明:2 种方法对 7 种单一的扰动信号特征提取都取得了很好的效果,可以将信号相互分开;但是在复合电能质量扰动信号的特征提取过程中,方法①的特征提取效果要优于方法②,如图 A1(a)所示,当采用方法①时,2 种复合扰动信号与单一扰动信号大部分已经分开,而采用方法②时,复合扰动信号与单一扰动信号相混合,很难区分,如图 A1(b)所示。实验结果证明 SAE 对包含复合扰动在内的电能质量扰动特征可以有很好的提取效果。

2.4 电能质量扰动分类效果

在验证了 SAE 对电能质量扰动特征提取的可行性之后,利用本文所提方法对 9 种电能质量扰动进行分类。采用混淆矩阵对电能质量扰动分类效果进行可视化,结果见附录中的图 A2。从混淆矩阵中可以看出,每种电能质量扰动类型的分类准确度都达到了 99%以上,总体分类准确度达到了 99.84%。实验结果表明本文所提方法能以很高的精度完成电能质量扰动分类。

3 参数选择与实验结果

本文开展深度学习的硬件实验环境配置如下:主板为 Notebook N15_17RF, CPU 为 i7-6700,内存 16 GB。软件实验环境配置为:操作系统为 Windows 10 Enterprise 64 位,编程软件和语言分别为 Anaconda3、python3.5,深度学习框架为 Tensorflow。为了验证本文所提方法的有效性、泛化能力,采用 10 折交叉验证法,即将数据集中的 2 394 个样本随机分成 10 份,每次选择其中的 1 份用来测试模型的性能,剩下的 9 份用来训练模型,交叉验证重复 9 次,将 9 次的平均交叉验证结果作为最终对模型精度的估计,根据最终实验结果确定 SAE、SSAE 的几个重要参数。设定参数 λ 、 β 的值分别为 0.003、3。

3.1 稀疏参数选择

SAE 的核心思想是将所有隐含节点的平均激活

水平限制在比较小的范围内,但对于模型稀疏参数的选择没有给出明确的指示。可以从 (s_{\min}, s_{\max}) 范围内选择优化稀疏参数,其中, s_{\max} 的选择不宜过大,这样才能满足稀疏条件;同时, s_{\min} 的值也不能过小,否则所有隐含的节点都不能被有效地激活,会降低特征提取的效率。图 3 给出了 SAE(隐含层节点数为 50)在不同稀疏参数下的分类准确率。

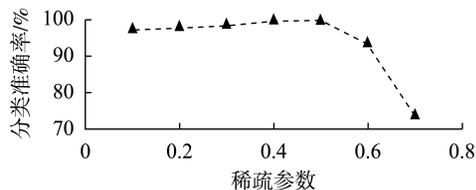


图 3 稀疏参数对电能质量扰动分类的影响

Fig.3 Influence of sparsity parameter on classification of power quality disturbances

结果表明,对于给定的数据集,当稀疏参数设定在(0.3,0.5)范围内时,整体分类的准确率可以达到 98%以上;当参数取得过小,例如小于 0.1 时,分类准确率降低至 94%;而当参数值达到 0.5 以上时,分类准确率也会有所下降,误差变大。因此本文实验中的稀疏参数将在(0.3,0.5)范围内进行选择。

3.2 SAE 隐含节点选择

隐含层中的隐含节点数量将会直接影响 SAE 的特征提取能力,为了保证从训练集找到有效的特征,达到预想的分类精度,隐含节点的数目就不能选择得过大。图 4 给出了 SAE 在不同隐含节点数下的准确率,其输入波形时长为 6 个工频周期,稀疏参数为 0.4。结果表明,当隐含层的节点数目达到 40 时,分类准确率超过 99%,并且能够随着数量的增加保持稳定。因此,SAE 的隐含层节点数目选取为 50 是比较合理的。

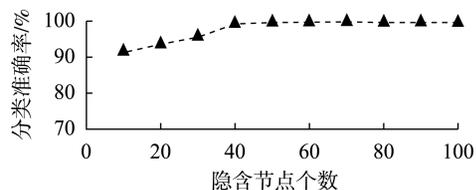


图 4 SAE 的隐含层节点数对电能质量扰动分类的影响

Fig.4 Influence of number of node in hidden layer of SAE on classification of power quality disturbances

在 2 层 SSAE 的特征提取中,2 个隐含层都要考虑,每一个隐含层中节点数的选择都十分重要,所以隐含层节点的确定比较困难。本文用三维立体图给出 2 层 SSAE 在不同隐含层节点数下的电能质量扰动分类准确率,如附录中的图 A3 所示,其输入波形时长为 6 个工频周期,稀疏参数为 0.4。结果表明,当隐含层节点数较小时,分类精度会随着节点数的增加而增加,当 2 个隐含层中节点的数目分别达到 90 和 50 时,分类准确率可以达到 99.84%,且随着数

目的增加保持稳定。另一方面,节点数选择得过大导致训练时间加长,因此,在2层SSAE中将隐含层节点数设置为90和50是比较合理的。

3.3 采样频率对电能质量扰动分类的影响

采用3.2节中的2层SSAE分别在1.6 kHz、3.2 kHz、6.4 kHz、12.8 kHz、25.6 kHz的采样频率下对电能质量扰动信号进行分类,结果如表1所示。实验结果表明本文所提方法在不同的采样频率下都可以达到很高的分类准确率,采样频率对分类准确率的影响可以忽略不计,同时也说明了所提方法具有很好的适应性。

表1 采样频率对电能质量扰动分类的影响

Table 1 Influence of sampling frequency on classification of power quality disturbances

采样频率/kHz	分类准确率/%	采样频率/kHz	分类准确率/%
1.6	99.85	12.8	99.83
3.2	99.87	25.6	99.85
6.4	99.80		

3.4 信噪比对分类效果的影响

在9种电能量扰动信号的基础上叠加信噪比(SNR)分别为50 dB、40 dB、30 dB、20 dB、10 dB的高斯白噪声,生成同样数量的电能质量扰动信号数据样本,检验本文所提方法的分类准确率,仿真测试结果如表2所示。可以看出,本文所提方法在不同信噪比下的分类准确率能够稳定在99%以上,表明本文所提方法具有很好的鲁棒性。

表2 噪声对电能质量扰动分类的影响

Table 2 Influence of noise on classification of power quality disturbances

信噪比/ dB	分类准确率/%		信噪比/ dB	分类准确率/%	
	SAE	SSAE		SAE	SSAE
10	99.22	99.19	40	99.81	99.74
20	99.50	99.37	50	99.76	99.82
30	99.85	99.70			

3.5 与其他扰动分类方法的比较

为了进一步验证本文所提方法的有效性,将其分类结果与其他分类方法^[7,19]进行对比,结果如表3所示。可以看出,本文所提方法在分类准确率上高于其他方法。

表3 不同方法的分类结果对比

Table 3 Comparison of classification results among different methods

分类方法	分类准确率/%	分类方法	分类准确率/%
单层SAE+softmax分类器	99.69	文献[7]方法	99.20
2层SSAE+softmax分类器	99.84	文献[19]方法	99.11

4 结论

本文提出了一种基于SAE深度神经网络的电

能质量扰动分类方法,将深度学习理论应用到电能质量扰动分类中,并将无监督训练的SAE特征提取与有监督训练的微调相结合,对7种单一扰动和2种复合电能质量扰动进行分类,经过仿真实验表明所提方法的整体分类精度达到了99.84%,而且具有很好的抗噪性。需要指出的是,本文工作主要基于仿真实验,下一步需要将此方法应用于实际电能质量扰动识别之中检测其性能。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 瞿合祚,刘恒,李晓明,等.一种电能质量多扰动分类中特征组合优化方法[J].电力自动化设备,2017,37(3):146-152.
QU Hezuo,LIU Heng,LI Xiaoming,et al.Feature combination optimization for multi-disturbance classification of power quality[J].Electric Power Automation Equipment,2017,37(3):146-152.
- [2] LUO A,XU Q M,MA F J,et al.Overview of power quality analysis and control technology for the smart grid[J].Journal of Modern Power Systems and Clean Energy,2016,4(1):1-9.
- [3] 崔志强,王宁,贾清泉.基于分层匹配追踪算法的电能质量复合扰动参数辨识方法[J].电力自动化设备,2017,37(3):153-159.
CUI Zhiqiang,WANG Ning,JIA Qingquan.Parameter identification based on hierarchical matching pursuit algorithm for complex power quality disturbance[J].Electric Power Automation Equipment,2017,37(3):153-159.
- [4] 仇新艳,李付亮.基于ITD和K均值聚类的电能质量扰动分析与识别[J].电力系统及其自动化学报,2015,27(8):54-59.
QIU Xinyan,LI Fuliang.Analysis and identification for power quality disturbance signals based on ITD and K-mean clustering algorithm[J].Proceedings of the CSU-EPSA,2015,27(8):54-59.
- [5] 徐志超,杨玲君,李晓明.基于聚类改进S变换与直接支持向量机的电能质量扰动识别[J].电力自动化设备,2015,35(7):50-58,73.
XU Zhichao,YANG Lingjun,LI Xiaoming.Power quality disturbance identification based on clustering-modified S-transform and direct support vector machine[J].Electric Power Automation Equipment,2015,35(7):50-58,73.
- [6] 张杨,刘志刚.EEMD在电能质量扰动检测中的应用[J].电力自动化设备,2011,31(12):86-91.
ZHANG Yang,LIU Zhigang.Application of EEMD in power quality disturbance detection[J].Electric Power Automation Equipment,2011,31(12):86-91.
- [7] 陈晓静,李开成,肖剑,等.一种实时电能质量扰动分类方法[J].电工技术学报,2017,32(3):45-55.
CHEN Xiaojing,LI Kaicheng,XIAO Jian,et al.A method of real-time power quality disturbance classification[J].Transactions of China Electrotechnical Society,2017,32(3):45-55.
- [8] 冯宇,唐轶,石延辉,等.电能质量分析与参数估计的研究方法综述[J].电力系统及其自动化学报,2010,22(3):78-85.
FENG Yu,TANG Yi,SHI Yanhui,et al.Survey on research method of power quality analysis and parameter estimate[J].Proceedings of the CSU-EPSA,2010,22(3):78-85.
- [9] KUMAR R,SINGH B,SHAHANI D T,et al.Recognition of power-quality disturbances using S-transform-based ANN classifier and rule-based decision tree[J].IEEE Transactions on Industry Appli-

- cations, 2015, 51(2): 1249-1258.
- [10] 陈华丰, 张葛祥. 基于决策树和支持向量机的电能质量扰动识别[J]. 电网技术, 2013, 37(5): 1272-1278.
CHEN Huafeng, ZHANG Gexiang. Power quality disturbance identification using decision tree and support vector machine[J]. Power System Technology, 2013, 37(5): 1272-1278.
- [11] CHEN K J, HU J, HE J L. A framework for automatically extracting overvoltage features based on sparse autoencoder[J]. IEEE Transactions on Smart Grid, 2018, 9(2): 594-604.
- [12] ZEILER M D, RANZATO M, MONGA R, et al. On rectified linear units for speech processing[C]//2013 IEEE International Conference on Acoustics, Speech and Signal Processing. Vancouver, BC, Canada; IEEE, 2013: 3517-3521.
- [13] 孙文珺, 邵思羽, 严如强. 基于稀疏自动编码深度神经网络的感应电动机故障诊断[J]. 机械工程学报, 2016, 52(9): 65-71.
SUN Wenjun, SHAO Siyu, YAN Ruqiang. Induction motor fault diagnosis based on deep neural network of sparse auto-encoder[J]. Chinese Journal of Mechanical Engineering, 2016, 52(9): 65-71.
- [14] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[C]//JMLR Workshop and Conference Proceedings Volume 15: AISTATS 2011. Brookline, MA, USA; Microtome Publishing, 2011: 315-323.
- [15] 石鑫, 朱永利, 宁晓光, 等. 基于深度自编码网络的电力变压器故障诊断[J]. 电力自动化设备, 2016, 36(5): 122-126.
SHI Xin, ZHU Yongli, NING Xiaoguang, et al. Transformer fault diagnosis based on deep auto-encoder network[J]. Electric Power Automation Equipment, 2016, 36(5): 122-126.
- [16] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[C]//European Conference on Computer Vision. [S.l.]: Springer International Publishing, 2014: 818-833.
- [17] CHEN Z Y, LI W H. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(7): 1693-1702.
- [18] 戴晓爱, 郭守恒, 任涓, 等. 基于堆栈式稀疏自编码器的高光谱影像分类[J]. 电子科技大学学报, 2016, 45(3): 382-386.
DAI Xiaoi, GUO Shouheng, REN Yu, et al. Hyperspectral remote sensing image classification using the stacked sparse autoencoder[J]. Journal of University of Electronic Science and Technology of China, 2016, 45(3): 382-386.
- [19] 黄建明, 瞿合祚, 李晓明. 基于短时傅里叶变换及其谱峭度的电能质量混合扰动分类[J]. 电网技术, 2016, 40(10): 3184-3191.
HUANG Jianming, QU Hezuo, LI Xiaoming. Classification for hybrid power quality disturbance based on STFT and its spectral kurtosis[J]. Power System Technology, 2016, 40(10): 3184-3191.

作者简介:



屈相帅

屈相帅(1995—),男,山东临沂人,硕士研究生,主要研究方向为电能质量扰动识别、深度学习(**E-mail**: quxiangshuai@163.com);

段斌(1966—),男,湖南湘潭人,教授,博士研究生导师,主要研究方向为电力系统及其自动化以及电力通信网络与系统

(**E-mail**: brizeey@foxmail.com);

尹桥宣(1991—),男,湖南郴州人,硕士研究生,主要研究方向为信息物理能源系统、深度学习(**E-mail**: xtu_yqx1991@163.com)。

Classification method of power quality disturbances based on deep neural network of sparse auto-encoder

QU Xiangshuai^{1,2}, DUAN Bin^{1,2}, YIN Qiaoxuan^{1,2}, YAN Yinxin², ZHONG Ying²

(1. Key Laboratory of Intelligent Computing & Information Processing of Ministry of Education, Xiangtan University, Xiangtan 411105, China; 2. Cooperative Innovation Center for Wind Power Equipment and Energy Conversion, Xiangtan University, Xiangtan 411105, China)

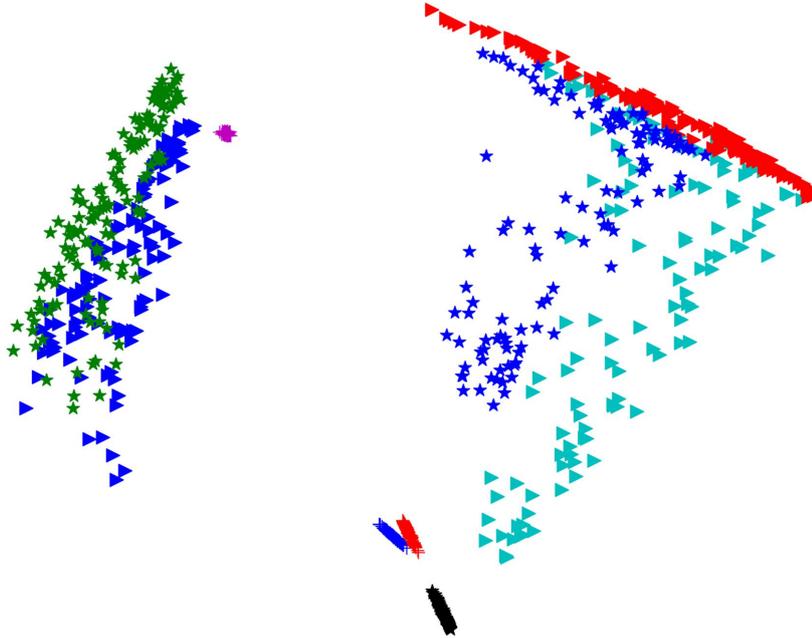
Abstract: Aiming at the increasingly prominent power quality disturbances in smart grid, a classification method of power quality disturbances based on deep neural network of SAE(Sparse Auto-Encoder) is proposed. The unsupervised feature learning is carried out for the original data of power quality disturbances by using SAE and the sparse feature expressions of data features are extracted automatically. The deep features of power quality disturbance data are acquired by learning layer by layer based on SSAE(Stack Sparse Auto-Encoder). The deep features are connected to the softmax classifier for fine-tuning training to obtain the classification result of power quality disturbances. SSAE is trained based on the data added with Gaussian white noise to improve the anti-noise ability of its feature expression. Simulative results show that the proposed method can accurately identify nine kinds of power quality disturbance signals including two types of complex disturbances, and have good robustness.

Key words: power quality; classification of disturbances; feature extraction; disturbance identification; sparse auto-encoder; deep learning

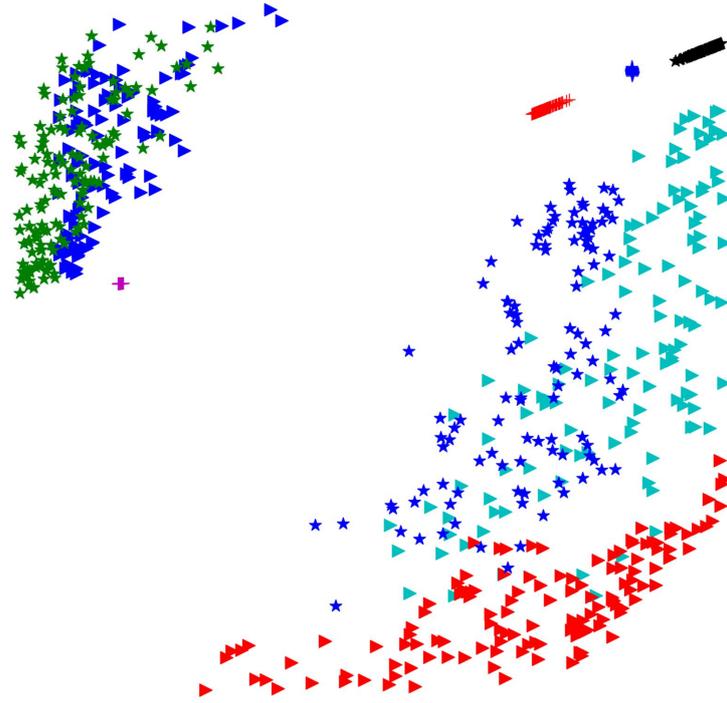
附录

表 A1 电能质量扰动仿真模型
Table A1 Simulation models of power quality disturbances

扰动类型	表达式	参数
电压暂降	$v(t) = A[1 - K(u(t_2) - u(t_1))] \cos(\omega t)$	$0.1 < K < 0.9, T \leq t_2 - t_1 \leq 9T$
电压暂升	$v(t) = A[1 + K(u(t_2) - u(t_1))] \cos(\omega t)$	$0.1 < K < 0.9, T \leq t_2 - t_1 \leq 9T$
电压中断	$v(t) = A[1 - K(u(t_2) - u(t_1))] \cos(\omega t)$	$0.9 < K < 1, T \leq t_2 - t_1 \leq 9T$
谐波	$v(t) = A \cos(\omega t) + h_3 \cos(3\omega t) + h_5 \cos(5\omega t) + h_7 \cos(7\omega t)$	$0.02 \leq h_i \leq 0.1 (i = 3, 5, 7)$
振荡暂态	$v(t) = A \{ \cos(\omega t) + K \exp[-(t - t_1) / \tau] \cos[(\omega_n(t - t_1)) (u(t_2) - u(t_1))] \}$	$K = 0.7, \tau = 0.1115, \omega_n = 2\pi f_n$ $900\text{Hz} \leq f_n \leq 1300\text{Hz}$
电压缺口	$v(t) = \cos(\omega t) + \text{sign}[\cos(\omega t)] \sum_{n=0}^9 K \{ u[t - (t_1 + 0.02n)] - u[t - (t_2 + 0.02n)] \}$	$0.2 \leq K \leq 0.4, 0 \leq t_1, t_2 \leq 0.5T,$ $0.01T \leq t_2 - t_1 \leq 0.05T$
电压尖峰	$v(t) = \cos(\omega t) + \text{sign}[\cos(\omega t)] \sum_{n=0}^9 K \{ u[t - (t_1 + 0.02n)] - u[t - (t_2 + 0.02n)] \}$	$0.2 \leq K \leq 0.4, 0 \leq t_1, t_2 \leq 0.5T,$ $0.01T \leq t_2 - t_1 \leq 0.05T$
谐波+电压暂降	$v(t) = A[1 - K(u(t_2) - u(t_1))] [\cos(\omega t) + h_3 \cos(3\omega t) + h_5 \cos(5\omega t) + h_7 \cos(7\omega t)]$	$0.1 \leq K \leq 0.9, 0.02 \leq h_i \leq 0.1 (i = 3, 5, 7)$
谐波+电压暂升	$v(t) = A[1 + K(u(t_2) - u(t_1))] [\cos(\omega t) + h_3 \cos(3\omega t) + h_5 \cos(5\omega t) + h_7 \cos(7\omega t)]$	$0.1 \leq K \leq 0.9, 0.02 \leq h_i \leq 0.1 (i = 3, 5, 7)$



(a) 方法①



(b) 方法②

- ▶ 电压暂降, ▶ 电压暂升, ▶ 电压中断
- ++ 振荡暂态, ++ 谐波, ++ 电压尖峰
- ★ 电压缺口, ★ 谐波+电压暂降, ★ 谐波+电压暂升

图 A1 2 种方法的特征提取二维可视化

Fig.A1 Two-dimensional representation of feature extraction for two method

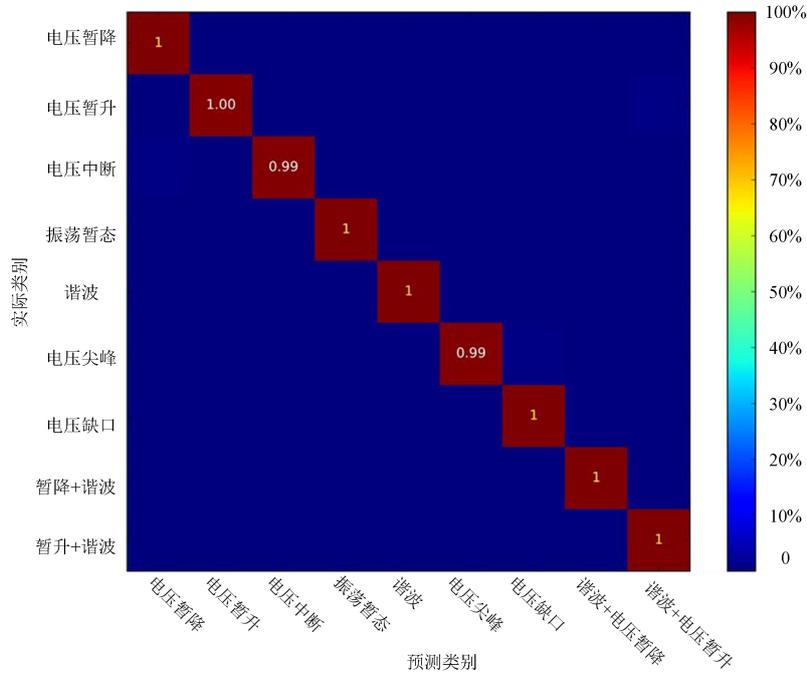


图 A2 电能质量扰动分类混淆矩阵

Fig.A2 Confusion matrix of classification accuracy for power quality disturbances

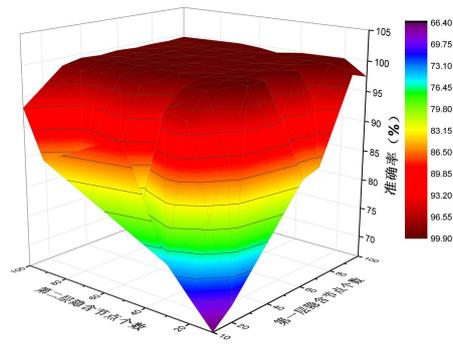


图 A3 两层 SSAE 隐含层节点数对电能质量扰动分类的影响

Fig.A3 Influence of number of node in hidden layer of two-layer SSAE on classification of power quality disturbances