

DOI: 10.19783/j.cnki.pspc.210085

基于多域特征的扰动辨识方法研究

张振宇¹, 张明龙¹, 高源¹, 罗翔¹, 朱珂²

(1. 国网福建省电力有限公司电力科学研究院, 福建 福州 350007; 2. 山东大学电气工程学院, 山东 济南 250061)

摘要: 扰动波形的辨识是基于扰动开展特征提取和信息挖掘等研究工作的前提, 而噪声、扰动间干扰以及特征提取方法的影响, 都有可能导致针对不同扰动提取出的同一域下典型特征间边缘重叠, 进而影响扰动辨识的准确性。提出一种利用多域典型特征来识别扰动类型的辨识方法。首先, 利用多域特征样本和单域特征样本先后训练神经网络, 进而结合 DS 证据理论融合各域输出以建立面向多域特征的辨识算法。其次, 在对三种因素影响下的单域特征开展分析的基础上, 对所提出的辨识算法与各种传统的基于单域特征辨识算法的正确率进行对比, 以论证所提出辨识算法的有效性。该方法克服了待辨识扰动单域下异常特征对辨识精度的影响, 受噪声影响小, 算法稳定性好。

关键词: 扰动辨识; 多域特征样本; 改进 dropout 算法; DS 证据理论; 配电网

Power disturbance identification research based on multi-domain features

ZHANG Zhenyu¹, ZHANG Minglong¹, GAO Yuan¹, LUO Xiang¹, ZHU Ke²

(1. Electrical Power Research Institute, State Grid Fujian Electric Power Co., Ltd., Fujian 350007, China;
2. School of Electrical Engineering, Shandong University, Jinan 250061, China)

Abstract: The identification of the disturbance waveform is the precondition of the research work of feature extraction and information mining based on the disturbance. However, noise, interference between disturbances and the effect of feature extraction method may lead to edge blurring of features of the same domain extracted from different disturbances, thus affecting the accuracy of disturbance recognition. Therefore, this paper proposes an identification method based on multi-domain typical features to identify disturbance types. First, the neural network is trained successively with multi-domain and single-domain features, and then the output of network in each domain is fused based on DS evidence theory to set up a multi-domain features oriented identification algorithm. Next, on the basis of analyzing the influence of three factors on the single-domain features, the effectiveness of the proposed algorithm is demonstrated by comparing its identification accuracy with that of the traditional single-domain feature recognition algorithms. The method reduces the influence of anomalous features in a single domain on the identification accuracy, and is robust to noise and stable.

This work is supported by the Science and Technology Project of the Headquarters of State Grid Corporation of China “Key Technologies Research and Application of Primary and Secondary Deep Integration with Lean Operation and Maintenance of Distribution Switch Based on Internet of Things” (No. 52130421000S).

Key words: disturbance identification; multi-domain feature sample; improved dropout algorithm; DS evidence theory; distribution system

0 引言

近年来, 非线性、冲击性和不平衡负荷不断投入使用导致波形畸变、三相不平衡、电网谐振等众

多电能质量问题, 严重影响了工业生产和用户生活, 同时, 越来越多的电力电子装置等敏感性负荷投入运行, 对电能质量提出更高的要求^[1-3]。不同类型的电能质量扰动对用户的影响程度不同, 如何从海量的波形监测数据中正确快速地辨识各类扰动对扰动波形的分析及应对措施的选择具有重要的意义^[4-7]。

当前, 关于各类扰动辨识算法的研究成果斐然。文献[8]利用加窗傅里叶变换提取扰动中的频域信

基金项目: 国家电网有限公司总部科技项目资助“基于物联网技术的配电开关一二次深度融合与精益运维关键技术研究及应用”(52130421000S)

息用于含有谐波的扰动辨识。文献[9]通过对扰动进行短时傅里叶变换提取时频相量,进而使用支持向量机完成电能质量扰动的分类。文献[10]利用短时傅里叶变换得到扰动特征序列以生成时频域特征曲线,利用决策树实现单一和复合扰动识别。文献[11-12]将小波变换得到的小波系数熵和能量值作为特征量输入神经网络,从而实现扰动信号的识别。文献[13]利用松散型小波提取系数幅值特征,进而通过梯度下降法优化的BP神经网络加以辨识。文献[14]基于极大重叠离散小波提取小波系数能量,利用隐马尔科夫模型对扰动进行分类识别。文献[15]基于可调窗的连续复小波和专家系统来识别多重电能扰动。文献[16]在对信号进行S变换后采用统计的方法确定两种最优特征,将其作为训练样本输入二元树结构支持向量机以实现扰动的辨识。文献[17]利用快速S变换提取时频特征和能量特征,通过决策树实现噪声影响下扰动信号的辨识。

综上所述,当前各种电能质量扰动辨识方法主要基于各类扰动的定义或者变换到某个域下的典型特征进行辨识。然而由于基于变换的各种特征提取方法均有其适用性^[18-20],加以噪声^[21-22]和扰动间干扰的影响^[23],使得提取的不同扰动典型特征间可能出现重叠现象,影响电能质量扰动辨识的准确性。针对该问题,本文提出一种利用多域典型特征来辨识各类扰动的方法。为了兼顾各域特征的差异性,先后利用多域特征样本和单域特征样本对神经网络开展训练。在输入单域特征样本时,基于各隐藏层神经元对辨识结果的平均影响分配其动作概率,进而在充分利用多域特征开展扰动辨识的同时,削弱单域下的异常特征对辨识的不利影响。

1 基于多域特征的电能质量扰动辨识方法

电能质量扰动辨识是电能质量分析的重要环节,鉴于单域下异常特征对扰动辨识的不利影响,综合多域特征开展扰动辨识。首先利用多域特征样本初步训练神经网络,其次分别利用各域特征样本对该网络的隐藏层神经元进行二次训练,以提高各域特征输入时神经网络的泛化能力,最后结合DS证据理论给出面向多域特征的在线辨识步骤。

1.1 BP神经网络的初步训练

本文首先利用各种特征提取技术提取待辨识扰动各域下的典型特征,然后将其混合后输入BP神经网络进行初步训练。各域下典型特征量^[24-28]如表1所示。

表1 时频域、小波域和S域的典型特征量
Table 1 Typical characteristics of the time-frequency Domain, wavelet domain and S domain

序号	时频域特征	小波域特征	S域特征
A	基频幅值曲线的最小值	1层能量值	基频幅值的均值
B	基频幅值曲线的最大值	2层能量值	基频幅值的标准差
C	各频率的正弦分量的标准差曲线波峰的频率值	3层能量值	基频幅值最小值时刻附近信号最小值
D	各频率分量幅值时域最大值的波峰个数	4层能量值	高频幅值均值
E	高频幅值序列曲线是否存在波峰	5层能量值	S变换最大频谱幅值曲线的峰值数

为防止传统BP神经网络在反向传播过程中易出现的梯度消失现象,采用softmax函数作为BP神经网络的激活函数,交叉熵作为衡量识别正确率的指标,算法过程如下。

假设神经网络输入层神经元的个数为 N_{in} ,隐藏层的神经元个数为 N_y ,输出层的神经元个数为 N_o 。输入层的输入为 $x_m(m=1,2,\dots,N_{in})$,第 m 个输入层神经元与第 i 个隐藏层神经元的连接权重为 v_{im} ,则第 i 个隐藏层神经元的输入 net_i 为

$$net_i = \sum_{m=1}^{N_{in}} v_{im} x_m \quad (1)$$

经激活函数后,第 i 个隐藏层神经元的输出 $f(net_i)$ 为

$$f(net_i) = \frac{1}{1 + e^{-net_i}} \quad (2)$$

第 k 个输出层神经元与第 i 个隐藏层神经元的连接权重为 w_{ki} ,第 k 个输出层神经元的输入 net_k 为

$$net_k = \sum_{i=1}^{N_y} w_{ki} f(net_i) \quad (3)$$

经激活函数后,第 k 个输出层神经元的输出 O_k 为

$$O_k = \frac{e^{net_k}}{\sum_{k=1}^{N_o} e^{net_k}} \quad (4)$$

则输出的交叉熵函数为

$$Loss = -\sum_{k=1}^{N_o} Y_k \ln O_k \quad (5)$$

式中, Y_k 为第 k 个输出层神经元真实的识别结果。

BP神经网络的反向传播过程中,权值 w_{ki} 的更新公式为

$$w_{ki}^{h+1} = w_{ki}^h + g \cdot \frac{\partial Loss}{\partial w_{ki}^h} \quad (6)$$

式中: h 表示BP神经网络处于第 h 次前向传播更新; g 为 w_{ki} 的更新步长。

$$\frac{\partial Loss}{\partial w_{ki}^h} = \frac{\partial Loss}{\partial net_k} \cdot \frac{\partial net_k}{\partial w_{ki}^h} = (O_k - Y_k) \cdot f'(net_k) \quad (7)$$

权值 v_{im} 的更新公式为

$$v_{im}^{h+1} = v_{im}^h + d \cdot \frac{\partial Loss}{\partial v_{im}^h} \quad (8)$$

式中, d 为 v_{im} 的更新步长。

$$\frac{\partial Loss}{\partial v_{im}^h} = \frac{\partial Loss}{\partial net_i} \cdot \frac{\partial net_i}{\partial v_{im}^h} = \left[\sum_{k=1}^{N_o} (O_k - Y_k) * w_{ki}^h \right] \cdot f'(net_i) \quad (9)$$

1.2 BP 神经网络的二次训练

为提高单个域下特征辨识的准确性, 需要分别利用各域特征对初步训练的神经网络进行二次训练。因此, 在经初步训练确定初值和偏置后, 进一步使用改进 dropout 算法, 在每个域特征分别输入神经网络时, 首先计算保留各隐藏层神经元前后交叉熵的损失差, 通过该值来反映各神经元对该域样本的敏感程度, 然后依据各神经元敏感程度分配其动作概率, 进而得到各域子神经网络。算法步骤如下所示:

1) 把某个域下一组特征作为单个样本输入神经网络后, 将第 n 个隐藏层神经元的影响因子置 0, 计算该步骤前后神经网络交叉熵的损失差 L_n 为

$$L_n = Loss - Loss_{v_n} \quad (10)$$

式中, $Loss_{v_n}$ 为当第 n 个隐藏层神经元的影响因子为 0 即移除该神经元时神经网络输出的交叉熵。为提高运行速度, 计算过程中可只取泰勒级数展开的前两项。

2) 计算该域下所有样本集的平均损失差 \bar{L}_n 。

3) 该域下第 n 个隐藏层神经元的动作概率为

$$AP_n = \frac{1}{1 + e^{\bar{L}_n/T}} \quad (11)$$

式(11)中使用 sigmoid 函数把 \bar{L}_n 映射到(0,1)区间, 其中 T 是控制 \bar{L}_n 对概率的影响程度。当 $T \rightarrow \infty$, 该算法类似于标准 dropout 算法; 当 $T \rightarrow 0$ 时, 则第 n 个隐藏层神经元的动作概率 AP_n 为

$$AP_n = \begin{cases} 1 & \bar{L}_n < 0 \\ 0 & \bar{L}_n \geq 0 \end{cases} \quad (12)$$

4) 求出在该域下所有隐藏层神经元的动作概率。

5) 针对各个域输入样本, 重复 1)–4) 的步骤, 得到在各个域下所有隐藏层神经元的动作概率 AP 。

6) 接下来, 按各域的神经网络结构对应的动作概率保留其隐藏层神经元, 训练 3~5 个周期。

7) 测试过程中, 针对不同域样本输入, 将各个神经元的响应与对应的动作概率 AP 相乘, 缩放各神经元响应。

1.3 电能质量扰动在线辨识

在线测试阶段, 首先将各个域特征分别输入相应域的子神经网络, 按在各个域神经元的动作概率缩放所有隐藏层神经元的响应, 得到各个域的辨识结果^[29-30]。鉴于每个域的辨识结果的可信度各不相同, 为了融合上述的辨识结果, 本文将各个域的神经网络的输出转化为各条独立证据, 利用证据理论中的 Dempster-Shafer(DS)组合规则, 融合不同域神经网络的识别证据, 得出最终的分类结果, 并给出该结果的信任程度。

DS 证据理论的辨别框架为 $\Theta = \{S_1, S_2, S_3, \dots\}$, S_1 表示电压暂升, S_2 表示电压暂降, S_3 表示电压中断……第 j 个域 BP 神经网络的识别结果分配的基本概率赋值为 $B_j \in [0, 1]$, 满足以下两个条件:

$$B_j(\emptyset) = 0 \quad (13)$$

$$\sum_{A \subseteq \Theta} B_j(A) = 1 \quad (14)$$

第 j 个域对应的分类器输出未知的 x 扰动属于 S_a 类电能质量扰动的基本概率分配为

$$B_j(S_a) = P_a \cdot P_{ab} \quad (15)$$

式中: P_a 为第 j 个域对应的分类器输出为 S_a 类电能质量扰动的后验概率; P_{ab} 为当第 j 个域对应的分类器输出为 S_b 类电能质量扰动时, 未知扰动 X 的真实类别是 S_a 类电能质量扰动的概率。根据混淆矩阵给出的相关信息可得 P_{ab} 为

$$P_{ab} = \frac{c_{ab}}{c_b} \quad (16)$$

式中: c_{ab} 为 S_a 类电能质量扰动被第 j 个域对应的分类器误判断为 S_b 类扰动的样本总数; c_b 为第 j 个域对应的分类器将未知扰动 X 辨别为 S_b 类电能质量扰动的样本总数。

对于每个分类器, 给定的扰动 $S \subseteq \Theta$, DS 证据理论的合成法则可简化为

$$B(S) = (B_1 \oplus B_2 \oplus B_3 \dots)(S) = \frac{1}{K} \sum_{z_1 \cap z_2 \cap z_3 \dots = S} B_1(z_1) B_2(z_2) B_3(z_3) \dots \quad (17)$$

其中

$$K = \sum_{z_1 \cap z_2 \cap z_3 \dots \neq \emptyset} B_1(z_1) B_2(z_2) B_3(z_3) \dots = 1 - \sum_{z_1 \cap z_2 \cap z_3 \dots = \emptyset} B_1(z_1) B_2(z_2) B_3(z_3) \dots \quad (18)$$

其中, 第 1, 2, 3……个域的神经网络识别结果对应的焦

元分别为 $Z_1, Z_2, Z_3 \dots$ 。 $K=0$ 表示证据之间所提供的信息相互矛盾, 此时无法用 DS 证据理论合成各条证据。 本文通过上述 DS 证据理论的合成法则融合各个域 BP 神经网络的输出, 给出最终的辨识结果。

基于上述各部分的阐述, 给出本文所提出辨识系统的建立和调试流程, 如图 1 所示。

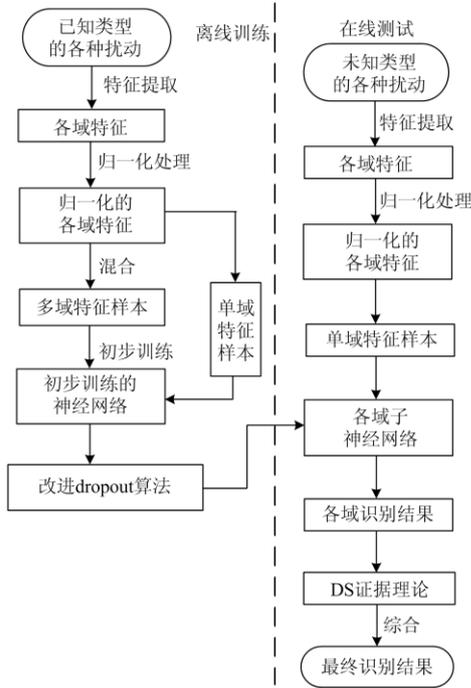


图 1 辨识系统的建立和调试流程图

Fig. 1 Establishment and debugging flow chart of identification system

2 仿真实验

利用仿真模拟生成 6 种单一扰动和 4 种复合扰动^[27], 信号的采样频率为 2.4 kHz, 并在信号上分别叠加 40 dB/20 dB/10 dB 高斯白噪声, 每种电能质量扰动类型各生成 300 个训练信号和 300 个测试信号。

按照本文 2.1 节所叙, 分别采用短时傅里列变换、小波变换、S 变换算法提取时频域特征、小波域特征、S 域特征, 并对上述特征归一化处理, 表达式如式(19)。

$$x = \frac{M - M_{\min}}{M_{\max} - M_{\min}} \quad (19)$$

式中: M_{\max} 、 M_{\min} 为原始最大、最小数据; M 为待处理数据。然后将归一化后各域的数据输入对应域的子神经网络, 以 DS 证据理论融合后得到最终的辨识结果。并将上述结果与传统基于单个域特征的辨识结果对比, 说明该方法的有效性。

2.1 提取的典型特征重叠性分析

基于单个域下的典型特征辨识可能因特征提取方法、噪声以及扰动间干扰的影响导致不同扰动的典型特征间边缘模糊, 进而影响最终识别的准确性。

2.1.1 特征提取方法的影响

由于各种特征提取方法本身都具有适用性, 使得提取出的扰动特征存在一定误差, 进而可能影响最终辨识的准确性。本文利用 STFT 从电压中断和电压暂降测试信号中提取用于辨识二者的两种典型特征即基频最大和最小值, 分布如图 2 所示, 从该图可以明显看出两种扰动的典型特征边界模糊, 主要是因为本文 STFT 选用的窗函数为 Blackman 函数, 主瓣宽度宽、时间分辨率低, 受窗宽影响, 当扰动持续时间较短时, 两者特征易出现混叠。

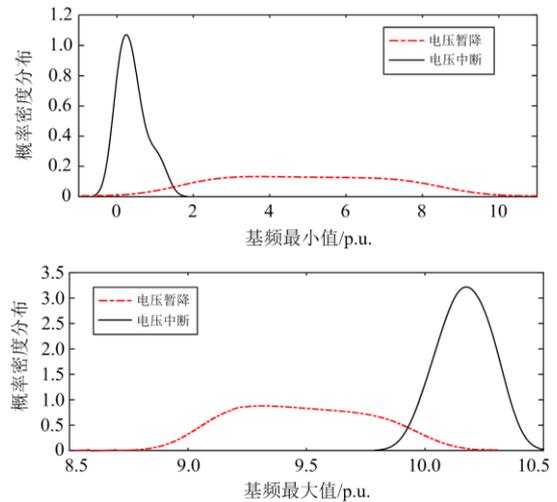


图 2 电压中断和电压暂降在时频域下两种特征分布

Fig. 2 Distribution of two features of voltage interruption and voltage sag in the time-frequency domain

2.1.2 噪声的影响

基于单个域的特征辨识电能质量扰动的正确率随噪声增大均有所降低, 其中基于小波域特征识别电能质量扰动对噪声尤为敏感。振荡瞬变和谐波的分类依据主要集中在高频段, 图 3 给出叠加 40 dB 噪声时, 利用小波变换提取用于辨识振荡瞬变和谐波的两种典型特征, 即 1 层归一化能量值和 2 层归一化能量值的分布, 易看出两类扰动的高频特征出现重叠, 主要是因为高噪声使小波系数大幅度减小, 当暂态的幅值和噪声的幅值接近时, 高频扰动特征易出现重叠。

2.1.3 扰动间干扰的影响

复合扰动并非各种单一扰动的线性叠加, 可能导致各域下的特征都发生改变。谐波作为稳态电能

质量问题,很有可能与其他电能质量扰动同时发生,因此本文利用S变换提取谐波及与谐波相关的2类复合扰动的典型特征,即基频幅值均值和高频幅值均值,分布如图4所示。从图4可以看出,三类扰动的典型特征间出现明显的混叠。

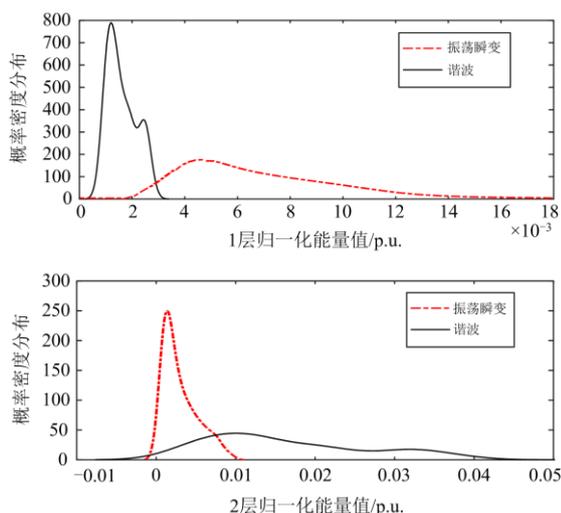


图3 叠加40 dB噪声时,振荡瞬变和谐波在小波域下两种特征分布情况

Fig. 3 Distribution of two features of transient oscillation and harmonics in the wavelet domain under 40 dB noise

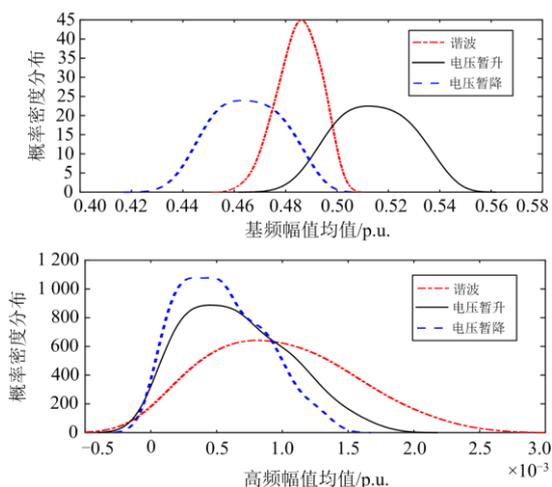


图4 三类电能质量扰动在S域两种特征的分布

Fig. 4 Distribution of two features of three types of power quality disturbances in the S domain

2.2 辨识结果对比和分析

2.2.1 辨识结果比较

在噪声干扰下,基于时频域特征、小波域特征、S域特征以及基于多域特征辨识各类电能质量扰动的结果和平均结果分别如图5和图6所示。

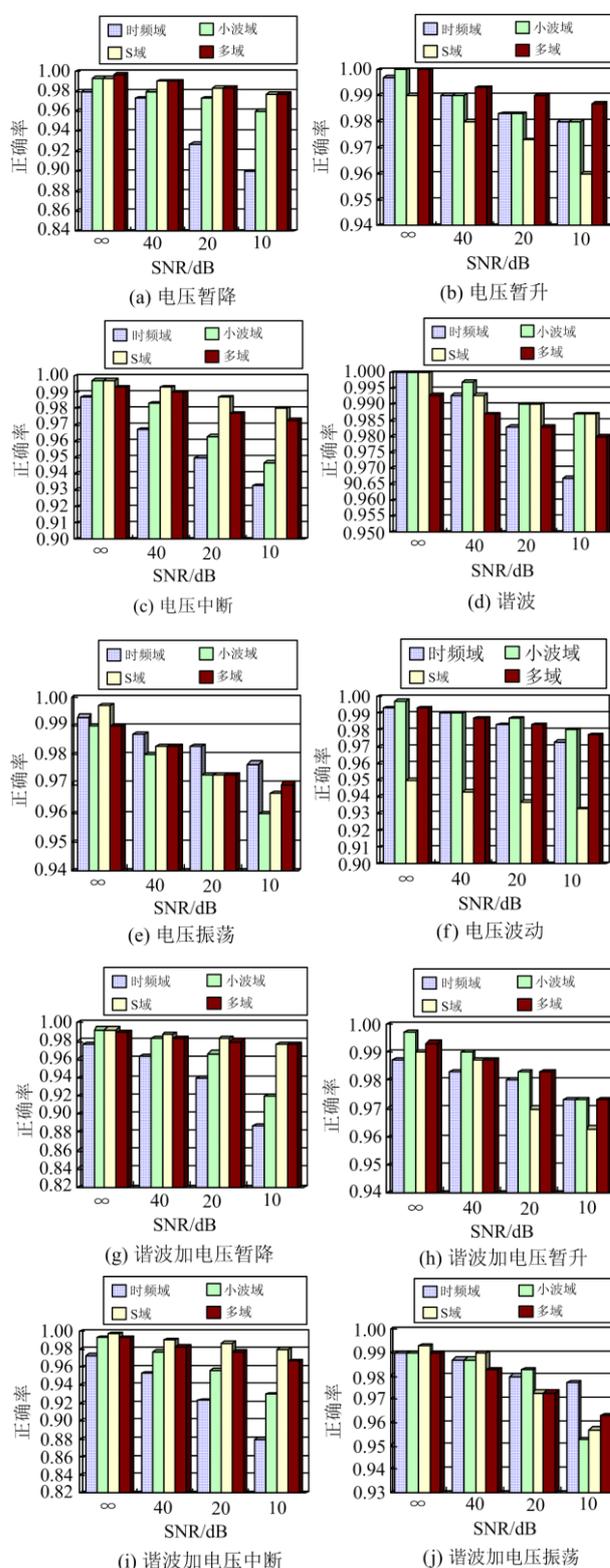


图5 4种辨识方法对各类电能质量扰动的辨识结果对比图

Fig. 5 Comparison of identification results of four kinds of methods for various power quality disturbance

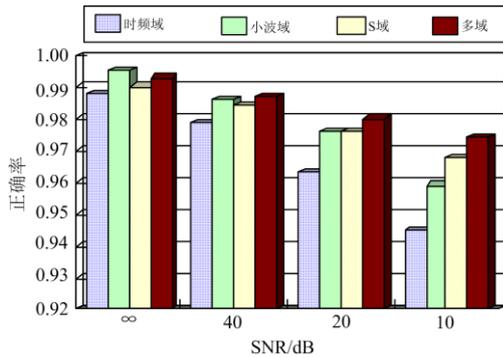


图 6 4种辨识方法对电能质量扰动的平均辨识结果对比图

Fig. 6 Comparison of average identification results of four kinds of methods for power quality disturbance

通过图 5 和图 6 中对比可知，基于单个域特征的辨识结果虽然均达到 90% 以上，但是受噪声的影响明显，且对个别单一扰动或复合扰动的识别效果不理想。相比之下，本文提出的方法对各种电能质量扰动的识别正确率都较高，且平均正确率优于基于单个域特征的辨识结果，而且受特征提取方法、噪声以及扰动间干扰的影响小，表现出了较高的鲁棒性。

应用本文所提出的面向多域特征的电能质量扰动辨识算法得到的识别结果如表 2 所示。

表 2 面向多域特征的电能质量扰动辨识结果

Table 2 Power quality disturbance identification results based on multiple domain features

扰动类型	无噪声	40 dB	20 dB	10 dB
电压暂升	100.0%	99.3%	99.0%	98.7%
电压暂降	99.7%	99.0%	98.3%	97.7%
电压中断	99.3%	99.0%	97.7%	97.3%
谐波	99.3%	98.7%	98.3%	98.0%
电压振荡	99.0%	98.3%	97.3%	97.0%
电压波动	99.3%	98.7%	98.3%	97.7%
谐波加电压暂降	99.0%	98.3%	98.0%	97.7%
谐波加电压暂升	99.3%	98.7%	98.3%	97.3%
谐波加电压中断	99.3%	98.3%	97.7%	96.7%
谐波加电压振荡	99.0%	98.3%	97.3%	96.3%
平均正确率	99.3%	98.7%	98.0%	97.4%

2.2.2 训练样本量的影响

不同样本量对本文提出的基于多域特征的电能质量扰动辨识正确率的影响如图 7 所示。由图 7 的结果可知每种扰动所提取的各个域训练样本数目达到 100 时，电能质量扰动的辨识结果已达到 97.2%，样本数目再增加，电能质量扰动的识别正确率变化不明显，说明本文提出的方法对小样本的识别效果较好。

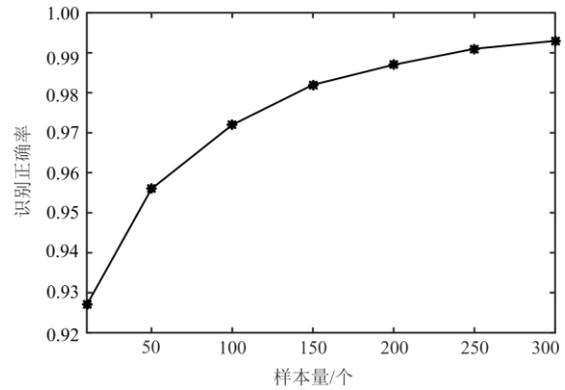


图 7 不同训练样本量下电能质量扰动平均识别结果对比

Fig. 7 Comparison of average identification results under different training sample quantity

3 结论

本文针对各种扰动所提取出的单个域下典型特征间因可能的边缘模糊而对辨识精度的影响，提出通过综合多域特征来辨识扰动，在初步训练和二次训练神经网络基础上，加以 DS 证据理论融合各域输出，以实现准确辨识，结论如下：

- 1) 通过对单个域典型特征的分析，发现特征提取方法、噪声以及扰动间干扰的影响均可能导致不同扰动单个域下典型特征间的边缘模糊。
- 2) 通过不同噪声强度、不同扰动类型下辨识结果的分析，验证了本文所提出的辨识方法在各种情况下均有较高的分类精度，受特征提取方法、噪声以及扰动间干扰的影响小，识别鲁棒性和抗噪性均较强。
- 3) 通过不同训练样本量下辨识结果的对比，证明了本文所提出的方法在样本较少的情况下，仍然得到了较好的分类结果。

参考文献

[1] 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.

[2] 庄双勇, 赵伟, 何学农, 等. 超谐波引发的电能质量问题及相关研究[J]. 电测与仪表, 2019, 56(1): 41-52. ZHUANG Shuangyong, ZHAO Wei, HE Xuenong, et al. Power quality problems caused by supraharmonics and related research[J]. Electrical Measurement & Instrumentation, 2019, 56(1): 41-52.

[3] 张楷, 邱晓燕, 李凌昊, 等. 含风电系统中计及静态电压稳定影响的储能系统配置方案[J]. 电力建设, 2020,

- 41(7): 110-116.
ZHANG Kai, QIU Xiaoyan, LI Linghao, et al. Energy storage configuration scheme considering the effect of static voltage stability in wind power systems[J]. *Electric Power Construction*, 2020, 41(7): 110-116.
- [4] 邓玉君, 周建萍, 茅大钧, 等. 基于 AFSA 的新型电力弹簧多目标电能质量优化控制[J]. *电力建设*, 2020, 41(2): 125-132.
DENG Yujun, ZHOU Jianping, MAO Dajun, et al. Multi-objective power quality optimization control of novel electric spring on the basis of AFSA[J]. *Electric Power Construction*, 2020, 41(2): 125-132.
- [5] 王红星, 刘军成, 李军, 等. 配电网电能质量监测数据简约方法探讨[J]. *电网与清洁能源*, 2020, 36(6): 8-12.
WANG Hongxing, LIU Juncheng, LI Jun, et al. Discussion of power quality data aggregation method used in distribution power grid[J]. *Power System and Clean Energy*, 2020, 36(6): 8-12.
- [6] 谢善益, 肖斐, 艾芊, 等. 多域分布式数据库的电能质量扰动事件记录关联规则挖掘[J]. *电网与清洁能源*, 2020, 36(5): 35-41.
XIE Shanyi, XIAO Fei, AI Qian, et al. Association rule mining of power quality disturbance event record in multi-domain distributed database[J]. *Power System and Clean Energy*, 2020, 36(5): 35-41.
- [7] 许立武, 李开成, 肖贤贵, 等. 基于深度前馈网络的电能质量复合扰动识别[J]. *电测与仪表*, 2020, 57(1): 62-69.
XU Liwu, LI Kaicheng, XIAO Xiangui, et al. Recognition of power quality complex disturbances based on deep feedforward network[J]. *Electrical Measurement & Instrumentation*, 2020, 57(1): 62-69.
- [8] 唐求, 王耀南, 郭斯羽, 等. 基于 S 变换与傅里叶变换的电能质量多扰动分类识别[J]. *湖南大学学报: 自然科学版*, 2009, 36(4): 38-42.
TANG Qiu, WANG Yaonan, GUO Siyu, et al. Power quality disturbance classification based on S transform and fourier transform[J]. *Journal of Hunan University: Natural Sciences*, 2009, 36(4): 38-42.
- [9] 覃思师, 刘前进. 基于 STFT 变换和 DAGSVMs 的电能质量扰动识别[J]. *电力系统保护与控制*, 2011, 39(1): 83-86.
QIN Sishi, LIU Qianjin. Power quality disturbances detection and identification based on STFT transform and DAGSVMs[J]. *Power System Protection and Control*, 2011, 39(1): 83-86.
- [10] 徐永海, 赵燕. 基于短时傅里叶变换的电能质量扰动识别与采用奇异值分解的扰动时间定位[J]. *电网技术*, 2011, 35(8): 174-180.
XU Yonghai, ZHAO Yan. Identification of power quality disturbance based on short-term fourier transform and disturbance time orientation by singular value decomposition[J]. *Power System Technology*, 2011, 35(8): 174-180.
- [11] 姚建刚, 郭知非, 陈锦攀. 基于小波和 BP 神经网络的电能扰动分类新方法[J]. *电网技术*, 2012, 36(5): 139-144.
YAO Jiangan, GUO Zhifei, CHEN Jinpan. A new approach to recognize power quality disturbances based on wavelet transform and BP neural network[J]. *Power System Technology*, 2012, 36(5): 139-144.
- [12] 秦英林, 田立军. 基于小波变换能量分布和神经网络的电能质量扰动分类[J]. *电力自动化设备*, 2009, 29(7): 64-66.
QIN Yinglin, TIAN Lijun. Classification of power quality disturbance based on wavelet energy distribution and neural network[J]. *Electric Power Automation Equipment*, 2009, 29(7): 64-66.
- [13] 肖桂雨, 向建平, 凌永志, 等. 基于小波神经网络的风力发电机故障预测方法[J]. *电力科学与技术学报*, 2019, 34(2): 195-201.
XIAO Guiyu, XIANG Jianping, LING Yongzhi, et al. Prediction of wind turbine faults based on wavelet neural networks[J]. *Journal of Electric Power Science And Technology*, 2019, 34(2): 195-201.
- [14] 谢善益, 肖斐, 艾芊, 等. 基于并行隐马尔科夫模型的电能质量扰动事件分类[J]. *电力系统保护与控制*, 2019, 47(2): 80-84.
XIE Shanyi, XIAO Fei, AI Qian, et al. Parallel hidden Markov model based classification of power quality disturbance events[J]. *Power System Protection and Control*, 2019, 47(2): 80-84.
- [15] 刘林, 林涛, 曹健. 基于可调窗复小波和专家系统的多重电能扰动识别[J]. *高电压技术*, 2009, 35(5): 1032-1037.
LIU Lin, LIN Tao, CAO Jian. Multiple power disturbance recognition based on complex-wavelet with adjustable window and expert system[J]. *High Voltage Engineering*, 2009, 35(5): 1032-1037.
- [16] 黄南天, 徐殿国, 刘晓胜. 基于 S 变换与 SVM 的电能质量复合扰动识别[J]. *电工技术学报*, 2011, 26(10): 23-30.
HUANG Nantian, XU Dianguo, LIU Xiaosheng. Identification of power quality complex disturbances based on S transform and SVM[J]. *Transactions of China Electrotechnical Society*, 2011, 26(10): 23-30.

- [17] 黄南天, 张卫辉, 蔡国伟, 等. 采用改进多分辨率快速 S 变换的电能质量扰动识别[J]. 电网技术, 2015, 39(5): 1412-1418.
HUANG Nantian, ZHANG Weihui, CAI Guowei, et al. Power quality disturbances classification with improved multiresolution fast S-transform[J]. Power System Technology, 2015, 39(5): 1412-1418.
- [18] 尹柏强, 何怡刚. 一种广义 S 变换及模糊 SOM 网络的电能质量多扰动检测和识别方法[J]. 中国电机工程学报, 2015, 35(4): 866-871.
YIN Baiqiang, HE Yigang. Detection and classification of power quality multi-disturbances based on generalized S-transform and fuzzy SOM neural network[J]. Proceedings of the CSEE, 2015, 35(4): 866-871.
- [19] 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.
- [20] 孙皓, 王鲁杨, 恽东军, 等. 基于改进的滑模频率偏移的孤岛检测方法[J]. 电力科学与技术学报, 2020, 35(4): 141-144.
SUN Hao, WANG Luyang, YUN Dongjun, et al. Improved slip mode frequency shift method based islanding detection[J]. Journal of Electric Power Science And Technology, 2020, 35(4): 141-144.
- [21] 赵凤展, 杨仁刚. 基于 S 变换和时域分析的电能质量扰动识别[J]. 电网技术, 2006, 30(15): 90-94.
ZHAO Fengzhan, YANG Rengang. Power quality disturbances classification based on S-transform and time domain analysis[J]. Power System Technology, 2006, 30(15): 90-94.
- [22] 张硕. 基于多分辨率 S 变换的电能质量扰动信号识别方法研究[D]. 吉林: 东北电力大学, 2020.
ZHANG Shuo. Research on power quality disturbance signal recognition method based on multiresolution S transform[D]. Jilin: Northeast Electric Power University, 2020.
- [23] 岳明道. 基于 S 变换和分类树的电网暂态电能质量扰动分类辨识[J]. 电力系统保护与控制, 2011, 39(9): 32-37.
YUE Mingdao. Transient power quality disturbance classification and identification in grid based on S transform and classification trees[J]. Power System Protection and Control, 2011, 39(9): 32-37.
- [24] 刘志刚, 张杨, 张桂南, 等. 一种基于时频域多特征量的电能质量混合扰动分类方法[J]. 中国电机工程学报, 2012, 32(34): 83-90.
LIU Zhigang, ZHANG Yang, ZHANG Guinan, et al. A new method for power quality mixed disturbance classification based on time-frequency domain multiple features[J]. Proceedings of the CSEE, 2012, 32(34): 83-90.
- [25] 赵燕. 电能质量扰动检测与识别方法研究[D]. 北京: 华北电力大学, 2011.
ZHAO Yan. The detection and recognition method of power quality disturbances[D]. Beijing: North China Electric Power University, 2011.
- [26] 杨剑锋, 姜爽, 石戈戈. 基于分段改进 S 变换的复合电能质量扰动识别[J]. 电力系统保护与控制, 2019, 47(9): 64-71.
YANG Jianfeng, JIANG Shuang, SHI Gege. Classification of composite power quality disturbances based on piecewise-modified S transform[J]. Power System Protection and Control, 2019, 47(9): 64-71.
- [27] ZHU T X, TSO S K, LO K L. Wavelet-based fuzzy reasoning approach to power-quality disturbance recognition[J]. IEEE Transactions on Power Delivery, 2004, 19(4): 1928-1935.
- [28] LI Ruisheng, WONG P, WANG Kun, et al. Power quality enhancement and engineering application with high permeability distributed photovoltaic access to low-voltage distribution networks in Australia[J]. Protection and Control of Modern Power Systems, 2020, 5(3): 183-189. DOI: 10.1186/s41601-020-00163-x.
- [29] 陈永延. 电力系统电能质量扰动识别方法研究[D]. 杭州: 浙江大学, 2010.
CHEN Yongyan. Research on classification of power quality disturbances[D]. Hangzhou: Zhejiang University, 2010.
- [30] 占勇, 程浩忠, 丁屹峰, 等. 基于 S 变换的电能质量扰动支持向量机分类识别[J]. 中国电机工程学报, 2005, 25(4): 51-56.
ZHAN Yong, CHENG Haozhong, DING Yifeng, et al. S-transform-based classification of power quality disturbance signals by support vector machines[J]. Proceedings of the CSEE, 2005, 25(4): 51-56.

收稿日期: 2021-01-21; 修回日期: 2021-05-13

作者简介:

张振宇(1989—), 男, 博士, 工程师, 研究方向为电力系统及其自动化。E-mail: 823976250@qq.com

(编辑 葛艳娜)