Vol.42 No.1 Jan. 2022

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

伊慧娟1,高云鹏1,2,朱彦卿1,黄 瑞1,2,3,黄 纯1

 (1. 湖南大学 电气与信息工程学院,湖南 长沙 410082;2. 智能电气量测与应用技术湖南省重点实验室, 湖南 长沙 410004;3. 国网湖南省电力有限公司,湖南 长沙 410004)

摘要:针对电能质量复合扰动识别中特征提取效率低、分类器识别能力与学习速度无法同步提高的问题,提 出一种基于自适应窗不完全S变换与留一交叉验证优化的核极限学习机(LOO-KELM)算法的复合电能质量 扰动识别方法。首先根据选定的主频率点自适应调节S变换窗宽系数,提取具有高时频分辨率的59种电能 质量(PQ)特征,再通过留一交叉验证寻找最小预测残差平方和,实现核极限学习机的输出权重优化,最后根 据提取PQ特征集与优化后的核极限学习机实现复合扰动的识别与分类。仿真和实测结果表明,所提方法对 不同噪声下的16类混合电能质量扰动均具有较高的分类精度,相较于现有复合电能质量识别方法,分类精 度更高且训练时间更短。

0 引言

近年来,随着光伏、风力发电等新能源分布式电 源并网行为的增加,新型电力电子器件与设备不断 接入,引起大量复杂且次数频繁的稳态与暂态电能 质量扰动,此类复合电能质量扰动(下文简称复合扰 动)的特征混叠严重,相对于单一电能质量扰动(下 文简称单一扰动)识别,复合扰动识别对特征提取与 分类器选择的要求更高,因此如何针对复合扰动的 特点进行准确、高效的复合扰动识别成为当前电能 质量扰动分类研究的重要课题^[1]。

复合扰动识别主要包括特征提取与模式识别2 个步骤。特征提取需对信号进行时频域分析,常用 的方法有傅里叶变换^[2]、小波变换^[3]、S变换^[4]等,其 中S变换结合傅里叶变换与连续小波变换的优点, 引入窗宽可调的高斯窗函数,在时、频域均具有分析 能力,在单一扰动特征法的提取中得到了广泛应用, 但当前智能电网环境下存在较多单一扰动叠加的复 合扰动,对S变换的时频域分辨率及特征提取效率 的要求更高。文献[5-6]通过S变换获得具有高时 频分辨率的复合扰动时频特征,但在不完全S变换 中,实现高时频分辨率的窗宽因子需通过大量实验

收稿日期:2020-08-07;修回日期:2021-06-11

基金项目:国家自然科学基金资助项目(51777061);长沙市重 点研发计划项目(kq1901029);国家重点实验室开放基金研 究项目(BGRIMM-KZSKL-2020-09)

Project supported by the National Natural Science Foundation of China(51777061), the Key R & D Projects in Changsha (kq1901029) and the Open Foundation of State Key Laboratory(BGRIMM-KZSKL-2020-09)

进行确定,特征提取效率低、成本高。复合扰动模式 识别方法主要包括专家系统[7]、人工神经网络、支持 向量机[8]、决策树[9]、深度学习[10]、极限学习机等,其 中专家系统分类器过度依赖先验知识;人工神经网络 分类的过程为"黑盒",训练时间长;支持向量机计算 速度快,但需解决核参数优化选择问题;决策树的分 类精度较高,但需对参数进行调节,易出现过拟合的 问题;深度学习的分类精度高但需大量样本且训练 时间过长,上述分类器均存在难以实现训练时间与 测试精度同步提高的问题。随着复合扰动在电能质 量扰动中占比的增加,研究快速、准确性高、专家依 赖度低且参数设置简单的分类器在工程应用中逐渐 得到重视。核极限学习机 KELM^[11](Kernel Extreme Learning Machine)为前向传播神经网络,其输入层 与隐含层间的连接权值直接被设定且在后期训练过 程中无需调整,在大幅提高了算法效率的同时,保证 了较高的识别精度。目前已有研究通过粒子群优化 PSO(Particle Swarm Optimization)算法^[12]等对 KELM 的正则化参数进行优化,但均以分类器准确度作为 适应度函数,优化过程复杂冗长。

针对上述问题,本文首先利用基于特定选择频率的自适应窗宽因子改进不完全S变换(简称自适应不完全S变换),得到高时频分辨率的复合扰动特征集,再通过基于预测残差平方和的留一交叉验证LOO(Leave-One-Out cross validation)法得到KELM的正则化参数,据此建立基于自适应不完全S变换与LOO-KELM算法的高效复合扰动特征提取与识别方法,最后通过大量仿真和实测数据验证本文所提方法的有效性和准确性。

1 基于自适应不完全S变换的特征提取

200

S变换采用窗宽与窗高可随频率自动调节的高 斯窗函数,在时频域对信号进行分解。复合扰动信 号为离散信号*x*(*n*),因此采用离散S变换进行信号 分析,其表达式为:

$$S(iT, n/(NT)) = \begin{cases} \sum_{m=0}^{N-1} F\left(\frac{m+n}{NT}\right) W_{GS}(m, n) e^{j2\pi m i N} & n \neq 0\\ \frac{1}{N} \sum_{m=0}^{N-1} F\left(\frac{m}{NT}\right) & n = 0 \end{cases}$$

(1)
=
$$\sum_{n=1}^{N-1} x(n) e^{-2\pi k n i/N}$$
 (2)

式中:T为采样时间间隔;N为采样点个数;k, i, m, n=0,1,…,N-1; $W_{cs}(m, n)$ 为高斯窗函数。

为提高扰动信号的时频分辨率,引入含窗宽因 子的高斯窗函数如式(3)所示。

$$W_{\rm GS}(m,n) = e^{-2\pi^2 m^2 \sigma_j / n^2}$$
 (3)

$$\boldsymbol{\tau}_f = a_0 - a_1 \cos(wf) - b_1 \sin(wf) \tag{4}$$

式中: σ_f 为高斯窗的窗宽调节因子: a_0 、 a_1 、 b_1 、w为常数; f为频率。

复合扰动可解耦至低、中、高3个频段,且主要 集中在几个特定频率处,因此在特定频率处采用不 完全S变换,可显著降低S变换矩阵的获取时间。结 合电能质量扰动的定义与扰动信号的快速傅里叶变 换FFT(Fast Fourier Transform)结果可知,暂降、暂 升、中断、闪变对电压幅值造成的影响较大,但电压 频率基本不受影响,因此对上述扰动在50 Hz处进 行频域特征提取;谐波主要包括3、5、7、9次奇次频 率成分,其他频率点的谐波幅值基本为0;由振荡信 号的定义可知,其信号中心频率集中在300~900 Hz, 通过FFT可知其频域中心点与250、350、450、550、 650、750、850、950 Hz接近,为快速得到信号在频域 的特征,选择以上相近频率点作为特征频率点。

对上述不同频率段的多个电能质量扰动信号进行分解,调整窗宽因子使分解结果具有较高的时频分辨率,由多次实验确定的不完全S变换的*σ*,计算式为:

 $\sigma_f = 9.7 - 9.5 \cos(0.15f) - 1.95 \sin(0.15f) \quad (5)$

在选取的分解频率下,由式(5)得到的不完全S 变换的窗宽因子见附录A表A1。由表可知,在不完 全S变换的特征提取中,只需设定好进行分析的频 率位置,利用式(5)得到的窗宽因子即可动态调整高 斯窗函数,由此得到具有高时频分辨率的扰动特征。

暂降+谐波信号和暂降+振荡信号这2种复合扰 动信号的FFT结果分别如图1(a)、(b)和图2(a)、(b) 所示,对应的自适应不完全S变换时频分析结果分 别如图1(c)和图2(c)所示。

由图1(a)可见,暂降+谐波信号在时域呈现明



图1 暂降+谐波信号的FFT结果和自适应不完全S 变换结果

Fig.1 FFT and self-adaptive incomplete S transform results of sag+harmonic signal



图 2 暂降+振荡信号的FFT结果和自适应不完全 S 变换结果

Fig.2 FFT and self-adaptive incomplete S transform results of sag+oscillation signal

显的电压降落现象;由图1(b)可见,FFT频域幅值 曲线的最高峰在50Hz处,该复合扰动信号中除了 基频外还包含3、5、7次谐波,频率成分主要为50、 150、250、350 Hz,结合图1(c)可知,自适应不完全S 变换和FFT得到的频域分析结果相同。由图2(a)可 见,暂降+振荡信号在时域的电压降落较为明显;由 图2(b)可见,信号包含50 Hz的基频与振荡中心为 440 Hz的高频;由图2(c)可见,频率50 Hz处为时频 幅值曲线的最高峰,即信号频率成分主要为基频;时 频幅值曲线的太高峰出现在450 Hz,即信号除基频 外还包含部分高频成分,与图2(b)中的结果基本吻 合。综上所述,本文提出的自适应不完全S变换对 各个频段的电能质量扰动信号均具有良好的时频分 辨率,可有效提取频域信息。将进行不完全S变换 后的幅值矩阵记为*T*_s,根据*T*_s的行、列向量构建电能 质量特征^[13],最终得到的59种电能质量特征值见附 录A表A2。

2 LOO-KELM 算法

2.1 KELM

极限学习机ELM(Extreme Learning Machine)是一种基于单向前馈神经网络架构的新型快速学习算法,其隐藏层的节点参数在给定的随机范围内初始化,无需进行复杂的参数调整计算。KELM^[14]是ELM的新型改进方法,需要设置的参数更少,无需提前设置隐藏节点,涉及的核参数为随机产生,训练速度快且泛化能力更强。KELM分类器可在保证分类精度的情况下,实现复合扰动模式的快速识别。

给定复合扰动样本数量为Z、扰动模式总数为 M的复合扰动训练样本集 (x_i, t_i) ,其中 x_i 为进行学习 的特征数据集, t_i 为特征数据集对应的分类标签,i=1,2,…,Z。设置 ELM 网络的隐藏节点数为u,选用 的激活函数为s(x),其输出结果可表示为:

$$f_{\text{outputi}} = \sum_{j=1}^{a} \beta_{j} s(w_{j} x_{i} + b_{j}) \quad i = 1, 2, \cdots, Z$$
 (6)

式中: $f_{outputi}$ 为第i个样本经过ELM网络的输出值; β_j 、 w_j 分别为第j个隐藏节点与输出、输入节点之间的权重; b_i 为第i个隐藏节点的偏置。

KELM 在 ELM 的基础上定义的核矩阵 Ω_{ELM} 为:

$$\boldsymbol{\Omega}_{\text{ELM}} = \boldsymbol{H}\boldsymbol{H}^{\mathrm{T}} \tag{7}$$

$$\boldsymbol{H} = [\boldsymbol{h}(x_1) \boldsymbol{h}(x_2) \cdots \boldsymbol{h}(x_N)]^{\mathrm{T}}$$

式中:H为隐藏层的输出矩阵; $h(x_i)$ 为 x_i 经隐含层输出的行向量。

核矩阵内的元素 $\Omega_{\text{ELM}}(i,j)$ 的计算表达式为:

$$\Omega_{\text{ELM}}(i,j) = \boldsymbol{h}(x_i)\boldsymbol{h}(x_j) = K(x_i,x_j)$$
(8)

式中: $K(\cdot)$ 为核函数。本文选用径向基函数 RBF (Radial Basis Function)核作为 KELM 的核函数,其 表达式如式(9)所示。

$$K(x_i, x_j) = \exp\left(-\gamma \left| x_i - x_j \right| \right)$$
(9)

式中:γ为RBF核参数。

KELM算法的输出函数为:

 $f'_{output}(x) = h(x)\beta = h(x)H^{T}(HH^{T} + I/C)^{-1}T$ (10) 式中: β 为输出权值; I 为单位矩阵; C 为正则化系数。

将式(8)代入式(10),可得 KELM 的输出函数表 达式为:

$$\boldsymbol{f}_{\text{output}}'(\boldsymbol{x}) = \begin{bmatrix} \boldsymbol{K}(\boldsymbol{x}, \boldsymbol{x}_{1}) \\ \boldsymbol{K}(\boldsymbol{x}, \boldsymbol{x}_{2}) \\ \vdots \\ \boldsymbol{K}(\boldsymbol{x}, \boldsymbol{x}_{N}) \end{bmatrix}^{\mathrm{T}} (\boldsymbol{I}/\boldsymbol{C} + \boldsymbol{\Omega}_{\text{ELM}})^{-1} \boldsymbol{T} \qquad (11)$$

式中:T为分类标签组成的矩阵。

由此可知,KELM 通过加入正则化系数平衡训 练误差项与正则化项,从而提高复合扰动分类结果 的稳定性。

2.2 改进LOO法

LOO法是常见的交叉验证法,其将样本数据集 划分为2个子集,其中一个子集为验证集,仅包含1 个样本,用于模型的泛化误差验证;另一个子集为训 练集,用于模型的训练。样本数据集的划分一直持 续到每个样本均作为验证集进行误差验证为止,得 到各个留一验证集的平均泛化误差,泛化误差越小 则分类器的实际分类性能越好。通过LOO法优化 KELM分类器的参数,可进一步提高电能质量扰动 模式识别精度(下文简称扰动模式识别精度)。对于 包含Y个样本的复合扰动训练集,利用其中的Y-1 个样本进行训练,剩余的1个样本用于对训练模型 进行泛化性能评估。通过统计量预测残差平方和 PRESS(Predicted Residual Error Sum of Squares)线 性模型代替多重重复训练模型,降低 KELM 分类器 中正则化系数计算的复杂度,从而以较低的时间成 本提高扰动模式识别精度。

基于均方误差 MSE(Mean Square Error)的 PRESS 计算公式为:

$$\lambda_{\text{MSE}}^{\text{PRESS}} = \frac{1}{Y} \sum_{i=1}^{N} v_{\text{erri}} = \frac{1}{Y} \sum_{i=1}^{N} f_{\text{err}} \left(f'_{\text{outputi}} - t_i \right) = \frac{1}{Y} \sum_{i=1}^{N} \left(\frac{f'_{\text{outputi}} - t_i}{1 - H_{ii}^{\text{NEW}}} \right)^2$$
(12)

 $\boldsymbol{H}^{\text{NEW}} = \boldsymbol{H}\boldsymbol{H}^{+} = \boldsymbol{H}\left(\boldsymbol{H}^{\text{T}}\boldsymbol{H} + \boldsymbol{I}/\boldsymbol{C}\right)^{-1}\boldsymbol{H}^{\text{T}} \qquad (13)$

式中:H^{NEW}为矩阵H^{NEW}对角线上的第*i*个元素值;v_{erri}为第*i*个样本数据与其标签的预测残差平方值;f'_{outfiti}为第*i*个样本经过KELM网络后的输出值;f_{err}(·)为PRESS计算函数。

将式(7)代入式(13),可得KELM的H^{NEW}为:

$$\boldsymbol{H}^{\text{NEW}} = \boldsymbol{\Omega}_{\text{ELM}} \left(\boldsymbol{\Omega}_{\text{ELM}} + \boldsymbol{I}/\boldsymbol{C} \right)^{-1}$$
(14)

传统的LOO法在优化正则化系数C时,需要对 KELM进行Y次重复训练,其计算复杂度为 $O(Y^2)$, 本文通过预测残差平方和的线性模型代替原始的 LOO模型,只需一次性计算出 Ω_{ELM} 与(Ω_{ELM} +I/C)⁻¹, 即可以通过式(11)、(12)、(14)计算得到验证误差值, 避免了 Y次 KELM 的训练过程,计算复杂度降低至 O(Y)。由此可见,改进的LOO法大幅缩短了 KELM 分类器的优化时间,在提高扰动模式识别精度的同 时,减少了优化过程引起的时间成本,实现了高效准 确的复合扰动识别。为便于说明,下文将经改进LOO 法优化的KELM分类器简称为LOO-KELM分类器。

3 复合扰动识别流程

202

通过自适应不完全S变换提取复合扰动波形的 时频域特征,构建复合扰动特征矩阵,通过求解 PRESS降低LOO法的复杂度,从而快速优化KELM 分类器的正则化系数C。基于自适应不完全S变换 与LOO-KELM算法的复合扰动识别流程如下。

1)通过复合扰动的数学模型产生样本数量为Z 的数据集(x_i,t_i)(*i*=1,2,…,Z),通过自适应不完全S 变换对数据集进行特征提取。

2)将得到的特征数据集按需求分为训练集与测 试集,并对样本进行乱序处理,同时将每个样本对应 的分类标签进行离散化表示,初始化正则化系数序 列,序列长度为L,序列中各元素均在[C_{min},C_{max}]范围 内,C(p)为序列中第p个元素,p=1,2,…,L,且p初 始化为1。

3)将C(p)代入式(11),从而得到KELM的输出 值 f'_{output} ,通过重复利用核矩阵 Ω_{ELM} 提高改进的LOO 法的效率,优化的LOO法的目标函数即为式(12)。

4)若迭代次数小于L,则令p=p+1,然后返回步骤3),继续进行迭代寻优;若迭代次数达到L,则迭代结束,转至步骤5)。

5)以最小化目标函数式(12)为目的,得到最优 正则化系数 C_{opt} ,最终得到LOO-KELM算法的最优输 出权重 β_{opt} 为:

$$\boldsymbol{\beta}_{\text{opt}} = (\boldsymbol{\Omega}_{\text{ELM}} + \boldsymbol{I}/\boldsymbol{C}_{\text{opt}})^{-1}\boldsymbol{T}$$
(15)

6)将自适应不完全S变换的提取特征输入 LOO-KELM分类器中,得到复合扰动的分类结果。本 步骤中KELM分类器通过寻找输出矩阵中的最大值 确定扰动所属类别,该最大值可直接反映分类器的 最大决策边界,而样本输出矩阵中的最大值 $f'_{output, max}$ 与次大值 $f'_{output, smax}$ 之差 $T_{diff}=f'_{output, smax}$ 可反映 决策边界优劣程度,且 T_{diff} 值越大,分类器的决策边 界越好,分类精度越高,因此可通过 T_{diff} 值来判断 KELM分类器对复合扰动的分类效果。

经过改进LOO法优化前、后的KELM分类器的 *T*_{diff}值如附录A图A1所示。由图可知,优化前, KELM分类器的*T*_{diff}值主要分布在(0,1.8)范围内,优 化后,KELM分类器的*T*_{diff}值呈现集中分布的特性, 且主要分布在(1.8,2.5)范围内,可见经过改进LOO 法优化后的KELM分类器具有较大的*T*_{diff}值,即具有 相对较优的决策边界。

4 算例仿真

4.1 仿真模型与样本建立

为验证 LOO-KELM 算法的鲁棒性与准确性,根 据 IEEE Std 1159-2019^[15]标准对各种电能质量扰 动模式的定义构建电能质量扰动信号的数学模型, 通过MATLAB仿真实验生成参数随机且信噪比SNR (Signal Noise Ratio)分别为20、30、40、50 dB的正常 信号(D₁)和16种电能质量扰动信号。其中,电能质 量扰动信号包括电压暂降(D₂)、电压暂升(D₃)、电压 中断(D₄)、暂态振荡(D₅)、电压切口(D₆)、电压尖峰 (D_7) 、闪变 (D_8) 、谐波 (D_0) 、暂降+谐波 (D_{10}) 、暂升+谐 波(D₁₁)、闪变+谐波(D₁₂)、中断+谐波(D₁₃)、暂降+闪 变(D₁₄)、暂升+闪变(D₁₅)、暂降+振荡(D₁₆)、暂升+振 荡(D₁₇),复合扰动信号的数学模型见附录A表A3。 将信号的采样频率、采样点数分别设置为6400 Hz、 1280。每种信号包含200组数据,共3400组数据, 其中2500组用于分类模型训练,剩余900组用于模 型测试,并对原本相同模式扰动信号聚类在一起的 数据集进行乱序处理,将单一扰动与复合扰动信号 随机混合后进行分类实验。

4.2 基于LOO-KELM算法的复合扰动模式识别

由仿真得到 2 500 组混合扰动信号对 LOO-KELM 分类器进行训练,正则化系数 C 的寻优结果 如图 3 所示。



图3 正则化参数的寻优结果

Fig.3 Optimization results of regularization parameter

由图 3 可见, λ_{MSE}^{PRESS}的最小值为0.8896, 对应的最 优正则化系数 C_{opt}=0.027 32, 从而可得到 LOO-KELM 算法的最优输出权重, 通过此权重构建最优 LOO-KELM 分类器。

分别对信噪比 20、30、40、50 dB下的复合扰动 数据集进行训练与测试,得到最优 LOO-KELM 分类 器对 17种信号的识别精度如表 1 所示。表中,r为信 噪比。

由表1可知,LOO-KELM分类器对单一扰动模式,如谐波、闪变、暂态振荡均具有高抗噪能力与高识别精度,因此当这3种单一扰动叠加电压暂升、电压暂降形成复合扰动时,LOO-KELM分类器对其仍具有良好的识别精度;LOO-KELM分类器在不同信噪比下对暂升+谐波、闪变+谐波、中断+谐波这3种复

表1 不同信噪比下的最优LOO-KELM分类器对 信号的识别精度

 Table 1
 Signal recognition accuracy of optimal

 LOO-KELM
 classifier
 under different
 SNRs

扰动	扰动	识别精度 / %			
类型	模式	r = 20 dB	r = 30 dB	r=40 dB	r=50 dB
	正常	98.00	100	100	100
	电压暂降	89.80	96.00	96.55	92.00
	电压暂升	94.34	96.23	95.31	98.31
	电压中断	96.36	97.96	86.84	95.65
单一	暂态振荡	98.53	100.00	97.87	100
	电压切口	74.07	86.96	100	90.74
	电压尖峰	72.13	84.13	90.00	94.00
	闪变	100	100	100	100
	谐波	100	100	100	100
	暂降+谐波	93.33	96.36	91.67	97.78
复合	暂升+谐波	100	100	100	100
	闪变+谐波	100	100	100	100
	中断+谐波	100	100	100	100
	暂降+闪变	92.98	98.31	95.65	96.72
	暂升+闪变	91.67	90.91	98.18	98.04
	暂降+振荡	90.74	96.30	98.36	96.00
	暂升+振荡	95.83	93.33	100	100
平均识别精度 / %		93.11	96.22	97.33	97.67

合扰动模式的识别精度均达了100%,对暂降+振荡 扰动在20dB信噪比下的识别精度为90.74%。综上 所述,LOO-KELM分类器在不同信噪比下对复合扰 动模式的识别精度均能保持在90%以上:除电压切 口、电压尖峰与电压暂降模式外,LOO-KELM分类器 对其他电能质量扰动模式的识别精度在20 dB的信 噪比下均可达90%以上,这是因为高噪声环境造成 的电压切口、电压尖峰扰动信号失真严重,从而对扰 动模式识别精度产生了较大的影响,但在实际情况 下,电压切口与尖峰出现的频率较低;在40 dB 及以 上信噪比的噪声环境中,LOO-KELM分类器对正常 信号和16种电能质量扰动信号的平均识别精度可以 达到97%以上,在低信噪比的环境中,平均识别精 度也可达到93%以上。由此可见,LOO-KELM分类 器在不同信噪比下均具有良好的分类精度和抗噪 性能。

4.3 与常用复合扰动模式识别方法的对比

在 20~50 dB 的信噪比环境下,对比支持向量机 SVM(Support Vector Machine)、KELM、PSO 算法改 进的 KELM(PSO-KELM)、遗传算法改进的 KELM (GA-KELM)及本文方法对包含单一扰动与复合扰 动的复杂混合扰动的识别效果,各算法的平均训 练时间 t_r 和平均扰动模式识别精度 r_{mer} 如图4所示。

由图4中的上图可见,基于KELM方法的平均训练时间基本不受噪声因素的干扰,其中PSO-KELM、GA-KELM方法的平均训练时间在300s附近波动,而本文方法的平均训练时间在10s附近小范围浮动,与PSO-KELM、GA-KELM方法的平均训练时间



图4 不同信噪比下各方法的平均训练时间和平均 扰动模式识别精度对比

Fig.4 Comparison of average training time and average disturbance mode recognition accuracy among different methods under different SNRs

相比降低了97%,且基本不受叠加噪声的影响。

由图4中的下图可见,与其他方法相比,本文方 法在各种信噪比下的平均扰动模式识别精度均在 90%以上,在平均训练时间显著降低的情况下仍可 达到96.1%;在20dB的低信噪比下,本文方法可保 持93.6%的平均扰动模式识别精度,而KELM与 SVM方法的平均扰动模式识别精度只能达到82.3%, PSO-KELM与GA-KELM方法的平均扰动模式识别 精度也未超过90%。

综上所述,本文方法在不同信噪比下均具有较高的平均扰动模式识别精度,且精度变化幅度最小, 尤其在低信噪比条件下展现出良好的抗噪能力与鲁 棒性,实现了分类精度与学习速度的同步提高。

5 实测信号分析

为验证本文方法对实测信号的有效性,利用本 文方法对广东某电网2020年5月的实测混合扰动信 号进行扰动分类。实测信号的采样频率为6.4 kHz, 广东某电网2020年5月11日发生暂降+振荡的扰动 事件时,三相电压实际波形的PQDiffractor显示见附 录A图A2。对实测信号进行自适应不完全S变换, 得到的幅值、频率信息如附录A表A4所示,表中同 时给出了实际扰动事件发生时实测信号本身的幅 值、频率信息作为对比。由表可见,自适应不完全S 变换可以在除振荡之外的扰动发生时100%准确提 取实测信号的所有频率成分,对于发生振荡时的实 测信号可提取到与实际振荡中心最相近的特定频率 450 Hz处的特征信息。

实测信号数据集由1000组训练集与600组测 试集组成,共包含10类扰动事件。利用本文方法 对实测扰动信号数据集进行扰动模式识别,结果 见表2。

表2 对实测信号数据集的扰动事件识别结果

Table 2 Disturbance mode recognition accuracy of identification results of actual signal data set

扰动模式	编号	扰动模式识别精度 / %
暂升	D_3	95.89
中断	D_4	100
暂降	D_2	100
谐波	D_9	100
振荡	D_5	92.55
脉冲	$D_6(D_7)$	87.50
闪变	D_8	100
暂降+谐波	D_{10}	100
暂升+谐波	D_{11}	100
暂降+振荡	D_{16}	100
平均扰动模式识	【别精度 / %	97.59

由表2可见,本文方法对实际扰动事件的平均 扰动模式识别精度达97.59%,对实测信号数据集中 的暂降+谐波、暂升+谐波、暂降+振荡这3类复合扰 动模式的识别精度达100%,且通过实测数据进行 模型训练的时间仅为12.156s。由此可知本文方法 可快速实现电网的复合扰动模式的精确识别,在实 际电网环境下具有良好的复合扰动识别效果。

6 结论

本文提出了一种基于自适应不完全S变换与 LOO-KELM算法的复合扰动识别方法,通过仿真与 实测信号分析结果可得到以下结论:

1)本文方法可对多个选定变换主频率点的窗宽 因子进行自适应设置,大幅降低了特征提取时间,同 时保证了特征在时频域的分辨率;

2)本文方法对 KELM 的输出权重进行优化,在 各种噪声环境下均能得到较高的扰动模式识别精 度,对实测数据的平均扰动模式识别精度可达到 97%以上;

3)与其他复合扰动模式识别方法相比,本文方 法的计算复杂度低、训练时间短、扰动模式识别精 度,且具有良好的抗噪性。

本文方法的不足在于当信号处于高噪声环境中时,电压尖峰与电压切口这2类扰动模式的信号失真 较为严重,因此其扰动模式识别精度会受影响,后续 工作需进一步提升高噪声下全扰动模式识别精度。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

- [1] MAHELA O P, SHAIK A G, GUPTA N. A critical review of detection and classification of power quality events [J]. Renewable and Sustainable Energy Reviews, 2015, 41:495-505.
- [2]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.

- [3] 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.
- [4]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.
- [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] BISWAL M, DASH P K. Detection and characterization of multiple power quality disturbances with a fast S-transform and decision tree based classifier[J]. Digital Signal Processing, 2013,23(4):1071-1083.
- [7] 王志群,朱守真,周双喜. 电能质量扰动的专家概率分类器模型[J]. 电力系统自动化,2004,28(8):45-49,56.
 WANG Zhiqun,ZHU Shouzhen,ZHOU Shuangxi. Expert probability classification for power quality disturbances[J]. Automation of Electric Power Systems,2004,28(8):45-49,56.
- [8] 秦业,袁海文,袁海斌,等.基于优化最小二乘支持向量机的电 能质量扰动分类[J].电工技术学报,2012,27(8):209-214.
 QIN Ye,YUAN Haiwen,YUAN Haibin, et al. Classification of power quality disturbances based on optimized least squares support vector machine[J]. Transactions of China Electrotechnical Society,2012,27(8):209-214.
- [9] 张春宁,陈红坤,黄绢,等. 基于S变换和决策树算法的电能 质量扰动识别[J]. 武汉大学学报(工学版),2010,43(6):800-804,808.

ZHANG Chunning, CHEN Hongkun, HUANG Juan, et al. Electricity quality disturbance identification method based on Stockwell-transform and decision tree[J]. Engineering Journal of Wuhan University, 2010, 43(6):800-804, 808.

[10] 屈相帅,段斌,尹桥宣,等.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[J].电力自动化设备,2019,39(5): 157-162.

QU Xiangshuai, DUAN Bin, YIN Qiaoxuan, et al. Classification method of power quality disturbances based on deep neural network of sparse auto-encoder[J]. Electric Power Automation Equipment, 2019, 39(5); 157-162.

- [11] HUANG Ghuangbin, ZHU Qinyu, SIEW C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70 (1):489-501.
- [12] 韩刚,张建文,褚鑫,等. 多特征组合及优化SVM的电能质量 扰动识别[J]. 电力系统及其自动化学报,2015,27(8):71-76,81.
 HAN Gang,ZHANG Jianwen,CHU Xin, et al. Power quality disturbance classification based on multi-features combination

and optimizing parameters of SVM[J]. Proceedings of the CSU-EPSA, 2015, 27(8):71-76, 81.

- [13] SINGH U, SINGH S N. Optimal feature selection via NSGA-II for power quality disturbances classification[J]. IEEE Transactions on Industrial Informatics, 2018, 14(7): 2994-3002.
- [14] HUANG Guangbin. An insight into extreme learning machines: random neurons, random features and kernels[J]. Cognitive Computation, 2014, 6(3): 376-390.
- [15] IEEE. IEEE recommended practice for monitoring electric power quality: IEEE Std 1159-2019[S]. New York, USA: IEEE, 2019.

作者简介:

伊慧娟(1995—), 女, 山西大同人, 硕士研究生, 研究方向为电能质量扰动的分析与检测、机器学习及其优化方法在复合电能质量扰动识别中的应用(E-mail: yihuijuan@hnu.edu.cn);



高云鹏(1978—),男,辽宁营口人,教 授,博士研究生导师,通信作者,主要研究方 向为电能质量分析、智能信息处理(E-mail: gfront@126.com);

朱彦卿(1978—),男,湖南醴陵人,副 教授,博士,主要研究方向为电能质量分析 与控制、机器学习及其优化方法在复合电能 质量扰动识别中的应用(E-mail:zyq@hnu. edu.cn):

伊慧娟

黄 瑞(1989—),男,湖南常德人,高级工程师,博士,主 要研究方向为用电采集系统通信技术(E-mail:218117051@qq. com);

黄 纯(1966—),男,湖南长沙人,教授,博士研究生导师,研究方向为电能质量分析与控制(E-mail:yellowpure@hotmail.com)。

(编辑 任思思)

Recognition of composite power quality disturbance based on improved incomplete S transform and LOO-KELM algorithm

YI Huijuan¹, GAO Yunpeng^{1,2}, ZHU Yanqing¹, HUANG Rui^{1,2,3}, HUANG Chun¹

(1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China;

2. Hunan Province Key Laboratory of Intelligent Electrical Measurement and Application Technology,

Changsha 410004, China;

3. State Grid Hunan Electric Power Company Limited, Changsha 410004, China)

Abstract: In order to solve the problems of low efficiency of feature extraction, and inability of classifier recognition and learning speed in composite power quality disturbance classification, a composite power quality disturbance recognition method based on incomplete S transformation of adaptive window and LOO-KELM (Kernel Extreme Learning Machine optimized by Leave-One-Out cross validation) algorithm is proposed. Firstly, the window width coefficient of S transform is adaptively adjusted according to the selected main frequency, 59 kinds of PQ(Power Quality) characteristics with high time-frequency resolution are extracted. Then through LOO, the minimum prediction residual sum of squares is obtained for the kernel extreme learning machine output weight optimization. According to the extraction of PQ feature set and the optimized kernel extreme learning machine, the identification and classification of compound disturbance are realized. Results of simulation and measurement show that the proposed method has higher classification accuracy for 16 types of mixed power quality disturbances under different noises. Compared with the existing composite power quality identification methods, the proposed method has higher classification accuracy and shorter training time.

Key words:power quality;composite disturbance classification;incomplete S transformation of adaptive window; kernel extreme learning machine;leave-one-out cross validation

Table A1 Calculation results of window width factor at a particular frequency					
频率/Hz	窗宽因子	频率/Hz	窗宽因子		
50	0.01	550	7.23		
150	0.27	650	9.41		
250	1.29	750	11.28		
350	2.93	850	12.61		
450	4.99	950	13.24		

表 A1 特定频率下的窗宽因子计算结果

表 A2 59 种 PQ 特征值

Table A2 59 kinds of PQ characteristics									
PQ 特征	THD	max+min	max-min	mean	std	rms	Sk	Ku	En
Ts	_	F1	F2	F3	F4	F5	F57	F58	F59
T_{\max}	_	F6	F7	F8	F9	F10	-	-	-
T_{\min}	—	F11	F12	F13	<i>F</i> 14	F15	-	-	-
T _mean	_	F16	F17	-	F18	F19	-	-	-
$T_{_{\rm std}}$	—	F20	F21	F22	F23	F24	-	-	-
$T_{\rm rms}$	—	F25	F26	F27	F28	-	-	-	-
F_{\max}	F29	F30	F31	F32	F33	F34	-	-	-
F_{\min}	F35	F36	F37	F38	F39	F40	-	-	-
F_{mean}	F41	F42	F43	-	F44	F45	-	-	-
$F_{_{\rm std}}$	F46	F47	F48	F49	F50	F51	-	-	-
$F_{\rm rms}$	F52	F53	F54	F55	F56	-	-	-	-



图 A1 改进 LOO 法优化前后 KELM 分类器的 T_{diff} 值 Fig.A1 T_{diff} values of KELM classifier before and after optimization by improved LOO method

表 A3 复合扰动模型

扰动模式	信号模型	参数
暂降+谐波	Г 13]	$0.1 \le k \le 0.9$
	$S(t) = \left\{ 1 - k[u(t_2) - u(t_1)] \right\} \left \sin(\omega t) + \sum a_k \sin(k\omega t) \right $	$0.5T < t_2 - t_1 < 30T$
		$0.05 < a_k < 0.6$
暂升+谐波	Г 13 Л	$0.1 < k \le 0.9$
	$S(t) = \left\{ 1 + k[u(t_2) - u(t_1)] \right\} \left \sin(\omega t) + \sum_{k} a_k \sin(k\omega t) \right $	$0.5T < t_2 - t_1 < 30T$
	<u>k=2</u>	$0.05 < a_k < 0.6$
	Г <u>13</u>]	$0.1 < \alpha \le 0.2$
闪变+谐波	$S(t) = \left[1 + \alpha \sin(2\pi\beta t)\right] \sin(\omega t) + \sum a_k \sin(k\omega t)$	$5Hz < \beta < 20Hz$
		$0.05 < a_k < 0.6$
	Г 13 Л	$0.9 < k \le 1$
中断+谐波	$S(t) = \left\{ 1 - k[u(t_2) - u(t_1)] \right\} \left[\sin(\omega t) + \sum_{k=2} a_k \sin(k\omega t) \right]$	$0.5T < t_2 - t_1 < 30T$
		$0.05 < a_k < 0.6$
		$0.1 \le k \le 0.9$
新政司亦	$S(t) = \{1 - k[u(t_2) - u(t_1)]\} [1 + \alpha \sin(2\pi\beta t)]$	$0.5T < t_2 - t_1 < 30T$
省陴+内安		$0.1 < \alpha \le 0.2$
		$5\text{Hz} < \beta < 20\text{Hz}$
		$0.1 \le k \le 0.9$
斩斗, 问亦	$S(t) = \{1 + k[u(t_2) - u(t_1)]\} [1 + \alpha \sin(2\pi\beta t)]$	$0.5T < t_2 - t_1 < 30T$
習开+闪变		$0.1 < \alpha \le 0.2$
		5 Hz < β < 20Hz
		$0.1 \le k \le 0.9$
暂降+振荡	$S(t) = \{1 - k[u(t_2) - u(t_1)]\}\sin(\omega t) +$	$0.5T < t_2 - t_1 < 30T$
	$\alpha \exp[-\lambda(t-t_1)]\sin(\beta\omega t)[u(t_2)-u(t_1)]$	$0.05 < \alpha < 1$
		$15 < \lambda < 130, 10$ Hz $\leq \beta \leq 40$ Hz
暂升+振荡		$0.1 \le k \le 0.9$
	$S(t) = \{1+k[u(t_2) - u(t_1)]\}\sin(\omega t) +$	$0.5T < t_2 - t_1 < 30T$
	$\alpha \exp[-\lambda(t-t_1)]\sin(\beta\omega t)[u(t_2)-u(t_1)]$	$0.05 < \alpha < 1$
		$15 < \lambda < 130.10$ Hz $\leq \beta \leq 40$ Hz

Table A3 Complex disturbance model of power quality



图 A2 暂降+振荡实测波形的 PQDiffractor 显示 Fig.A2 Measured waveform of Sag+Transient on PQDiffractor

表 A4 实际电网数据的扰动事件时频信息

扰动事件类型	扰动发生后幅值标幺值	不完全 S 变换的幅值标幺值	扰动发生后频率/Hz	不完全S变换的频率/Hz
暂升	1.4910	1.4900	50	50
中断	0.0596	0.0497	50	50
暂降	0.2459	0.2485	50	50
谐波	0.9993	0.9927	50,150,250,350	50,150,250,350
振荡	1.0540	0.9993	50,420	50,450
脉冲	1.337	1.007	50	50
闪变	0.8210	0.8260	50	50
暂降+谐波	0.3128	0.3339	50,150	50,150
暂升+谐波	1.4060	1.486	50,150	50,150
暂降+振荡	0.5322	0.5305	50,750	50,750

Table A4 Time-frequency information of disturbance events of actual grid data