



(12) 发明专利申请

(10) 申请公布号 CN 116559650 A

(43) 申请公布日 2023. 08. 08

(21) 申请号 202310698716.2

(22) 申请日 2023.06.13

(71) 申请人 河北工业大学

地址 300401 天津市北辰区双口镇西平道
5340号

(72) 发明人 刘帼巾 刘达明

(51) Int. Cl.

G01R 31/327 (2006.01)

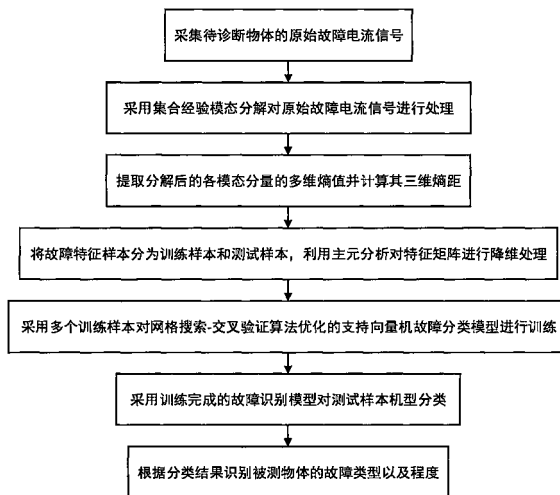
权利要求书3页 说明书7页 附图9页

(54) 发明名称

一种基于多维熵距的自动转换开关故障识别方法

(57) 摘要

本发明公开一种基于多维样本熵的自动转换开关故障识别方法,属于故障诊断技术领域。该方法首先采集自动转化开关电磁机构的原始故障电流信号,然后将电流信号进行集合经验模态分解,提取各经验模态分量的小波能量熵,频率谱熵及样本熵,对三种信息熵进行标准化处理并计算其多维熵距作为特征向量,其次选择主成分分析法对所有特征向量进行降维处理以得到最终的特征矩阵。将故障特征分为多个训练样本和测试样本,然后采用训练样本对基于网格搜索-交叉验证算法优化的支持向量机的故障识别模型进行训练并进行分类,最后根据分类结果识别样本的故障类型。本发明所提模型在处理多特征融合的故障中具有较高的创新性,在故障识别过程中具有较高的准确度。



1. 一种基于多维熵距的自动转换开关故障识别方法,其特征在于所述方法包括以下步骤:

- (1) 采集待诊断物体的原始故障电流信号;
- (2) 采用集合经验模态分解对原始故障电流信号进行处理;
- (3) 提取分解后的各模态分量的多维熵值并计算其多维熵距;
- (4) 将故障特征样本分为训练样本和测试样本,利用主元分析对特征矩阵进行降维处理;

(5) 采用多个训练样本对网格搜索-交叉验证算法优化的支持向量机故障分类模型进行训练;

- (6) 采用训练完成的故障识别模型对测试样本机型分类;
- (7) 根据分类结果识别被测物体的故障类型以及程度;

步骤(2)中所提取原始故障信息的进行集合经验模态分解的过程包括:

- (2-1) 将符号相反的白噪声信号成对地添加到原始信号,形成两个新的信号;
- (2-2) 对目标信号进行经验模态分解;
- (2-3) 循环步骤(2-1)和(2-2);
- (2-4) 将上述分解结果进行总体平均运算,得到分解结果:

$$\hat{i}(t) = \sum_{i=1}^n f_i(t) + r_n(t)$$

其中, $\hat{i}(t)$ 为被分解故障电流信号; $f_i(t)$ ($i=1,2,\dots,n$)为第*i*个模态分量; $r_n(t)$ 为残余分量;

分解得到的模态分量 $f_i(t)$ 需要满足以下条件:

整个时间序列中的极值点与过零点的数量最多相差一个;

任何时刻通过局部极大值和局部极小值而得出的包络线的均值为零;

进一步地,步骤(3)中在各模态分量中提取多维熵值作为特征值的过程包括:

步骤(3)中在各模态分量中提取多维熵值作为特征值的过程包括:

(3-1) 应用能量权重及能量熵的概念,计算各模态分量下的能量权重熵值;

(3-2) 根据样本熵的原理,计算各模态信号产生新模式的概率,从而求取各模态分量的样本熵值;

(3-3) 根据能量守恒原则,对时域信号通过傅里叶变换,并绘制处对数功率谱来反映各分量的功率谱熵值;

步骤(4)中将故障特征样本分为训练样本和测试样本的过程包括:

选择非故障状态下的不同熵值的样本数据,组成训练样本矩阵 X_{train} :

$$X_{train} = \begin{bmatrix} H_{n1} & H_{p1} & H_{s1} & S_{H1} \\ H_{n2} & H_{p2} & H_{s2} & S_{H2} \\ \vdots & \vdots & \vdots & \vdots \\ H_{n10} & H_{p10} & H_{s10} & S_{H10} \end{bmatrix}$$

其中, X_{train} 为十个周期样本中的4种样本熵值所组成的矩阵;

增加故障样本的周期数并将其作为检测样本矩阵 X_{test} ;

$$X_{test} = \begin{bmatrix} H_{n1} & H_{p1} & H_{s1} & S_{H1} \\ H_{n2} & H_{p2} & H_{s2} & S_{H2} \\ \vdots & \vdots & \vdots & \vdots \\ H_{n20} & H_{p20} & H_{s20} & S_{H20} \end{bmatrix}$$

步骤(5)中采用多个训练样本对网格搜索-交叉验证算法优化的支持向量机故障分类模型进行训练过程包括:

(5-1) 将多维度熵值输入进参数优化后的支持向量机模型,通过穷举法来搜索支持向量机待寻优参数的可能取值;

(5-2) 将不同故障状态作为支持向量机输出,并利用交叉验证来选择最优参数。

2. 根据权利要求2所述的一种基于多维熵距的自动转换开关故障识别方法,其特征量提取的特征在于所述步骤(3-1)及步骤(3-3),具体步骤如下:

(1) 应用能量权重及能量熵的概念,计算各模态分量 $f(t)$ 与原始电流信号 $I(t)$ 能量的比值将其作为对应模态分量的能量权重 λ_k ,具体如下:

$$\lambda_k = \frac{\left| \sum_{j=1}^h f_i^2(j) \right|}{\left| \sum_{j=1}^h I^2(j) \right|}$$

根据各分量的能量权重,定义能量权重熵 J 如下:

$$J = -\sum_{k=0}^N \lambda_k \lg \lambda_k$$

其中, h 为每周期数据点数, k 为第几个模态;

(2) 根据样本熵的原理,计算各模态信号中产生新模式的概率, $B^m(r)$ 为两个序列在相似容限 r 下匹配 m 个点的概率,而 $B^{m+1}(r)$ 为两个序列匹配 $m+1$ 个点的概率,样本熵定义为:

$$SampEn(m, r) = -\ln \frac{B^{m+1}(r)}{B^m(r)}$$

(3) 首先对原时域电流信号进行傅里叶变换,并计算频率谱序列 y_i 在对应频率处的功率谱值 S_i ,求解第 i 个功率谱在整个功率谱中所占的百分比 q_i ,并根据对应的对数功率来表示其对应的功率谱熵值,具体如下:

$$H_p = -\sum_{i=1}^n q_i \lg q_i$$

3. 根据权利要求2所述的一种基于多维熵距的自动转换开关故障识别方法,其特征在于步骤(4)利用主成分分析算法对支持向量机的参数进行优化,具体步骤如下:

(1) 对 X_{train} , X_{test} 进行标准化处理得到 X_{strain} 和 X_{stest} ;

(2) 求 X_{strain} 的协方差矩阵,得到 u 个特征值及对应特征向量 p_1, p_2, \dots, p_u ;

(3) 建立主元分析的模型 $\bar{X}strain$ 为:

$$\bar{X}strain = \sum_{i=1}^k t_i p_i^T$$

其中, t_i 表示第 i 个主元;

(4) 利用 $Xstest$ 矩阵求解得到的特征值及其对应的特征向量来计算 T^2 统计量的控制上

限 X_{stest} 及SPE统计量的上限 Q_{uc1} ;

(5) 采集不同的周期的变脸矩阵,重复步骤(1)~步骤(4),得到各个样本的 T^2 统计量和SPE统计量及对应上限 T_{uc1} 和 Q_{uc1} ,作为降维后的故障特征值。

4. 根据权利要求2所述的一种基于多维熵距的自动转换开关故障识别方法,其特征在于步骤(5)利用网格搜索-交叉验证算法对支持向量机的参数进行优化,具体步骤如下:

1) 确定网格搜索-交叉验证算法的参数,设置C和g的搜索范围、网格搜索法的搜索步长及交叉验证的折数;

2) 根据搜索步长,在搜索范围内对参数C和g的值进行搜索,利用穷举法,列出所有可能的参数组合;

3) 根据交叉验证原理,将加速退化试验得到的性能退化数据平均分成N组,取出其中一组作为测试集,其余N-1组作为训练集,使每一组数据都充当一次测试集,共得到N个组合;在进行SVM模型的训练和预测时,取N次预测结果的平均值作为最终结果。

一种基于多维熵距的自动转换开关故障识别方法

技术领域

[0001] 本发明属于故障识别技术领域,尤其涉及一种基于多维熵距的自动转换开关故障识别方法。

背景技术

[0002] 自动转换开关由一个(或几个)转换开关电器和其他必需的电器组成,用于监视电源电路、可以在电路发生故障时将负载电路从一个电源自动转换至另一个电源的电器,是保证系统供电的连续性必备电器。但随着动作次数的增加以及振动和温度等环境应力的作用下,自动转换开关的健康状况会产生退化,严重时会产生机械结构卡涩等故障,使其无法正常的对电路进行切换。因此,对自动转换开关的健康状况进行检测,是近年研究的重点。

[0003] 在故障诊断中,特征信号的选取是保证诊断准确性的前提,在自动转换开关切换电路时,其线圈电流会随着机构的动作而产生相应的变化,电流信号中包含着丰富的机械结构信息,可作为后续故障识别的依据。针对自动转换开关故障电流时域信号采集简单,但是易受其他信号的干扰且抗干扰能力较差,此外,电流信号非线性、非平稳特征导致的时域特征难以进行后续分析,因此,在频域方面进行特征提取的方法应运而生。为了更好的处理大量的检测信息,引入了信息熵的理论。传统小波分析可以将信号分析更加精细,对高频信号的处理分辨率高,但是所需处理的信息也大幅增加,小波能量熵则可以有效地减少系统的复杂度,而功率谱熵可以更好的描述电流信号发生故障时频谱能量的变化,样本熵则在处理复杂序列样本是的统计特征具有显著优势。但是仅从单信息熵进行特征提取存在偶然性,且适用范围有限无法处理复杂的多故障信号,而多特征信号融合,往往会造成噪声和冗余现象的出现。

发明内容

[0004] 针对目前单信息熵方法的不足,提供一种基于多维熵距的自动转换开关故障识别方法。

[0005] 该方法首先采集自动转化开关电磁机构的原始故障电流信号,然后将电流信号进行集合经验模态分解,提取各经验模态分量的小波能量熵,频率谱熵及样本熵,从而尽可能全面的解决单信号特征量存在的偶然性问题。为了能够对多维信号进行更好的数据融合,且消除三种信息熵不同量级的影响,对三种信息熵进行标准化处理并计算其多维熵距作为特征向量,其次选择主成分分析法对所有特征向量进行降维处理以得到最终的特征矩阵。将故障特征分为多个训练样本和测试样本,然后采用训练样本对基于网格搜索-交叉验证算法优化的支持向量机的故障识别模型进行训练,采用已训练完成的故障时识模型对测试样本进行分类,最后根据分类结果识别样本的故障类型及故障程度。结果表明,本发明所提模型在检测多特征融合故障的准确率更高,在故障识别过程中具有更强的鲁棒性。

[0006] 本发明提供的一种基于多维熵距的自动转换开关故障识别方法包括以下步骤:

[0007] (1) 采集待诊断物体的原始故障电流信号;

- [0008] (2) 采用集合经验模态分解对原始故障电流信号进行处理；
- [0009] (3) 提取分解后的各模态分量的多维熵值并计算其多维熵距；
- [0010] (4) 将故障特征样本分为训练样本和测试样本，利用主元分析对特征矩阵进行降维处理；
- [0011] (5) 采用多个训练样本对网格搜索-交叉验证算法优化的支持向量机故障分类模型进行训练；
- [0012] (6) 采用训练完成的故障识别模型对测试样本机型分类；
- [0013] (7) 根据分类结果识别被测物体的故障类型以及程度；
- [0014] 进一步地，步骤(2)中所提取原始故障信息的进行集合经验模态分解的过程包括：
- [0015] (2-1) 将符号相反的白噪声信号成对地添加到原始信号，形成两个新的信号；
- [0016] (2-2) 对目标信号进行经验模态分解；
- [0017] (2-3) 循环步骤(2-1)和(2-2)；
- [0018] (2-4) 将上述分解结果进行总体平均运算，得到分解结果：

$$[0019] \quad \hat{i}(t) = \sum_{i=1}^n f_i(t) + r_n(t)$$

[0020] 其中， $\hat{i}(t)$ 为被分解故障电流信号； $f_i(t)$ ($i=1, 2, \dots, n$)为第*i*个模态分量； $r_n(t)$ 为残余分量；

- [0021] 分解得到的模态分量 $f_i(t)$ 需要满足以下条件：
- [0022] 整个时间序列中的极值点与过零点的数量最多相差一个；
- [0023] 任何时刻通过局部极大值和局部极小值而得出的包络线的均值为零；
- [0024] 进一步地，步骤(3)中在各模态分量中提取多维熵值作为特征值的过程包括：
- [0025] (3-1) 应用能量权重及能量熵的概念，计算各模态分量 $f(t)$ 与原始电流信号 $I(t)$ 能量的比值将其作

[0026] 为对应模态分量的能量权重 λ_k ，具体如下：

$$[0027] \quad \lambda_k = \frac{\left| \sum_{j=1}^h f_i^2(j) \right|}{\left| \sum_{j=1}^h I^2(j) \right|}$$

[0028] 根据各分量的能量权重，定义能量权重熵 J 如下：

$$[0029] \quad J = - \sum_{k=0}^N \lambda_k \lg \lambda_k$$

[0029] 其中， h 为每周期数据点数， k 为第几个模态；

[0030] (3-2) 根据样本熵的原理，计算各模态信号中产生新模式的概率；

[0031] 将故障电流信号一个周期内 N 个采样点分为一组位数为 m 的向量序列 $I_m(1)$ ， $I_m(2)$ ， \dots ， $I_m(N-M+1)$ 并定义向量序列的距离为：

$$d = \max_{k=0, 1, \dots, m-1} (|i(n+k) - i(t+k)|)$$

[0032] 其中 d 为向量序列 $I_m(n)$ 与 $I_m(t)$ 之间的距离；

[0033] 对于给定的 $I_m(n)$ ，统计 $I_m(n)$ 与 $I_m(t)$ 之间距离小于等于 r 的 t 的个数，记作 $B^m(r)$ ，令 $k=m+1$ ，此时的个数记作 $B^{m+1}(r)$ ；

[0034] 其中 $B^m(r)$ 为两个序列在相似容限 r 下匹配 m 个点的概率,而 $B^{m+1}(r)$ 为两个序列匹配 $m+1$ 个点的概率。样本熵定义为:

$$[0035] \quad \text{SampEn}(m,r) = -\ln \frac{B^{m+1}(r)}{B^m(r)}$$

[0036] (3-3)根据能量守恒原则,首先对原时域电流信号进行傅里叶变换,并计算频率谱序列 y_1 在对应频率处的功率谱值 S_i ,并根据对应的对数功率来表示其对应的功率谱熵值,具体如下:

$$[0037] \quad H_p = -\sum_{i=1}^n q_i \lg q_i$$

[0038] 其中, q_i 为第 i 个功率谱在整个功率谱中所占的百分比:

$$[0039] \quad q_i = \frac{S_i}{\sum_{i=1}^n S_i}$$

[0040] 进一步地,步骤(3)中对故障电流信号提取多维熵值后构建特征矩阵的过程包括:

[0041] 将上述每一种信息熵分别看作一个维度,则这三种信息熵就被看作三个维度,由此组成了一个三维空间;

[0042] 分别以小波能量熵、功率谱熵、样本熵作为三维空间的 x, y, z 轴;

[0043] 为了消除三种信息熵不同量级的影响,对三种信息熵进行Z-score标准化处理;

[0044] 预先求出信号样本的三种信息熵的均值和标准差,再取前十个正常周期为一组样本,经Z-score标准化处理,得到这组样本的三种熵值(H_n, H_p, H_s);

[0045] 再将每个周期视为一个样本,同样经Z-score标准化处理,则可以求出对应于每个周期的熵点(H_{nx}, H_{px}, H_{sx});定义三维空间距离 S_H 为“信息熵距”有:

$$[0046] \quad S_H = \sqrt{(H_{nx} - H_n)^2 + (H_{px} - H_p)^2 + (H_{sx} - H_s)^2}$$

[0047] 选择不同状态下各变量的样本,组成特征矩阵 X ;

[0048] 进一步地,步骤(4)中将故障特征样本分为训练样本和测试样本的过程包括:

[0049] 选择非故障状态下的不同熵值的样本数据,组成训练样本矩阵 X_{train} :

$$[0050] \quad X_{\text{train}} = \begin{bmatrix} H_{n1} & H_{p1} & H_{s1} & S_{H1} \\ H_{n2} & H_{p2} & H_{s2} & S_{H2} \\ \vdots & \vdots & \vdots & \vdots \\ H_{n10} & H_{p10} & H_{s10} & S_{H10} \end{bmatrix}$$

[0051] 其中, X_{train} 为十个周期样本中的4种样本熵值所组成的矩阵;

[0052] 增加故障样本的周期数并将其作为检测样本矩阵 Z_{test} ;

$$[0053] \quad X_{\text{test}} = \begin{bmatrix} H_{n1} & H_{p1} & H_{s1} & S_{H1} \\ H_{n2} & H_{p2} & H_{s2} & S_{H2} \\ \vdots & \vdots & \vdots & \vdots \\ H_{n20} & H_{p20} & H_{s20} & S_{H20} \end{bmatrix}$$

[0054] 进一步地,步骤(4)中对训练样本和测试样本进行主元分析的过程包括:

[0055] (1)对 $X_{\text{train}}, X_{\text{test}}$ 进行标准化处理得到 X_{strain} 和 X_{stest} ;

[0056] (2)求 X_{strain} 的协方差矩阵,得到 u 个特征值及对应特征向量 p_1, p_2, \dots, p_u ;

[0057] (3) 建立主元分析的模型 $\bar{X}strain$ 为:

$$[0058] \quad \bar{X}strain = \sum_{i=1}^k t_i p_i^T$$

[0059] 其中, t_i 表示第 i 个主元;

[0060] (4) 利用 $Xstest$ 矩阵求解得到的特征值及其对应的特征向量来计算 T^2 统计量的控制上限 T_{uc1} 及 SPE 统计量的上限 Q_{uc1} ;

[0070] (5) 采集不同的周期的变脸矩阵, 重复步骤 (1) ~ 步骤 (4), 得到各个样本的 T^2 统计量和 SPE 统计量及对应上限 T_{uc1} 和 Q_{uc1} , 作为降维后的故障特征值, 总流程如图 2 所示;

[0071] 进一步地, 步骤 (5) 中采用多个训练样本对网格搜索-交叉验证算法优化的支持向量机故障分类模型进行训练过程包括:

[0072] (1) 确定网格搜索-交叉验证算法的参数, 设置 C 和 g 的搜索范围、网格搜索法的搜索步长及交叉验证的折数;

[0073] (2) 根据搜索步长, 在搜索范围内对参数 C 和 g 的值进行搜索, 利用穷举法, 列出所有可能的参数组合。

[0074] (3) 根据交叉验证原理, 将加速退化试验得到的性能退化数据平均分成 N 组, 取出其中一组作为测试集, 其余 $N-1$ 组作为训练集, 使每一组数据都充当一次测试集, 共得到 N 个组合。在进行 SVM 模型的训练和预测时, 取 N 次预测结果的平均值作为最终结果。

[0075] (4) 将测试样本输入到网格搜索-交叉验证算法优化的支持向量机的模型, 输出物体故障类型和程度。

[0076] 本发明从故障物品电流信号中提取多维信号熵, 并利用多维熵距的方法实现了三种信息熵的融合。多维熵距在衡量非线性和随机突变性的时间序列上十分有效, 可以准确地提取信号中的深层特征值, 在信号处理及提取故障特征方面有着较好的创新型。此外, 基于多维熵距提取特征与网格搜索-交叉验证算法优化的支持向量机相结合, 可以使该故障识别模型能够保持较高的准确率。本发明有以下显著特点:

[0076] (1) 本发明所提的多维熵距提取特征向量, 消除了单特征量偶然性的影响, 可以有效避免传统特征提取时易产生的误判现象, 同时所采用的主元分析技术对多维样本熵进行降维处理, 可以减少多维特征融合带来的噪声与冗余。

[0077] (2) 本发明所提的网格搜索-交叉验证算法优化的支持向量机是一种智能算法, 能够有效地解决对支持向量机参数设置时人工操作的耗时多和精度差的问题, 并有效地提高故障识别率。

[0078] (3) 本发明将基于多维熵距提取特征向量算法与网格搜索-交叉验证算法优化的支持向量机相结合, 系统性地提出了一种新的故障诊断方法。

附图说明

[0079] 图 1 为本发明基于多维熵距的自动转换开关故障识别方法的流程图;

[0080] 图 2 为本发明提取故障电流信号多维样本熵的流程图;

[0081] 图 3(a) 为某公司自动转换开关线圈短路故障下所提取的小波能量熵值;

[0082] 图 3(b) 为某公司自动转换开关铁心卡涩故障下所提取的小波能量熵值;

[0083] 图 3(c) 为某公司自动转换开关机械结构卡涩故障下所提取的小波能量熵值;

- [0084] 图3(d)为某公司自动转换开关衔铁行程不足故障下所提取的小波能量熵值；
- [0085] 图4(a)为某公司自动转换开关线圈短路故障下所提取的功率谱熵值；
- [0086] 图4(b)为某公司自动转换开关铁心卡涩故障下所提取的功率谱熵值；
- [0087] 图4(c)为某公司自动转换开关机械结构卡涩故障下所提取的功率谱熵值；
- [0088] 图4(d)为某公司自动转换开关衔铁行程不足故障下所提取的功率谱熵值；
- [0089] 图5(a)为某公司自动转换开关线圈短路故障下所提取的样本熵值；
- [0090] 图5(b)为某公司自动转换开关铁心卡涩故障下所提取的样本熵值；
- [0091] 图5(c)为某公司自动转换开关机械结构卡涩故障下所提取的样本熵值；
- [0092] 图5(d)为某公司自动转换开关衔铁行程不足故障下所提取的样本熵值；
- [0093] 图6为基于多维样本熵的支持向量机的故障信号训练集的故障识别率；
- [0094] 图7为基于多维样本熵的优化后支持向量机的故障信号测试集的故障识别率；

具体实施方式

[0095] 本发明方法包括如下步骤：

[0096] (1) 采集待诊断物体的原始故障电流信号；

[0097] (2) 采用集合经验模态分解对原始故障电流信号进行处理；

[0098] (3) 提取分解后的各模态分量的多维熵值并计算其三维熵距

[0099] (4) 将故障特征样本分为训练样本和测试样本，利用主元分析对特征矩阵进行降维处理；

[0100] (5) 采用多个训练样本对网格搜索-交叉验证算法优化的支持向量机故障分类模型进行训练；

[0101] (6) 采用训练完成的故障识别模型对测试样本进行分类；

[0102] (7) 根据分类结果识别被测物体的故障类型以及程度；

[0103] 工程时处理非平稳信号时，一般选择小波包分析对所采集信号进行处理，但小波包变换在故障信号分解时存在着能量泄露的问题，其分解不具有自适应性，对分解后各模态分量直接提取特征向量会使所需处理的信息大幅增加，增加了系统的复杂度。对此引入了小波能量熵的理论，但单特征量易受偶然性的影响，使得传统特征提取过程易产生误判现象。

[0104] 鉴于以上问题，为了克服单特征量故障识别准确率低的问题，本实例创新性地提出应用多维熵值作为原始故障电流信号的特征向量，可以全面的结合不同样本熵的优势，避免特征提取中的误判现象。为了说明多维熵值的优越性，本实例以自动转换开关为故障物体来说明方法的有效性，并对不同故障情况下自动转换开关的故障电流信号进行分析。实验采用某公司产品质量检测部门的试验测试数据，试验所用全寿命试验台包括供电装置、支撑装置、控制装置、数据采集装置及监控台，测试电器型号为ATSE-100/63A/4P，人为模拟线圈短路、铁心卡涩、机械结构卡涩及衔铁行程不足四种故障，采样频率为20KHZ，每种状态取40组数据，每组数据长度为1200个数据点。采集数据后对其进行集合经验模态分解，对分解后各模态分量进行小波能量熵、功率谱熵和样本熵分析，如图3、图4和图5所示。

[0105] 分析图3可知，不同故障类型的小波能量熵值有着明显差异，正常周期时的小波能量熵基本呈现一条水平线，整体波动很小，而故障周期的熵值波动较大且有增加的趋势。且

在发生铁心故障时,增长速度明显大于其他故障,因此小波能量熵对于区分铁心故障有着显著优势。

[0106] 分析图4可知,对于功率谱熵而言,其正常周期下波形仍然近似为线性,但是在故障周期时不同类型故障波形均产生波动,其中发生线圈短路故障时,其功率谱熵值在信号末端处于稳定上升阶段,而其他类型故障则存在下降的波动,因此功率谱熵对于区分线圈短路故障有着明显优势。

[0107] 分析图5可知,对于样本熵而言,不同故障类型的样本熵有着明显差距,当发生机械结构卡涩时,其样本熵值在正常周期下明显高于其他故障类型,且当发生衔铁行程不足的故障时,其样本熵变化较其他故障波动不明显,仅在周期末样本熵值发生快速增长,因此样本熵对于区分机械结构卡涩和衔铁行程不足有着明显优势。

[0108] 综上,基于不同样本熵对各故障类型的识别能力,采取多维熵可以有效地提取各故障样本的特征量。为了融合各信息熵的优势同时减少计算量,将多维熵值通过主元分析进行降维,从而得到各样本的 T^2 和SPE统计量及其控制上限 T_{uc1} 和 Q_{uc1} ,如表1和表2所示。

[0109] 表1某公司产品质量检测部门的试验测试数据 T^2 统计量及控制上限 T_{uc1}

T^2	线圈短路	铁心卡涩	机械结构卡涩	衔铁行程不足	
正常周期	1	0.43	0.23	0.07	0.27
	2	0.63	0.26	0.16	0.09
	3	0.12	0.03	0.10	0.11
	4	0.36	0.01	0.03	0.03
	5	0.14	0.17	0.00	0.19
	6	0.06	0.02	0.15	0.42
	7	0.12	0.20	0.32	0.33
	8	0.44	0.18	0.16	0.21
	9	0.43	0.31	0.21	0.34
	10	0.21	0.00	0.00	0.00
T_{uc1}	线圈短路	铁心卡涩	机械结构卡涩	衔铁行程不足	
故障周期	11	769	723	532	1.36×10^4
	12	1.35×10^4	4.71	3.97×10^4	833
	13	5.26×10^4	5.36×10^4	6.35×10^4	5.36×10^4
	14	3.24×10^4	3.17×10^4	5.64×10^4	1.36×10^4
	15	3.12×10^4	6.14×10^4	5.68×10^4	7.21×10^4
	16	4.32×10^4	2.34×10^4	3.94×10^4	4.35×10^4
	17	6.23×10^4	5.31×10^4	8.63×10^4	6.98×10^4
	18	4.23×10^4	1.99×10^4	4.56×10^4	3.24×10^4
	19	2.84×10^4	3.65×10^4	5.23×10^4	5.65×10^4
	20	3.22×10^4	2.04×10^4	3.99×10^4	2.36×10^4

[0110] 表2某公司产品质量检测部门的试验测试数据SPE统计量及控制上限 Q_{uc1}

<i>SPE</i>		线圈短路	铁心卡涩	机械结构卡涩	衔铁行程不足
正常周期	1	0.52	0.42	0.18	0.59
	2	0.17	0.17	0.34	0.23
	3	0.25	0.32	0.19	0.71
	4	0.71	0.15	0.21	0.47
	5	0.54	0.62	0.61	0.65
	6	0.63	0.14	0.47	0.31
	7	0.21	0.33	0.62	0.42
	8	0.57	0.00	0.01	0.27
	9	0.00	0.01	0.00	0.05
	10	0.18	0.47	0.07	0.03
<i>Q_{uci}</i>		线圈短路	铁心卡涩	机械结构卡涩	衔铁行程不足
故障周期	11	2.33×10^4	7.21×10^4	8.21×10^4	1.32×10^4
	12	1.31×10^4	8.33×10^4	3.53×10^4	8.30×10^4
	13	5.32×10^4	3.36×10^4	5.36×10^4	1.35×10^4
	14	7.32×10^4	6.31×10^4	4.74×10^4	2.36×10^4
	15	8.33×10^4	1.25×10^4	8.21×10^4	4.99×10^4
	16	9.22×10^4	5.32×10^4	7.11×10^4	5.72×10^4
	17	3.74×10^4	7.11×10^4	6.32×10^4	6.30×10^4
	18	5.32×10^4	3.25×10^4	3.21×10^4	4.71×10^4
	19	4.22×10^4	6.75×10^4	4.24×10^4	8.55×10^4
	20	5.31×10^4	1.42×10^4	6.31×10^4	2.73×10^4

[0111] 在上述实验数据中,共有4种故障类型,每种故障类型数据有60组,共计240组数据,现在随机从每种故障的60组样本中选取30组样本作为训练样本,剩下的30组样本作为测试样本,共计120组训练样本和120组测试样本;首先将测试集输入进待优化后的支持向量机模型,得到通过学习得到其最优的网络结构参数,接着对其参数进行重新赋值,将测试集数据输入到优化后支持向量机模型,训练集和测试集得到的故障识别率如图6和图7所示。

[0112] 从图6中可以看到未经优化的支持向量机模型对前两种故障的分类情况,并不准确,存在错分的情况。而经过优化后的支持向量机模型分类情况如图7所示,优化后的模型对前两种故障的分类准确率达到100%,且该模型对后两种故障仍能保持较高的准确率,仅存在一列机械结构卡涩的故障被错分至衔铁行程不足的故障,这充分说明了提取故障信号的多维信息熵能够有效地反映不同故障的特征,且经过优化后的支持向量机模型其故障识别准确率有着明显的提升,能够准确地对不同的故障进行识别。

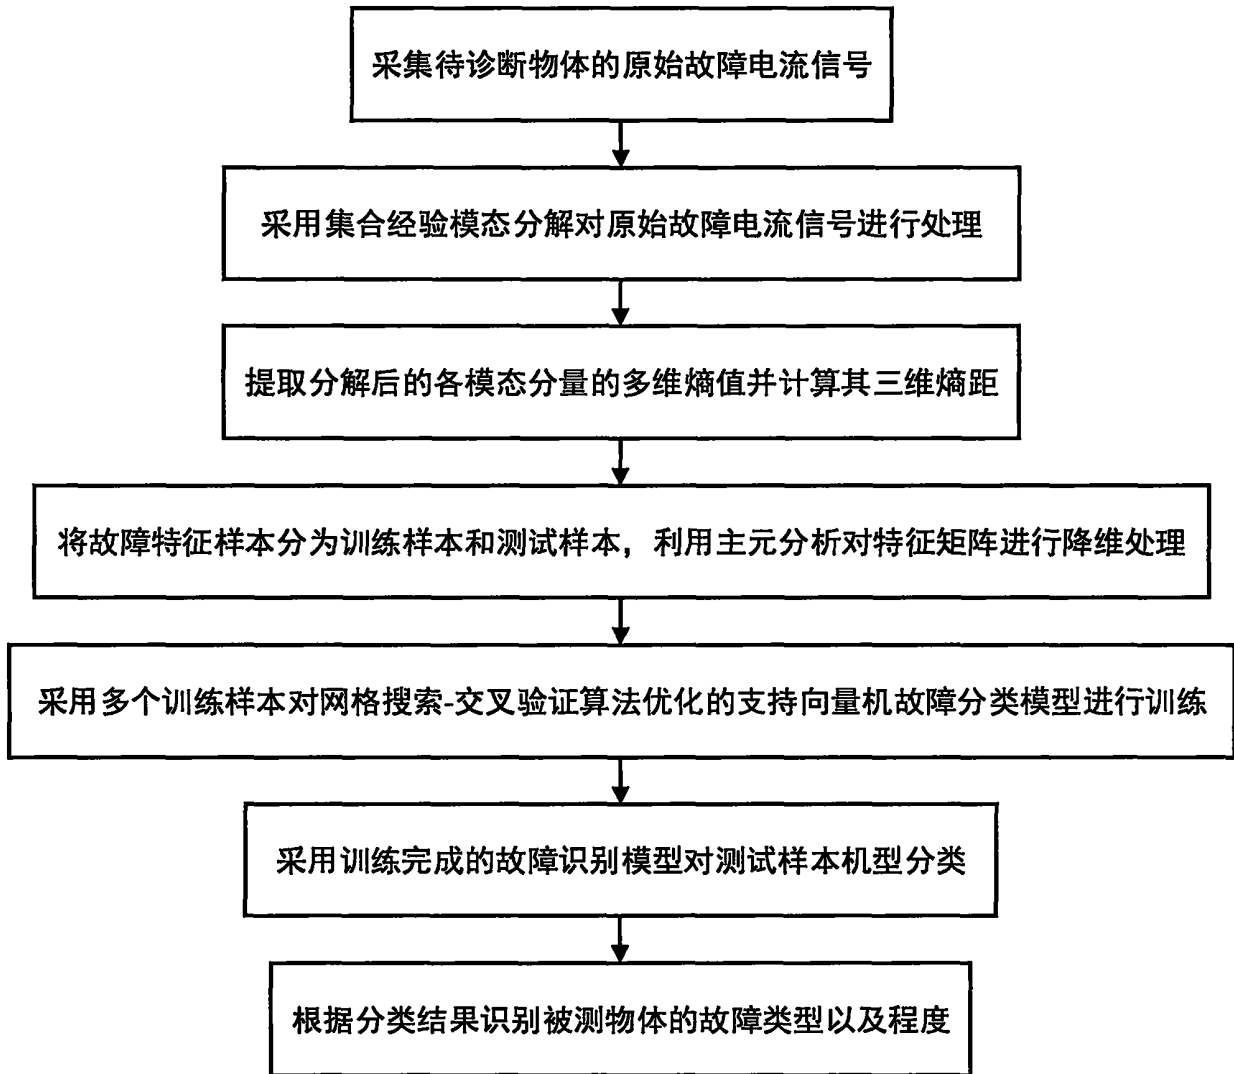


图1

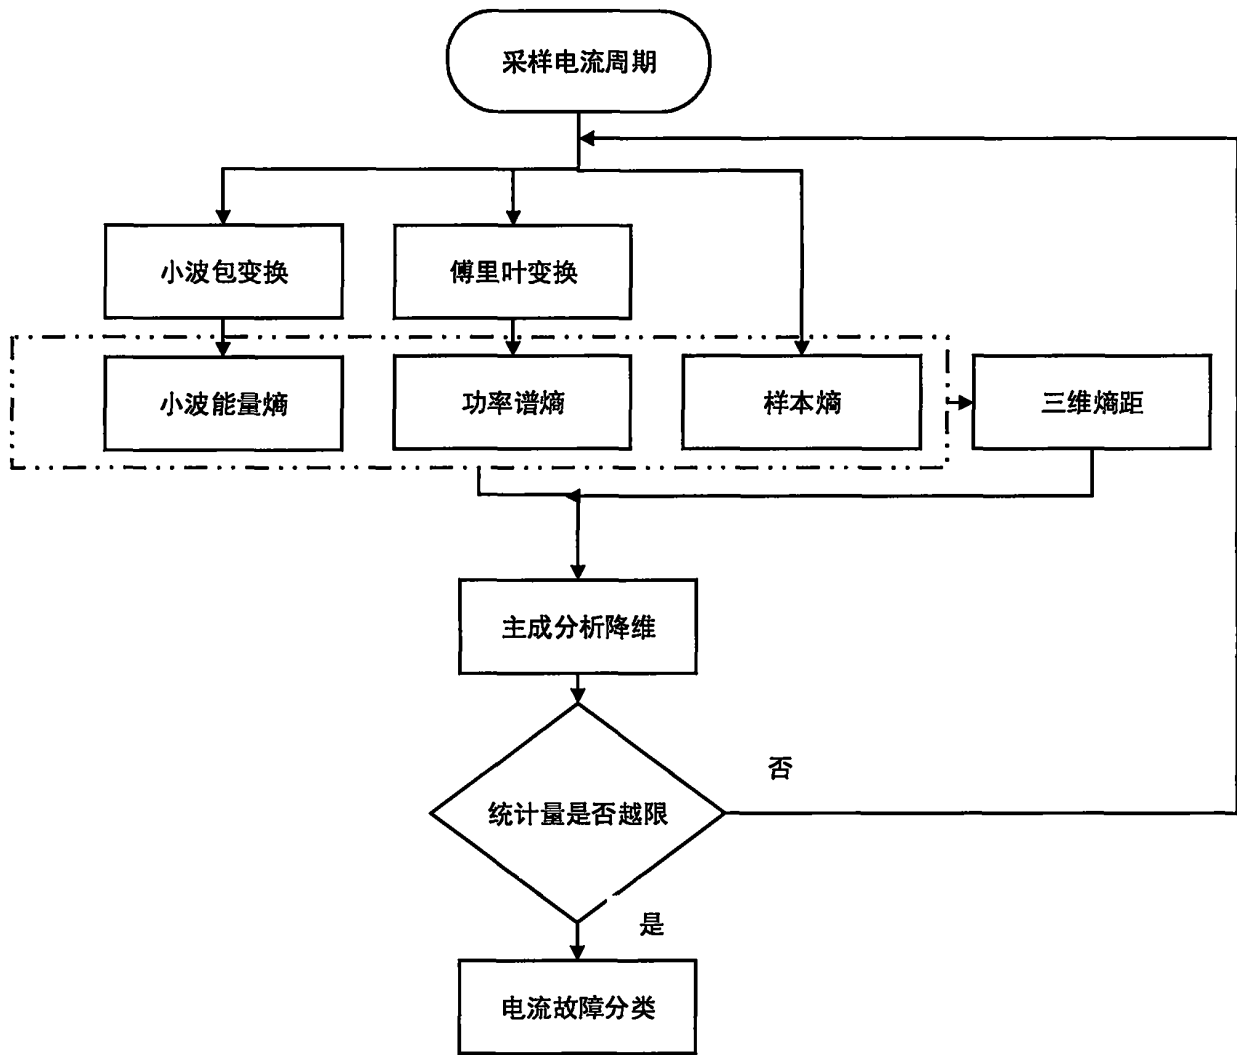


图2




图3(a)




图3(b)




图3(c)




图3(d)




图4(a)




图4(b)




图4(c)




图4(d)




图5(a)




图5(b)




图5(c)




图5(d)




图6




图7