

## 一种电能质量多扰动分类中特征组合优化方法

瞿合祚<sup>1</sup>, 刘恒<sup>2</sup>, 李晓明<sup>1</sup>, 黄建明<sup>1</sup>

(1. 武汉大学电气工程学院, 湖北武汉 430072; 2. 国网湖北省电力公司孝感供电公司, 湖北孝感 432000)

**摘要:** 针对电能质量扰动分类中冗余特征量造成分类器训练困难、分类准确率下降的问题, 提出一种基于改进遗传算法的特征组合优化方法。该方法对信号进行小波变换, 提取各层的改进小波能量熵作为原始特征, 并构造一种基于欧氏距离的适应度函数, 采用改进的自适应遗传算法对原始特征进行筛选和优化组合, 形成用于电能质量扰动分类的最优特征组合。分别采用二分类-支持向量机法(Binary-SVM)、多标签径向基神经网络(ML-RBF)和多标签 $K$ 近邻法(ML-KNN)对不同噪声情况下的电能质量单一扰动和混合扰动进行分类, 仿真结果验证了所提特征组合优化方法能有效提高分类器的训练速度和分类准确率。

**关键词:** 电能质量; 小波变换; 遗传算法; 特征组合; 多标签分类; 分类器

**中图分类号:** TM 761

**文献标识码:** A

**DOI:** 10.16081/j.issn.1006-6047.2017.03.024

## 0 引言

随着电力电子与信息技术在电力系统中的广泛应用和新能源改革的不断推进, 系统的用电负荷结构发生重大改变。变频装置、炼钢电弧炉、电气化铁道等非线性、冲击性、波动性负荷对电能质量的扰动<sup>[1]</sup>将严重影响工业生产和居民用电, 甚至对电力系统的安全稳定运行造成威胁。如何提高电能质量已成为电力企业和用户共同关心的课题。为了治理电能质量问题, 首先必须对电能质量扰动事件进行准确识别和分类, 这是电能质量问题的关键。

当前对电能质量扰动信号进行识别分类大体分为特征提取和模式分类2个步骤。特征提取采用的方法主要有小波变换<sup>[2]</sup>、S变换<sup>[3]</sup>、原子分解<sup>[4]</sup>、短时傅里叶变换<sup>[5]</sup>、谱峭度<sup>[6]</sup>等。短时傅里叶变换由于窗函数固定, 其时频分辨率也相对固定, 无法同时满足低频和不同时频分辨率的要求; S变换由短时傅里叶变换和小波变换发展而来, 具有良好的时频特性, 但其对瞬态冲击的检测效果不明显; 小波变换具有多分辨率分析的能力, 在暂态扰动特征提取领域具有独特优势。采用机器学习技术进行模式分类的方法主要有神经网络<sup>[7-8]</sup>、支持向量机(SVM)<sup>[9-10]</sup>、 $k$ -近邻分类<sup>[11]</sup>等。文献[7]使用改进粒子群优化算法训练神经网络, 以改善神经网络的稳定性, 但该算法使得训练复杂度增加, 训练时间变长。SVM结构简单, 计算复杂性小, 可有效解决小样本、非线性的分类问题, 但分类性能受核函数和参数设置的影响较大, 且分类能力随着样本数量的增加而下降。文献[11]基于 $k$ -近邻分类和贝叶斯准则提出一种多标签分

类法, 在电能质量复合扰动分类中效果较好, 但该方法需要存储所有训练样本, 当训练样本增加时需要更多的计算机内存。

电能质量扰动分类的关键是分类特征的选择, 但特征选择没有统一标准, 难以事先确定有效的分类特征, 不可避免会出现冗余特征, 甚至无效特征, 这将对后续分类器的工作产生不利影响, 例如导致训练难度增大、分类准确率下降等<sup>[12]</sup>。特征选择在降低分类精度的前提下, 根据评价准则从原始特征中去除冗余特征, 得到一组使评价准则最优的特征子集, 该子集能够保持原始特征的物理含义。文献[13]将多种原始特征两两组合, 使用二维散点图辅助人工选取分类效果最佳的一对特征量, 能显著减小分类特征数量, 但该方法需要人工参与, 随着原始特征数量的增加工作量会迅速增大。文献[14]将特征选择策略与特定的分类器相结合, 以分类器的分类错误率衡量特征子集的优劣, 能得到相应分类器的最优特征子集, 但训练时间较长, 算法泛化能力较差。

考虑到选取有效的电能质量分类特征难度较大, 本文提出一种基于改进遗传算法的电能质量扰动分类中特征组合优化方法, 该方法提取各层改进小波能量熵的不同统计特性作为原始特征, 并构造一种基于欧氏距离的适应度函数, 采用改进的自适应遗传算法对原始特征进行优化组合; 对比采用优化特征前后多种分类器对电能质量单一扰动和混合扰动的分类结果, 验证所提方法的有效性和鲁棒性。

## 1 小波变换原理

## 1.1 连续小波变换原理

小波变换在时域和频域同时具有良好的局部化性质<sup>[15]</sup>, 广泛应用于信号处理领域。任意能量有限信号 $f(x) \in L^2(\mathbf{R})$ 的连续小波变换如式(1)所示。

$$W_{\tau} f(x) = f(x) \otimes \psi_a(x) = a^{-1} \int_{\mathbf{R}} f(\tau) \psi[a^{-1}(x-\tau)] dx \quad (1)$$

其中,  $\psi_a(x) = a^{-1} \psi(a^{-1}x)$  为小波基函数;  $a$  为尺度因子, 与频率相关, 且  $a > 0$ 。改变基函数的尺度因子可以获得不同的频率分辨率。

## 1.2 离散平稳小波变换原理

离散平稳小波变换是一种非正交小波变换, 变换原理如图 1 所示。与常用的 Mallat 算法<sup>[16]</sup>不同, 该方法不对信号本身进行下采样处理, 而是对滤波器组进行内插补零(上采样), 使每级分解系数和原始序列的长度保持一致, 可有效避免因信号下采样而造成重构信号发生振荡的现象, 也被称为多孔算法<sup>[16]</sup>。如式(2)和式(3)所示, 分别对低通滤波器系数  $h[k]$  和高通滤波器系数  $g[k]$  进行上采样。

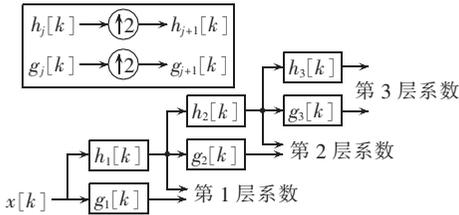


图 1 离散平稳小波变换原理

Fig.1 Principle of discrete stationary wavelet transform

$$h_{j+1}[k] = h_j[k] \uparrow 2 = \begin{cases} h_j[k/2] & k=2, 4, \dots, 2L_j \\ 0 & k=1, 3, \dots, 2L_j+1 \end{cases} \quad (2)$$

$$g_{j+1}[k] = g_j[k] \uparrow 2 = \begin{cases} g_j[k/2] & k=2, 4, \dots, 2L_j \\ 0 & k=1, 3, \dots, 2L_j+1 \end{cases} \quad (3)$$

其中,  $L_j$  为第  $j$  层滤波器的长度。

相应地, 高频系数  $d_j$  和低频系数  $c_j$  见式(4)。

$$\begin{cases} c_{j+1}[k] = h_j[-k] \otimes c_j[k] \\ d_{j+1}[k] = g_j[-k] \otimes c_j[k] \end{cases} \quad (4)$$

其中,  $c_0 = x[k]$  为原信号;  $x[k]$  为原始信号时间序列。

小波重构是小波分解的逆过程, 如式(5)所示。

$$c_j[k] = (h_j[k] \otimes c_{j+1}[k] + g_j[k] \otimes d_{j+1}[k]) / 2 \quad (5)$$

## 2 小波能量熵

### 2.1 小波能量熵定义

小波变换可以在频域和时域同时定位并分析非平稳时变信号, 在此基础上引入熵的概念进而定义小波熵<sup>[17]</sup>, 从而对被分析信号在各频段上的能量分布进行统计分析。小波能量熵通过各层小波分解系数对信号能量进行划分, 最终以一个定量的熵值来反映信号能量在频域上的分布复杂度。设第  $j$  层小波分解系数为  $S_j$ ,  $s_j[i]$  为第  $j$  层第  $i$  个小波系数, 则 Shannon 能量熵的定义如式(6)所示。

$$S_E(S_j) = - \sum_{i=1}^N s_j^2[i] \ln s_j^2[i] \quad (6)$$

其中,  $N$  为第  $j$  层小波系数的个数。

### 2.2 改进小波能量熵

单一的小波能量熵没有考虑能量随时间的变

化, 无法反映局部信息。为了采用小波熵分析非平稳时变信号, 本文对小波分解系数进行加窗处理再计算 Shannon 熵, 从而得到一种改进小波能量熵的计算方法。设  $g$  为宽度是  $N_w$  ( $N_w \in \mathbf{N}$ ) 的滑动窗, 窗中心为  $\tau \in \mathbf{N}$ , 则加窗 Shannon 能量熵的计算如式(7)所示。在时轴上移动窗函数得到随时间变换的 Shannon 熵, 能反映小波能量随时间的变化情况。通过计算小波变换各层分解系数的改进小波 Shannon 熵, 可获得各频段分量的能量在时域的分布情况。

$$S_E(S_j, \tau) = S_E(S_j[k] g[k-\tau]) = - \sum_{i=1}^N (s_j[i] g[i-\tau])^2 \ln (s_j[i] g[i-\tau])^2 \quad (7)$$

## 3 基于遗传算法的特征组合优化原理

电能质量分类过程中, 过多的分类特征会使分类器的结构过于复杂, 增加分类器的训练难度, 减缓分类处理速度, 降低分类准确率。遗传算法是建立在自然选择和遗传学理论上的迭代自适应概率性搜索算法, 是一种全局优化算法, 最早由 John Holland 于 1975 年提出<sup>[18]</sup>。本文提出基于改进遗传算法的分类特征组合方法, 提取用于扰动分类的最优特征组合, 以降低特征向量维数, 优化分类器结构, 提高分类准确率。其基本步骤有编码、初代种群生成、适应度检测、选择、交叉、变异、判断收敛、译码。

设原始特征集合为  $B_s = \{b_1, b_2, \dots, b_F\}$ ,  $b_i = \{1, 0\}$  ( $i=1, 2, \dots, F$ ),  $b_i=1$  表示选中特征  $i$ , 反之则表示未选中。特征组合优化问题可以描述为在一定约束条件下从特征集  $B_s$  中选取一个子集  $B$  使其在某评价准则下最优。

(1) 编码。

常用的染色体编码方法有二进制编码、符号编码、浮点数编码和格雷编码。本文的染色体编码方式为二进制编码, 其可以直观地反映特征组合的情况, 同时易于进行遗传操作, 染色体编码示意图如图 2 所示。若对应特征序号的基因为 1 表示选择该特征, 若为 0 则表示不选择该特征。

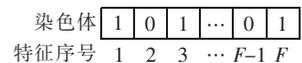


图 2 染色体编码示意图

Fig.2 Schematic diagram of chromosome encoding

(2) 初始种群生成。

初始种群是由  $N_p$  个染色体字符串组成的群体 ( $N_p$  为种群规模), 种群中每一个染色体的长度  $F$  与原始特征数相等。初始种群中的染色体都是随机生成的, 以初始种群作为第一代种群开始遗传迭代。

(3) 适应度检测。

为了使用遗传算法寻优, 需要根据实际问题确定

适应度函数。个体适应度的高低决定其是继续繁殖还是被淘汰。适应度函数设计的好坏直接关系遗传算法能否进化出最优个体,构造合适的适应度函数是特征选择的关键。

如图 3 所示,合适的特征应当满足 2 个性质:一是类内稳定性,对于同属一类的特征在特征空间中分布应当集中;二是类间差异性,对于不同类的特征应当有差异,且类间差异应大于类内差异。本文采用欧氏距离量化上述 2 个性质,欧氏距离的计算式为:

$$d(\mathbf{x}_s, \mathbf{x}_t) = \sqrt{\sum_{i=1}^n |x_{si} - x_{ti}|^2} \quad (8)$$

其中,  $n$  为特征维度。

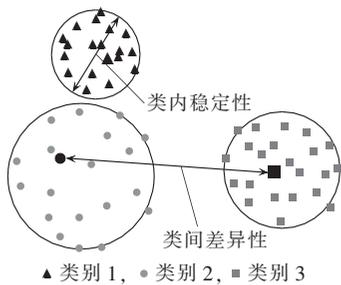


图 3 自适应最优特征选取原理

Fig.3 Principle of adaptive optimal feature selection

设染色体对应的特征子集为  $B$ , 组合的特征数为  $q$ , 对应的样本集为  $D_B = \{(\mathbf{x}_1, \mathbf{y}_1), (\mathbf{x}_2, \mathbf{y}_2), \dots, (\mathbf{x}_m, \mathbf{y}_m)\}$ , 其中  $\mathbf{x}_i \in \mathbf{R}^q, \mathbf{y}_i = (y_i^{(1)}, y_i^{(2)}, \dots, y_i^{(L)})$ ,  $y_i^{(l)} \in \{-1, 1\}$ ,  $y_i^{(l)} = 1$  表示样本  $i$  属于标签  $l$ , 反之则不属于。

染色体的适应度计算流程如下。

a. 判断  $q$  与类别数  $L$  的大小关系, 由于多标签分类必须满足分类特征数不小于分类标签数<sup>[19]</sup>, 若  $q < L$ , 则该染色体的适应度  $F_{it}$  为 0。

b. 根据样本的标签构造  $L$  个样本子集, 分别为  $D_{B1}, D_{B2}, \dots, D_{BL}$ , 其中  $D_{Bl} = \{(\mathbf{x}_j, \mathbf{y}_j) | y_j^{(l)} = 1\}$ 。

c. 按式(9)计算  $L$  个样本子集的中心特征向量  $\bar{\mathbf{x}}_{Dl}$ , 其中  $P_l$  为样本子集  $D_{Bl}$  包含的样本数。中心特征向量表示相应类型样本在特征空间的中心, 视为类型特征向量, 从而简化类间差异系数的计算。

$$\bar{\mathbf{x}}_{Dl} = \frac{1}{P_l} \sum_{i=1}^{P_l} \mathbf{x}_i \quad l=1, 2, \dots, L \quad (9)$$

d. 按式(10)计算每个样本子集的稳定系数  $I_l$ , 该参数衡量各个样本子集的特征集中程度,  $I_l$  越小表示样本子集越集中。

$$I_l = \frac{1}{qP_l} \sum_{i=1}^{P_l} d(\mathbf{x}_i, \bar{\mathbf{x}}_{Dl}) \quad l=1, 2, \dots, L \quad (10)$$

e. 按式(11)计算特征子集的内稳定系数  $I$ , 该参数衡量特征子集的内稳定性,  $I$  越小表示该特征子集的内稳定性越好。

$$I = \frac{1}{q} \sum_{l=1}^L I_l \quad (11)$$

f. 按式(12)计算特征子集的内稳定系数  $K$ , 该参数衡量特征子集的内差异性,  $K$  越大表示该特征子集的内差异性越大, 更适于分类。

$$K = \frac{2}{q^2(q-1)} \sum_{i=2}^q \sum_{j=1}^{i-1} d(\bar{\mathbf{x}}_{Di}, \bar{\mathbf{x}}_{Dj}) \quad i \neq j \quad (12)$$

g. 计算特征子集的适应度  $F_{it} = K \exp(-\alpha I)$ , 其中权重系数  $\alpha$  用以调节类内稳定系数与类间差异系数的重要性, 该系数的取值会影响遗传算法的优化性能。

(4) 选择、交叉和变异。

选择过程采用最优保存法和轮盘赌选择法结合的方法, 可保证种群中最优的个体不会被淘汰, 同时适应度高的个体更有可能被选中, 但适应度低的个体也不至于完全被淘汰, 有利于保持种群基因的多样性。交叉过程采用两点交叉的方式生成下一代, 在父代中选择 2 个染色体, 并选择 2 个点作为交叉点, 然后将父代染色体 2 个交叉点之间的基因互换得到 2 个子代染色体。变异操作采用随机基因位取反变异。为了保证遗传算法迭代不过早收敛, 使交叉概率  $p_c$  和变异概率  $p_m$  随操作个体适应度的变化而改变<sup>[20]</sup>, 如式(13)和式(14)所示。

$$p_c = \begin{cases} p_{c1} - \frac{(p_{c1} - p_{c2})(f' - f_{avg})}{f_{max} - f_{avg}} & f' \geq f_{avg} \\ p_{c1} & f' < f_{avg} \end{cases} \quad (13)$$

$$p_m = \begin{cases} p_{m1} - \frac{(p_{m1} - p_{m2})(f' - f_{avg})}{f_{max} - f_{avg}} & f' \geq f_{avg} \\ p_{m1} & f' < f_{avg} \end{cases} \quad (14)$$

其中,  $f_{max}$  为种群最佳个体适应度;  $f_{avg}$  为种群平均个体适应度;  $f'$  为父代染色体中适应度较大的值;  $p_{c1} = 0.85, p_{c2} = 0.45$  分别为  $p_c$  变化范围的上、下界;  $p_{m1} = 0.08, p_{m2} = 0.01$  分别为  $p_m$  变化范围的上、下界。

(5) 收敛条件。

本文收敛条件有 2 个: 一是种群的最大适应度值超过  $M$  代未发生变化; 二是种群达到最大迭代次数。2 个条件满足其一就停止迭代, 输出最优个体。

(6) 译码。

译码是特征编码的逆过程, 算法迭代结束后, 对种群最优染色体进行译码, 编码中为 1 的基因位所代表的特征将被选为最优分类特征。

## 4 电能质量扰动分类方法

实际电力系统中电能质量扰动往往是多种扰动同时存在的复合扰动, 电能质量扰动分类问题属于多标签分类的范畴<sup>[11]</sup>, 它不同于一般的二分类问题, 是比较复杂的分类问题。目前国内外运用较广的多标签分类方法有二分类-支持向量机(Binary-SVM)法<sup>[21]</sup>、多标签径向基神经网络(ML-RBF)<sup>[22]</sup>和多标签  $K$  近邻(ML-KNN)法<sup>[23]</sup>。

Binary-SVM 属于问题转换(problem transforma-

tion)<sup>[19]</sup>,将多标签分类问题转换为多个单标签分类问题,每个标签构造一个 SVM 分类器,扰动信号的类别由多个 SVM 分类器确定。ML-RBF 和 ML-KNN 均属于算法适应(algorithm adaptation)<sup>[19]</sup>,算法直接面向多标签数据。ML-RBF 采用均值聚类确定每一类样本的聚类中心,将其作为径向基函数神经网络基函数的中心,并采用最小二乘法直接求取网络的连接权重。ML-KNN 根据待分类样本的  $K$  个最近邻样本的标签和训练样本中样本的先验统计概率,使用最大化后验概率原则,确定待分类样本属于各标签的概率值。

### 5 仿真分析

#### 5.1 电能质量扰动模型

电能质量扰动信号种类繁多,其基本的扰动信号包括电压暂升、电压中断、电压暂降、谐波、暂态振荡、瞬态冲击、电压闪变等。在 MATLAB2015 环境中,参考文献[13,24]建立标准信号与电能质量基本扰动信号模型,如表 1 所示。其中,基波频率  $f_0$  为 50 Hz,采样频率  $f_s$  为 12.8 kHz, $T$  为工频周期, $u(t)$  为单位阶跃函数。为了适应不同幅值的信号,电压幅值为归一化幅值,实际应用中可对电压信号进行归一化处理。谐波信号主要考虑 13 次及以下的谐波(650 Hz),暂态振荡频率范围为 700~1500 Hz。

表 1 电能质量标准信号与扰动信号模型  
Table 1 Models of power-quality standard signal and disturbance signals

信号类型	信号模型	参数
标准信号 $C_0$	$v(t) = \sin(\omega t)$	$\omega = 2\pi f_0$
电压暂升 $C_1$	$v(t) = \{1+k[u(t_2)-u(t_1)]\}\sin(\omega t)$	$0.1 \leq k \leq 0.9,$ $0.5T \leq t_2 - t_1 \leq 30T$
电压中断 $C_2$	$v(t) = \{1-k[u(t_2)-u(t_1)]\}\sin(\omega t)$	$0.9 < k \leq 1,$ $0.5T \leq t_2 - t_1 \leq 30T$
电压暂降 $C_3$	$v(t) = \{1-k[u(t_2)-u(t_1)]\}\sin(\omega t)$	$0.1 \leq k \leq 0.9,$ $0.5T \leq t_2 - t_1 \leq 30T$
谐波 $C_4$	$v(t) = \sin(\omega t) + \sum_{k=2}^{13} a_k \sin(k\omega t)$	$0.01 < a_k < 0.2$
暂态振荡 $C_5$	$v(t) = \sin(\omega t) + \gamma e^{-\lambda(t-t_1)} \sin(\beta\omega t)$	$0.05 < \gamma < 1,$ $15 < \lambda < 130, 14 \leq \beta < 30$
瞬态冲击 $C_6$	$v(t) = \sin(\omega t) + \gamma[u(t_1)-u(t_2)]$	$\gamma > 0.8,$ $1 \text{ ms} < t_2 - t_1 < 3 \text{ ms}$
电压闪变 $C_7$	$v(t) = [1 + \gamma \sin(\beta\omega t)] \times \sin(\omega t)$	$0.05 < \gamma < 0.2,$ $0.1 < \beta < 0.5$

#### 5.2 改进小波能量熵特征提取

不同扰动信号在时频分布上的差异表现为时频

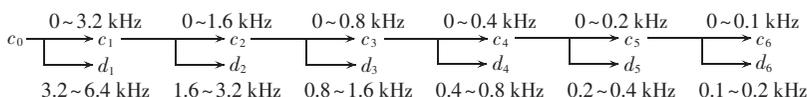


图 4 信号的平稳小波分解示意图

Fig.4 Schematic diagram of stationary wavelet decomposition

平面上不同小块的时频段能量分布的差异,各时频区能量分布的均匀性差异反映扰动分量状态的差别。基于平稳小波变换建立的改进小波能量熵测度可以对时频平面上能量分布的均匀性进行定量描述,并对扰动分量的不确定性和复杂度加以定量度量,所以能较好地提取电能质量扰动的特征。常用的小波基有 harr 小波、dbN 小波、coifN 小波和 symN 小波等,由于 coifN 小波相对其他小波基具有更长的支撑长度<sup>[25]</sup>,更有利于信号能量的集中和各层小波能量熵特征的提取,然而过大的支撑长度会增加计算时间。信号的离散小波变换实质上是对信号进行多尺度分析,综合考虑信号采样频率、小波基性质和不同类型扰动所在频段的差异,本文采用 coif4 小波对扰动信号进行 6 层小波分解,每层分解系数对应着不同频段,如图 4 所示。分别计算  $d_1$ — $d_6$  各层系数的改进 Shannon 熵  $S_{E_{di}}(k)$ — $S_{E_{d6}}(k)$ ,并提取下述特征量作为电能质量扰动分类的原始特征量。

- (1)  $F_1$ — $F_6$  为各层平稳小波变换高频系数的改进小波 Shannon 熵  $S_{E_{di}}(k)$  的最大值。
- (2)  $F_7$ — $F_{12}$  为各层平稳小波变换高频系数的改进小波 Shannon 熵  $S_{E_{di}}(k)$  的最小值。
- (3)  $F_{13}$ — $F_{18}$  为各层平稳小波变换高频系数的改进小波 Shannon 熵  $S_{E_{di}}(k)$  的平均值。
- (4)  $F_{19}$ — $F_{24}$  为各层平稳小波变换高频系数的改进小波 Shannon 熵  $S_{E_{di}}(k)$  的标准差。
- (5)  $F_{25}$ — $F_{28}$  依次为第 6 层平稳小波变换低频系数的改进小波 Shannon 熵的  $S_{E_{d6}}(k)$  的最大值、最小值、平均值和标准差。

(6) 在分解到一定尺度时可将第 6 层低频分量近似地认为是基波信号,采用半个周期的滑动有效值计算方法计算第 6 层低频分量的有效值,见式(15),提取其中的最大值和最小值作为特征量  $F_{29}$  和  $F_{30}$ 。

$$RMS_{d6}(k) = \sqrt{\frac{1}{128} \sum_{i=k-128}^k c_6^2(k)} \quad k > 128 \quad (15)$$

提取样本中的  $F_1$ — $F_{30}$  形成原始特征集合  $F = \{F_1, F_2, \dots, F_{30}\}$ 。

#### 5.3 分类特征组合优化

采用改进遗传算法对原始特征集  $F = \{F_1, F_2, \dots, F_{30}\}$  进行组合优化,提取最优分类特征组合。适应度函数权重系数  $\alpha$  取为 10,优化结果见图 5 和表 2。

当信噪比为 50 dB 时,最优特征组合中没有原始特征  $F_{21}$  的原因在于噪声对类别边界的影响;当信噪比较小时,由于噪声的存在导致类别边界更加“粗糙”,使类内稳定性减小,类间差异性增大,为了保证分类

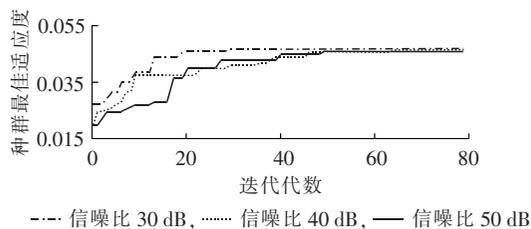


图 5 不同信噪比下适应度变化情况

Fig.5 Variation of fitness for different SNRs

表 2 最优特征组合优化结果

Table 2 Results of feature combination optimization

信噪比/dB	最优特征组合	适应度
30	$F_1, F_2, F_{13}-F_{15}, F_{19}-F_{25}, F_{29}, F_{30}$	0.046900
40	$F_1, F_2, F_{13}-F_{15}, F_{19}-F_{25}, F_{29}, F_{30}$	0.046495
50	$F_1, F_2, F_{13}-F_{15}, F_{19}, F_{20}, F_{22}-F_{25}, F_{29}, F_{30}$	0.045846

效果,需要更多的分类特征;而信噪比增大时类别边界更为“平滑”,即类内稳定性提高,类间差异性减小,此时在遗传算法优化过程中  $F_{21}$  作为冗余特征被剔除。最优特征组合中均不含  $F_7-F_{12}$  说明各层平稳小波变换高频系数的改进小波 Shannon 熵的最小值作为分类特征会增加分类难度,因此被视为冗余特征。从优化结果可知在不同信噪比下,遗传算法经过 50 次迭代后种群适应度趋向最优值;优化得到的最优特征组合较为接近,可见本文提出的适应度函数具有一定抗噪性,算法稳定性较好。

#### 5.4 分类效果仿真验证

本文参考文献[26],考虑的电能质量扰动信号为表 1 中的 7 种单一扰动信号以及由它们复合而成的复合扰动信号,其中双重复合扰动 11 种,三重复合扰动 12 种,四重复合扰动 7 种,共 37 种电能质量扰动信号。采用 MATLAB 生成上述扰动信号,每类扰动生成 200 个随机样本,共 7400 个样本,所有样本覆盖表 1 中各个参数的不同范围,如不同的幅值和相位、谐波频率、扰动持续时间和振荡频率等。每类扰动分别叠加信噪比为 30 dB、40 dB 和 50 dB 的高

斯白噪声,选取 60% 的样本构成训练集,其余的构成测试集。在不同的噪声强度下分别采用 Binary-SVM、ML-RBF 和 ML-KNN 3 种多标签分类方法对上述电能质量扰动信号进行分类测试。表 3 给出了不同分类方法在特征优化前后的电能质量扰动分类结果。

从表 3 可知,在不同信噪比下同一分类器的准确率变化不大,可见 3 种分类方法均有一定的噪声鲁棒性;在优化特征组合后,3 种分类方法的准确率均比优化特征组合前有不同程度的提升,其中 ML-KNN 分类方法的提升效果最为明显,ML-RBF 分类方法的提升效果次之,对 Binary-SVM 分类方法而言,特征优化前后的准确率变化不大,分类效果只有较小的提升;3 种分类方法中分类效果最好的是 ML-RBF,在信噪比 30 dB 下优化特征组合后分类准确率达到 93.67%。

造成优化特征组合后对 3 种分类方法效果提升程度不同的原因在于不同分类方法的分类原理不同。本文基于欧氏距离计算不同特征组合的适应度,得到的特征组合满足类间差异大、类内稳定的特点。由于 ML-KNN 分类方法根据欧氏距离计算样本的  $K$  个近邻,因而优化的特征组合能更好地提升 ML-KNN 分类方法的分类效果。ML-RBF 分类方法采用均值聚类获得神经网络的基函数中心,优化后的特征组合使不同类别的样本更为集中的分布于类特征向量周围,因而能提高 ML-RBF 分类方法的分类准确率。Binary-SVM 分类方法引入非线性核函数使样本映射至高维空间,从而更容易得到分类超平面,但优化特征组合使特征维数降低,反而加大了样本的分类难度。因此优化特征组合可能降低 Binary-SVM 法的分类准确率,但由于高斯核的非线性映射能力,使特征维度减小带来的影响被削弱,故表 3 中 Binary-SVM 分类方法的分类效果在采用优化特征组合前后没有显著变化。

表 4 给出了优化特征组合前后的训练时间与分类处理时间对比。优化特征组合后,训练时间和分类处

表 3 不同分类方法在特征优化前后的电能质量扰动分类结果

Table 3 Results of power-quality disturbance classification by different methods, before and after feature combination optimization

扰动信号		分类准确率/%								
		ML-RBF 分类方法			ML-KNN 分类方法			Binary-SVM 分类方法		
		30 dB	40 dB	50 dB	30 dB	40 dB	50 dB	30 dB	40 dB	50 dB
单一扰动	优化前	97.50	96.43	96.96	97.14	93.93	96.79	96.96	95.36	97.14
	优化后	97.68	98.75	97.86	97.50	93.39	94.47	97.68	96.25	97.68
双重扰动	优化前	92.73	94.32	93.75	80.57	82.95	82.05	90.23	88.75	92.50
	优化后	95.80	95.57	95.46	87.73	84.89	84.09	91.59	88.98	93.18
三重扰动	优化前	86.25	84.38	85.21	56.35	59.79	60.21	83.85	82.71	82.81
	优化后	90.31	90.94	87.50	74.23	73.44	65.73	84.48	85.21	82.19
四重扰动	优化前	87.86	82.14	86.96	61.96	57.86	62.50	77.86	77.68	80.90
	优化后	90.89	88.75	90.18	69.29	70.00	75.36	76.25	76.61	80.90
平均值	优化前	91.09	89.32	90.72	74.01	73.64	75.39	87.23	86.13	88.34
	优化后	93.67	93.51	92.75	82.19	80.43	79.92	87.50	86.77	88.49

注:30 dB、40 dB、50 dB 为信噪比。

理时间均不同程度地降低。Binary-SVM 和 ML-KNN 分类方法的训练时间减小不显著,因为其主要影响因素是训练样本数,而不是特征维数;在训练 ML-RBF 分类方法过程中,使用最小二乘法得到网络连接权重,特征维度的减小能直接降低最小二乘法的计算量,故训练时间降低显著。

表4 不同分类方法在特征优化前后的训练时间与分类时间

Table 4 Training time and classification time of different classification methods, before and after feature combination optimization

分类方法	训练时间			分类处理时间		
	优化前/s	优化后/s	降幅/%	优化前/s	优化后/s	降幅/%
ML-RBF	20.239	16.491	18.52	8.152	7.984	2.05
ML-KNN	2.217	2.138	3.56	2.294	2.254	1.43
Binary-SVM	4.525	4.482	0.94	0.925	0.849	8.14

## 6 结论

为了解决电能质量分类中特征向量维数过大、特征选择没有统一标准从而影响分类效果的问题,本文提出一种基于改进遗传算法的特征组合优化选择方法。以改进小波能量熵作为原始特征,构造一种基于欧氏距离的适应度函数,并采用改进遗传算法对原始特征进行优化组合,最终运用多种电能质量分类方法进行验证,表明所提方法具有以下特点:

a. 优化后的特征组合能够提升多种电能质量扰动分类方法的准确率;

b. 特征组合优化算法具有较好的抗噪性和鲁棒性,能有效地提取原始特征中利于分类的特征;

c. 应用特征组合优化后能够提升分类方法的训练速度和分类速度;

d. 所提方法不依赖于特定的分类方法,充分利用了原始特征的信息优化特征组合,算法复杂度低,为电能质量多扰动的分类特征组合提供了新的方法和思路。

下一步的工作将考虑采用泛化能力更高的适应度函数来提高遗传算法优化特征组合的适用范围,以及对更多分类方法的适用性。

## 参考文献:

[1] 付学谦,陈皓勇. 基于加权秩和比法的电能质量综合评估[J]. 电力自动化设备,2015,35(1):128-132.  
FU Xueqian, CHEN Haoyong. Comprehensive power quality evaluation based on weighted rank sum ratio method[J]. Electric Power Automation Equipment, 2015, 35(1): 128-132.

[2] 丁建光,张沛超. 基于 Hoeffding Tree 的电能质量在线扰动分类[J]. 电力自动化设备,2014,34(9):84-89.  
DING Jianguang, ZHANG Peichao. Online power quality disturbance classification based on Hoeffding Tree[J]. Electric Power Automation Equipment, 2014, 34(9): 84-89.

[3] 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.  
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.

[4] 曲正伟,郝婉茹,王宁. 原子分解快速算法在电能质量扰动分析中的应用[J]. 电力自动化设备,2015,35(10):145-150.  
QU Zhengwei, HAO Wanru, WANG Ning. Application of atomic rapid decomposition algorithm in power quality disturbance analysis[J]. Electric Power Automation Equipment, 2015, 35(10): 145-150.

[5] 黄建明,翟合祚,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.

[6] 朱玲,刘志刚,胡巧琳. 基于 CWD 谱峭度的暂态电能质量扰动识别[J]. 电力自动化设备,2014,34(2):125-131.  
ZHU Ling, LIU Zhigang, HU Qiaolin. Recognition of transient power quality disturbances based on CWD spectral kurtosis[J]. Electric Power Automation Equipment, 2014, 34(2): 125-131.

[7] 杨耿煌,温渤婴. 基于量子行为粒子群优化-人工神经网络的电能质量扰动识别[J]. 中国电机工程学报,2008,28(10):123-129.  
YANG Genghuang, WEN Boying. Identification of power quality disturbance based on QPSO-ANN[J]. Proceedings of the CSEE, 2008, 28(10): 123-129.

[8] 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.

[9] 尹柏强,何怡刚,朱彦卿. 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):866-872.  
YIN Baiqiang, HE Yigang, ZHU Yanqing. 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): 866-872.

[10] 胡伟,李勇,曹一家. 基于 LOF 和 SVM 的智能配电网故障辨识方法[J]. 电力自动化设备,2016,36(6):7-12.  
HU Wei, LI Yong, CAO Yijia. Fault identification based on LOF and SVM for smart distribution network[J]. Electric Power Automation Equipment, 2016, 36(6): 7-12.

[11] 周维维,管春,卢伟国. 多标签分类法在电能质量复合扰动分类中的应用[J]. 中国电机工程学报,2011,31(4):45-50.  
ZHOU Luwei, GUAN Chun, LU Weigu. Application of multi-label classification method to categorization of multiple power quality disturbances[J]. Proceedings of the CSEE, 2011, 31(4): 45-50.

[12] KOLLER D. Toward optimal feature selection[C]//13th International Conference on Machine Learning. San Francisco, USA: [s.n.], 2000:284-292.

[13] 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.
- [14] 管春. 电能质量扰动分类中特征选择问题的研究[J]. 重庆邮电大学学报(自然科学版), 2013, 25(4): 514-517.  
GUAN Chun. Feature selection in power quality event classification[J]. Journal of Chongqing University of Posts and Telecommunications(Natural Science Edition), 2013, 25(4): 514-517.
- [15] GENCERÖ, ÖZTÜRK S, ERFIDAN T. A new approach to voltage sag detection based on wavelet transform[J]. International Journal of Electrical Power & Energy Systems, 2010, 32(2): 133-140.
- [16] SHENSA M J. Generalized and parallelized a Trous and Mallat algorithms to design non-uniform filter-banks[J]. IEEE Transactions on Signal Processing, 1992, 40(10): 2464-2482.
- [17] ROSSON O A, BLANCO S, YORDANOVA J, et al. Wavelet entropy: a new tool for analysis of short duration brain electrical signals[J]. Journal of Neuroscience Methods, 2001, 105(1): 65-75.
- [18] HOLLAND J H. Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control and artificial intelligence[J]. The Quarterly Review of Biology, 1994, 6(69): 126-137.
- [19] GIBAJA E. A tutorial on multi-label learning[J]. Acm Computing Surveys, 2015, 47(3): 1-38.
- [20] 吴忠强, 赵立儒, 贾文静. 计及 DG 与 STATCOM 的配电网重构优化策略[J]. 电力自动化设备, 2016, 36(1): 111-116.  
WU Zhongqiang, ZHAO Liru, JIA Wenjing. Optimal reconfiguration of distribution network with DG and STATCOM[J]. Electric Power Automation Equipment, 2016, 36(1): 111-116.
- [21] CHIH-WEI H, CHIH-JEN L. A comparison of methods for multi-class support vector machines[J]. IEEE Transactions on Neural Networks, 2002, 13(2): 415-425.
- [22] ZHANG M L. ML-RBF: RBF neural networks for multi-label learning[J]. Neural Processing Letters, 2009, 29(2): 61-74.
- [23] ZHANG M L, ZHOU Z H. ML-KNN: a lazy learning approach to multi-label learning[J]. Pattern Recognition, 2007, 40(7): 2038-2048.
- [24] 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.
- [25] 朱璐瑛, 贺鹏飞, 周洋. 基于 Coiflets 正交小波的超宽带脉冲波形设计[J]. 现代电子技术, 2008, 31(23): 1-3.  
ZHU Luying, HE Pengfei, ZHOU Yang. Ultra-wideband pulse design based on orthogonal Coiflets wavelet[J]. Modern Electronics Technique, 2008, 31(23): 1-3.
- [26] 张杨, 刘志刚. 一种基于时频域多特征量的电能质量混合扰动分类新方法[J]. 中国电机工程学报, 2012, 32(34): 83-90.  
ZHANG Yang, LIU Zhigang. 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.

#### 作者简介:



瞿合祚

瞿合祚(1993—), 男, 浙江温州人, 硕士研究生, 主要研究方向为电力系统运行与控制(**E-mail**: quhezuo@163.com);

刘恒(1980—), 男, 湖北孝感人, 高级工程师, 硕士研究生, 主要研究方向为电力系统运行与控制(**E-mail**: 9853214@qq.com);

李晓明(1955—), 男, 湖北应城人, 教授, 博士研究生导师, 主要研究方向为电力系统运行与控制、电能质量、智能电网等。

## Feature combination optimization for multi-disturbance classification of power quality

QU Hezuo<sup>1</sup>, LIU Heng<sup>2</sup>, LI Xiaoming<sup>1</sup>, HUANG Jianming<sup>1</sup>

(1. School of Electrical Engineering, Wuhan University, Wuhan 430072, China;

2. State Grid Hubei Xiaogan Power Supply Company, Xiaogan 432000, China)

**Abstract:** Aiming at the difficult classifier training and low classification accuracy of power quality disturbance classification due to the redundant feature parameters, an optimization method based on the improved genetic algorithm is proposed for the feature combination, which carries out the wavelet transform to extract the improved wavelet energy entropy as the primal feature for each layer of signals, constructs a fitness function based on Euclidean distance, applies the improved adaptive genetic algorithm to optimally select and combine the primal features as the optimal feature combinations for the power-quality disturbance classification. Single and mixed power-quality disturbances in different noise conditions are classified by three multi-label classifiers(Binary-SVM, ML-RBF and ML-KNN) respectively, and the simulative results show that, the proposed optimization method of feature combination effectively improves the training speed and classification accuracy of different classifiers.

**Key words:** power quality; wavelet transforms; genetic algorithms; feature combination; multi-label classification; classifiers