

单一电能质量扰动的分类识别研究*

桑博 刘洪文 尹志勇

(军械工程学院车辆与电气工程系 石家庄 050003)

摘要:电能质量扰动的分类识别对电能质量综合治理具有重要意义,为此提出了一种基于粒子群优化极限学习机的电能质量扰动分类新方法。利用小波变换将扰动信号做10层分解,提取有效区分扰动信号类型层数的能量差、能量差平均值及能量差的标准差作为特征向量,并将扰动信号与正常信号的均方根作为补充,减少输入向量维度。提出采用极限学习机训练误差作为粒子群的适应度函数来优化隐含层神经元个数,在提升分类速度的基础上保持较高的分类精度。经仿真验证表明,该方法能够准确有效地识别常见的7种扰动类型,相比于传统的BP神经网络具有较高的分类速度。

关键词:电能质量;分类识别;极限学习机;隐含层个数;粒子群算法

中图分类号: TN911 **文献标识码:** A **国家标准学科分类代码:** 520.604

Research of signal power quality disturbance identification and classification

Sang Bo Liu Hongwen Yin Zhiyong

(Department of Vehicle and Electrical Engineering of Ordnance Engineering College, Shijiazhuang 050003, China)

Abstract: Power quality disturbance identification and classification are important for power quality management, for which a new method is proposed to deal with power quality disturbance identification and classification based on PSO-ELM (particle swarm optimization-extreme learning machine). Decompose the disturbance signals with wavelet for ten layers and extract the layers of energy difference which can effectively distinguish the difference between disturbance signals, the average of energy difference and the standard deviation of energy difference as feature vectors, in addition, the root mean of disturbance signals and normal signals is calculated as a supplement in order to reduce the dimension of the importing vectors. It is proposed that ELM training error is used as the fitness function of PSO to optimize the hidden layer neuron number to enhance the speed of classification and also maintain high classification accuracy. Simulation results show that this method can accurately and effectively identify seven common disturbance types and have a higher classification speed comparing to the traditional BP neural network.

Keywords: power quality; classification; extreme learning machine (ELM); hidden layer number; PSO

1 引言

随着现代电力系统非线性、冲击性负载的大量使用,给电力系统也带来了很大程度的电能质量污染,因此电能质量的监测与分析对电力系统的发展至关重要。为了使电力系统安全稳定的运行,需要实时地对海量的扰动信息中识别出扰动信号类型,然后才能采取相应的补偿措施。为此,电能质量扰动的分类识别就成为了电能质量监测与分析中的重要一环,目前电能质量扰动分类的主要步骤为特征值提取与分类器设计。特征值提取实质上为信

号处理过程,主要采用的方法有短时傅里叶变换、小波分析、S变换、数学形态学等^[1-4],它们具有时频域特性,能够有效地分析电能质量扰动的非平稳信号,但这些方法也存在一些不足,出现提取扰动信号特征向量时维数过大,导致分析计算繁琐,分类速度下降等问题。本文将扰动信号进行小波分解,计算每层扰动信号与正常信号的能量差,选取能明显区别扰动类型分解层数的能量差与能量差的标准差作为特征向量,并将扰动信号与正常信号的均方根作为补充,这样更能体现各类扰动信号的特征,减少输入分类器的向量维度,有利于提升分类速度与精度。在分类

收稿日期:2016-04

* 基金项目:国家自然科学基金(51307184)项目资助

器设计方面,目前主要采用的方法有神经网络,支持向量机,模糊系统等智能算法^[3,5-7],这些智能算法在分类精度上可以到达比较高的水平,但在训练时需要大量的训练样本,训练时间过长,在分类速度上还不能满足要求。本文采用极限学习机(extreme learning machine, ELM)作为分类器^[8],该算法随机产生输入层与隐含层的连接权值,训练过程无需调整,加快了分类速度,并提出采用粒子群算法(particle swarm optimization, PSO)优化 ELM 的隐含层神经元个数,在提升分类速度的基础上保持较高的分类精度。将提取的特征值输入到 ELM 分类器中,经仿真验证,该方法能够实现对 7 种常见的扰动信号的自动识别,验证了其有效性。

2 PSO-ELM 分类器基本原理及步骤

ELM 作为单隐含层前馈神经网络,随机产生输入层与隐含层的连接权值,训练过程无需调整,只需设置隐含层神经元个数,便可得到最优解,相比于传统的训练方法,具有学习速度快、泛化性能好的优点^[8]。HUANG G B 在文献[9]中提出,当隐含层神经元个数与训练样本数相等时,ELM 可有以零误差逼近训练样本。但在实际应用中,如果训练样本数目过大,会导致计算量较大,增加训练时间,为此, HUANG G B 提出当隐含层个数小于训练样本数时,ELM 的训练误差可有逼近任意 $\epsilon > 0$, 即:

$$\sum_{j=1}^Q \|t_j - y_j\| < \epsilon \quad (1)$$

式中: t_j 与 y_j 分别为样本输出矩阵第 i 个神经元的真实输出值与实际输出值。由式(1)可以看出,隐含层神经元个数的设定对 ELM 的训练精度与训练速度至关重要。

粒子群优化算法^[10]最早由 Kennedy 和 Eberhart 在 1995 年提出用于求解最优化问题的。假设在一个 D 维的搜索空间中,由 n 个粒子组成的种群 $\mathbf{X} = (X_1, X_2, \dots, X_n)$,其中第 i 个粒子表示为一个 D 维的向量 $\mathbf{X} = (X_{i1}, X_{i2}, \dots, X_{iD})^T$,代表第 i 个粒子在 D 维搜索空间中的位置,也代表问题的一个潜在解。根据目标函数即可计算出每个粒子位置 x_i 对应的适应度值。第 i 个粒子的速度为 $\mathbf{V} = (V_{i1}, V_{i2}, \dots, V_{iD})^T$,其个体极值为 $\mathbf{P} = (P_{i1}, P_{i2}, \dots, P_{iD})^T$,种群的个体极值为 $\mathbf{P} = (P_{g1}, P_{g2}, \dots, P_{gD})^T$ 。每次迭代过程中,粒子通过个体极值和群体极值更新自身的速度和位置,即:

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{gd}^k - X_{id}^k) \quad (2)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \quad (3)$$

式中: ω 为惯性权重; $d=1, 2, \dots, D$; $i=1, 2, \dots, n$; k 为当前迭代次数, c_1, c_2 为非负常数,称为加速因子,通常取 $c_1 = c_2 = 2$; r_1, r_2 是分布于 $[0, 1]$ 区间的随机数。为加强 PSO 的自适应性,本文采用动态惯性权重,即:

$$\omega(k) = \omega_s - (\omega_s - \omega_e)(k/T_{\max})^2 \quad (4)$$

式中: $\omega_s = 0.9$, $\omega_e = 0.4$, k 为当前迭代次数, T_{\max} 为最大迭代次数。PSO-ELM 基本原理就是利用粒子群算法优化

极限学习机的隐含层个数,当训练样本 Q 较大时,为减小计算量,隐含层个数通常取的比 Q 小,采用训练误差作为 PSO 的适应度函数,当 PSO 搜索达到最大迭代次数或最小误差时停止迭代,此时输出最优隐含层个数。适应度函数如式(5)所示:

$$f = \sum_{k=1}^m \sum_{j=1}^Q (t_{k,j} - y_{k,j}) \quad (5)$$

式中: $t_{k,j}$ 为表示第 j 个训练样本的第 k 个实际输出值, $y_{k,j}$ 表示第 j 个训练样本的第 k 个网络输出值。PSO-ELM 具体分类过程如下:

1) 采用 'db4' 小波变换将 7 种扰动信号做 10 层小波分解,将提取到的 6 种特征向量输入到 ELM 分类器中,在训练过程中 ω 和 b 随机设定且保持不变,初始隐含层神经元数目为 30;

2) 粒子群参数设置,种群数量设为 30,最大速度为 1, $T_{\max} = 120$, $c_1 = c_2 = 2$,适应度函数最小误差 $\epsilon = 0.01$,惯性权重 ω 采用式(4)进行动态调整,防止迭代过程陷入局部最优,增强全局搜索能力;

3) 初始化粒子群速度,计算粒子适应度,寻找个体极值和群体极值,迭代更新粒子速度与位置,并将每次得到的隐含层数输入到 ELM 分类器中并计算训练误差;

4) 判断是否满足迭代终止条件,若达到最大迭代次数或适应度函数达到最小误差要求时,终止迭代,此时得到的隐含层数目极为最优值;

5) 再次将得到的最优隐含层数目输入 ELM 分类器,完成扰动信号的分类识别。

3 仿真验证及分析

3.1 电能质量扰动信号模型

常见的 7 种扰动信号为:电压暂升,电压暂降,电压中断,谐波,暂态振荡,暂态脉冲,电压闪变。考虑到实际扰动信号存在噪声污染,在扰动信号中加入信噪比为 30 dB 的高斯白噪声,数学模型如图 1 所示。

3.2 特征向量提取

本文采用 db4 作为母小波对扰动信号进行 10 层分解,获得每层的小波分解系数,根据 Parseval 能量公式计算出各层的能量值,Parseval 能量公式为:

$$E_j = \sum_{k=1}^{N/2^j} |D_j(k)|^2 \quad (6)$$

式中: $E_j, D_j(k)$ 分别为小波分解后第 j 层的能量与第 j 层的小波系数。

另外,扰动信号经小波变换后能量分布特征值与正常信号的能量分布差值也可以有效区分扰动信号类型,为减小输入向量维度,本文每类扰动信号取 10 层能量差的平均值 ΔE_{ave} ,标准差 ΔE_{std} 作为特征向量。能量差计算公式如(7)所示:

$$\Delta E_j = E_j - E_{0j} \quad (7)$$

式中: E_{0j} 为正常信号小波分解后第 j 层的能量值。

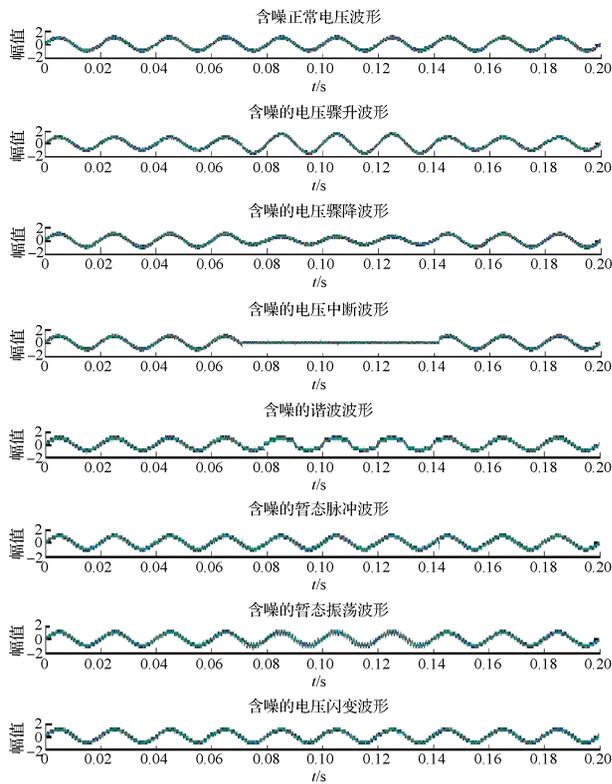


图1 电能质量信号波形

为了提升能量值的区分精度,将能量差作归一化处理,归一化处理后信号能量差波形如图2所示。

通过计算表1中每列数据标准差选出标准差较大且无相同数据的 ΔE_5 、 ΔE_8 、 ΔE_9 作为特征向量,有效区分不同的扰动信号类型,最后选取扰动信号与正常信号的均方根 R 作为第6个特征向量,其表达式为:

$$R = \sqrt{\frac{1}{N} \sum_{i=1}^N [s(t) - x(t)]^2} \quad (8)$$

式中: N 为采样点个数, $s(t)$ 为扰动信号, $x(t)$ 为正常信号。综上所述,最终输入 PSO-ELM 分类器的特征向量为 $E = [\Delta E_5, \Delta E_8, \Delta E_9, \Delta E_{ave}, \Delta E_{std}, R]$ 。

3.3 算法性能比较

对扰动信号取10个工频周期分析,采样频率为3200 Hz。每种扰动信号取200个样本,8类信号共1600个样本,每类样本取前150个作为训练样本,后50个作为测试样本。每次实验随机选取30个训练样本(8类信号共240个),10个测试样本(8类信号共80个),由于每次实验是随机选取训练样本与测试样本,实验结果的准确率和运行时间都会不同,为验证该方法的准确性,将实验运行50次,某次测试实验的运行结果如图3所示。

从本次测试集分类结果中看出,80个测试样本中只有2个分类错误,将实验进行50次后,计算分类准确率与运行时间的平均值作为最后实验结果,并将该方法与BP神经网络^[5]和ELM进行比较结果如表1所示。

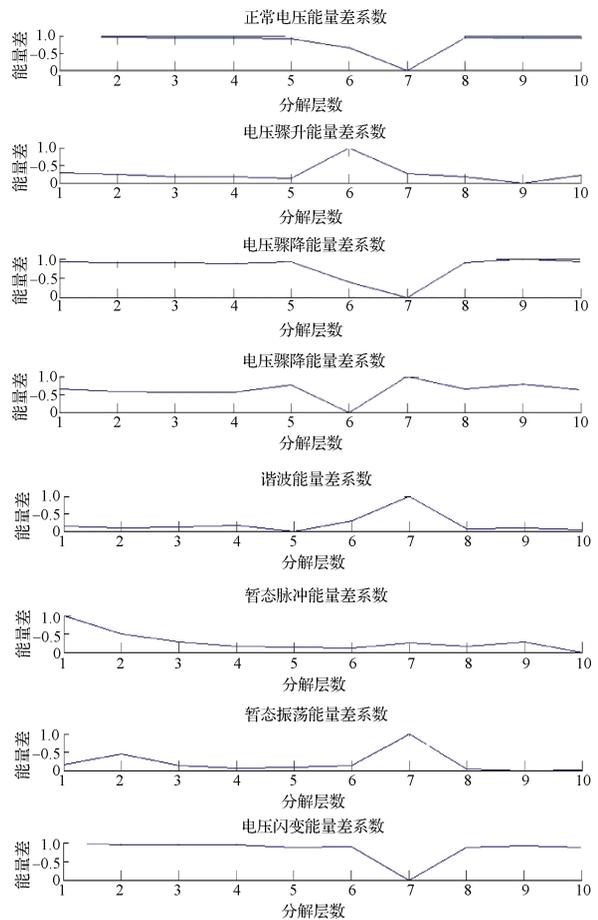


图2 电能质量信号能量差波形

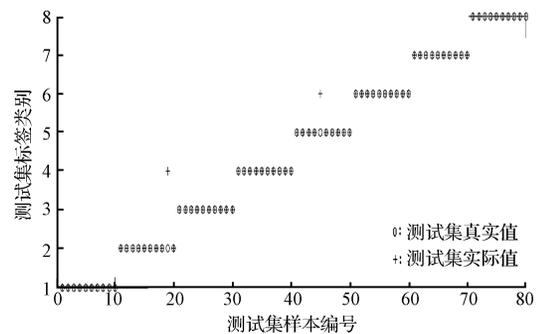


图3 测试集分类结果

表1 不同分类方法比较结果

分类方法	训练样本	测试样本	平均训练时间/s	平均测试时间/s	平均分类准确率(%)
BP神经网络	240	80	9.752 4	3.362 1	95.75
ELM	240	80	6.645 6	2.301 1	96.40
PSO-ELM	240	80	7.836 3	2.452 9	97.65

从表1中可以看出, PSO-ELM无论是在训练速度上还是分类精度上都要优于BP神经网络,但是采用PSO优化ELM后,虽然在测试时间上慢于只采用ELM,但在训练精度上有所提升,从本质上来看,在分类识别过程中需要根据实际情况在分类精度与分类速度上做出折中的选择,满足实际需求。

4 结论

本文提出了一种基于粒子群优化极限学习机的电能质量扰动分类新方法。首先利用小波变换对扰动信号进行10层分解,提取能够反映不同扰动类型的特征向量,减小输入向量维度;然后利用粒子群算法优化影响极限学习机分类精度的隐含层神经元个数;最后将得到的最优隐含层神经元个数输入分类器进行分类识别,经过仿真实验分析,验证了该方法比传统的BP神经网络能够更准确、更快速地对常见的扰动信号进行分类识别。

参考文献

- [1] 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.
- [2] 王林泓,陈学昌. 基于双密度双树小波变换的电能质量扰动识别方法[J]. 电测与仪表,2012,49(8):18-21.
- [3] 戴文,魏淑艳,曹明革. 小波变换在谐波检测中的应用研究[J]. 电子测量技术,2011,34(7):37-39.
- [4] 张伟,师奕兵,周龙甫,等. 基于改进粒子群算法的小波神经网络分类器[J]. 仪器仪表学报,2010,31(10):2203-2209.
- [5] 张韩. 基于小波变换和PSO-BP神经网络的电能质量扰动分类[D]. 上海:华东理工大学,2014:42-45.
- [6] 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.
- [7] 刘松松,张辉,毛征,等. 基于HRM特征提取和SVM的目标检测方法[J]. 国外电子测量技术,2014,33(10):38-41.
- [8] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1-3):489-501.
- [9] HUANG G B, LEI C K, SIEW C K. Universal Approximation using incremental constructive feedforward networks with random hidden nodes [J]. IEEE Transactions on Neural Networks, 2006, 17(4):879-892.
- [10] 王道明,鲁昌华,蒋薇薇,等. 基于粒子群算法的决策树SVM多分类方法研究[J]. 电子测量与仪器学报,2015,29(4):611-615.

作者简介

桑博,1990年出生,男,硕士研究生,主要研究方向为电能质量检测与分析。
E-mail:726932384@qq.com

刘洪文,1972年出生,男,博士,副教授,主要研究方向为装备电力系统检测理论。

尹志勇,1979年出生,男,博士,讲师,主要研究方向为军用自动测试系统。