

基于 SPSO 优化 Multiple Kernel-TWSVM 的 滚动轴承故障诊断*

徐冠基, 曾柯, 柏林

(重庆大学机械传动国家重点实验室 重庆, 400044)

摘要 双子支持向量机(twin support vector machine,简称 TWSVM)的核函数选择对其分类性能有着重要影响,TWSVM 其核函数一般是局部核函数或者全局核函数,这两种核函数的泛化能力和分类性能不能兼顾。笔者利用综合加权的高斯局部核函数和多项式全局核函数方法组成双核函数来改进 TWSVM 以提高其泛化能力和分类性能,并采用简化粒子群优化(simple particle swarm optimization,简称 SPSO)方法来对权值和参数进行优化,提出了 SPSO 优化 Multiple Kernel-TWSVM 模型,将该模型应用到滚动轴承故障诊断模式识别中。实验结果表明,双核 TWSVM 比单核 TWSVM 和反向传播(back propagation,简称 BP)神经网络具有更高的分类准确率。

关键词 滚动轴承;故障诊断;相空间重构;简化粒子群优化;双核双子支持向量机

中图分类号 TH133.33

引言

滚动轴承是机械设备的重要零部件,其运行状态关系着设备的正常运转,国内外很多学者对滚动轴承的状态监测做了大量的研究,并且随着近年来人工智能领域的迅猛发展,滚动轴承的故障诊断技术得到了长足的发展。信号获取的方法大多是采用加速度传感器测量振动信号,特征提取是状态辨识的大数据基础,常用的振动信号特征提取方法包括时域分析,频域分析以及时频域分析。其中:时域分析包括峰值,峭度,均方根值和方差等;频域分析包括快速傅里叶变换和离散傅里叶变换等;时频分析法包括小波变换,短时傅里叶变换,希尔伯特变换和 Winger 分布等。上述特征提取方法是建立在振动信号是线性和平稳信号的基础之上,而滚动轴承在高速运转过程中滚动体与内外圈的接触是非线性的,并且其载荷的分布以及接触刚度的变化也是非线性的,因此滚动轴承在产生故障时会使其运转周期消失并产生非线性振动^[1]。传统的线性、平稳特征提取技术,容易丢失重要的非线性状态信息,不能很好地从复杂非线性信号中提取真实反映其非线性振动本质的有效状态特征^[1]。分形维数和熵特征利

用相空间重构技术将滚动轴承振动信号映射到高维空间中以复原原始信号中的混沌特征^[2],分形维数是描述事物分形特性的一种有效方式,同时也是将事物分形特征进行量化的度量参数^[3],熵特征是用来反映系统的混乱程度和复杂性,熵累计得越多表示系统混乱程度越高,反之越低^[4],而系统的混乱程度和复杂性又与其故障状态有着密切的关联性。可见,利用分形维数和熵特征来对滚动轴承故障信号进行非线性特征提取能更加有效地辨识轴承的故障状态。

状态辨识的实质是机器学习与模式识别,近年来人工智能的快速发展促进了故障诊断技术的进一步提高,常用的模式识别方法有支持向量机和 BP 神经网络等,SVM 是一个二分类算法,对均衡或近似均衡分布的样本,分类效果显著^[5],如果遇到存在多种状态类别的多分类问题,SVM 只能通过二叉树或者偏二叉树等方法来细化分类,这样做可能会导致训练样本不均衡问题,而 SVM 在处理该类问题时往往不尽人意^[6]。Jayadev 等^[7]提出了 TWSVM,TWSVM 算法专门处理样本非均衡问题,其核心思想是构造两个非平行的超平面,使正类样本靠近正类超平面而负类样本尽可能地远离,使负类样本靠近负类超平面而正类样本尽可能地远离。TWS-

* 国家自然科学基金资助项目(51975067,51675064)
收稿日期:2017-06-13;修回日期:2017-11-29

VM 其训练速度较快,有着能较好求解异或问题和分类性能优越等明显的优势^[8],由于使用非平行的分类超平面,TWSVM 在解决两类样本交叉分布的分类问题时,具有更强的泛化能力^[9]。TWSVM 的主要原理在于是利用核函数来把高维向量空间中的内积计算转换为原低维空间中某个函数的函数值代替,以解决训练样本线性不可分问题。其核函数的选择与优化对其分类性能的提高起着至关重要的作用。不同种类的核函数也具有不同的特性,比如高斯核函数是局部核函数,多项式核函数是全局核函数,基于局部核函数和全局核函数的双核函数^[10],基于高斯核和多项式核的双核函数^[11]等。但这些核函数改进融合大多用于提高传统 SVM 模型分类性能中,尚未见对 TWSVM 核参数进行优化选择的报道。因此,为解决其核函数性能单调的缺点,提出了将加权的高斯核和多项式核双核函数引入到 TWSVM 分类模型,以提高 TWSVM 的分类性能和泛化能力,并采用简化粒子群优化(simple particle swarm optimization,简称 SPSO)^[12]算法对核函数权值,分类模型参数和核参数寻优。实验结果表明,基于分形维数和熵特征的非线性特征提取方法能够有效地提取滚动轴承的故障特征,并且双核 TWSVM 分类精度和泛化性能要高于单核 TWSVM,另外在同等条件下对比 BP 神经网络的分类精度,单核 TWSVM 和双核 TWSVM 模型分类性能要优于 BP 神经网络。

1 非线性特征提取

目前对于时间序列非线性特征的分析一般采用相空间重构法,时间序列相空间重构的原理是通过延时时间和嵌入维数把时间序列映射到更高维的空间中以便提取出原混沌时间序列中所含的非线性特征信息。

实现时间序列相空间重构的一种合适的方法是 G-P 算法^[13]。

1) 选取合适的延迟时间 τ 和嵌入维数 m 对时间序列 $X = \{x_1, x_2, \dots, x_N\}$ 进行相空间重构,得到重构的相空间如式(1)所示

$$\begin{bmatrix} \mathbf{y}_1^T \\ \mathbf{y}_2^T \\ \vdots \\ \mathbf{y}_{N_m}^T \end{bmatrix} = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(m-1)\tau} \\ x_2 & x_{2+\tau} & \cdots & x_{2+(m-1)\tau} \\ \vdots & \vdots & & \vdots \\ x_{N_m} & x_{N_m+\tau} & \cdots & x_{N_m+(m-1)\tau} \end{bmatrix} \quad (1)$$

其中: $N_m = N - (m - 1)\tau$ 。

2) 计算累积分布函数

$$C(r) = \frac{2}{N_m(N_m - 1)} \sum_{i=1}^{N_m} \sum_{j=1}^{N_m} H(u) \quad (2)$$

$$u = r - \mathbf{y}_i^T - \mathbf{y}_j^T$$

其中: $\mathbf{y}_i^T - \mathbf{y}_j^T$ 表示两个相点之间的距离; r 为所设定的阈值; $H(u)$ 为符号函数。

决定重构相空间的两个重要参数是延迟时间 τ 和嵌入维数 m , Takens^[14] 认为延迟时间 τ 和嵌入维数 m 的选取是相互独立的过程。一般延迟时间(采用自相关函数法或者互信息法^[15]), 嵌入维数 m 可选用 CAO 法^[16], G-P 方法^[17]。

本研究拟采用关联维数, 盒维数, 近似熵, 样本熵, 模糊熵和 Kolmogorov 熵来提取时间序列非线性特征。关联维数描述的是混沌时间序列具有某种确定规律及程度, 经相空间重构后的时间序列相互关联的点对个数越多, 就表明系统运动的规律性就越强^[2]。对于复杂机械设备的状态变化, 盒维数可以用来定量地描述分形边界的统计自相似特性^[18]。近似熵是用一个非负数来表示某时间序列的复杂性, 越复杂的时间序列对应的近似熵越大^[19]。模糊熵是衡量时间序列在维数变化时产生新模式的概率的大小, 序列产生新模式的概率越大, 则序列的复杂度越大, 熵值越大^[20]。样本熵分析方法只需要较短数据就可得出稳健的估计值, 是一种具有较好的抗噪和抗干扰能力的非线性分析方法^[21]。Kolmogorov 熵是非线性特性的度量特征量之一^[22], 描述非线性系统产生信息量多少和快慢程度的物理量^[23]。

2 基于 SPSO 的双核 TWSVM 原理

TWSVM 比较于传统的 SVM 所建立的一个超平面, TWSVM 构建了两个不平行的超平面, 并使正类样本靠近正类超平面而负类样本尽可能地远离, 而负类样本靠近负类超平面而正类样本尽可能地远离。非线性 TWSVM 的算法原理可参考文献[5, 8]。另外, 核函数的选择对 TWSVM 的分类性能具有重要的作用, 不同的核函数具有不同的分类特性, 如上所述高斯核函数属于局部核函数, 多项式核函数属于全局核函数。如何结合各个核函数的优点, 并对其进行优化对提高 TWSVM 的分类性能具有重要的作用。全局核函数泛化能力强而分类能力较弱, 局部核函数分类能力强而泛化能力弱, 因此可以看出核函数的泛化能力与分类能力是相互制约的, 这就需要找到一个平衡点让双核函数既具备较强的分类能力也要具备较强的泛化能力。因此将加权的

高斯核和多项式核双核函数其互补性强,应用到 TWSVM 分类模型中以解决其核函数性能单调的缺点,以此提高 TWSVM 的分类性能和泛化能力。

多项式核函数和高斯核函数是比较常见的两种核函数。

高斯核函数

$$K_{\text{RBF}}(x_i, x_j) = \exp\left[-\frac{|x_i - x_j|^2}{2\sigma^2}\right] \quad (3)$$

多项式核函数

$$K_{\text{poly}}(x_i, x_j) = [(x_i x_j) + c]^d \quad (4)$$

加权的高斯核和多项式核双核函数如下

$$K_{\text{mix}} = mK_{\text{poly}} + (1 - m)K_{\text{RBF}} \quad (5)$$

其中: K_{poly} 为多项式核; K_{RBF} 为高斯核; m 为调节核函数所占权值大小的参数。

假设矩阵 \mathbf{A} , \mathbf{B} 分别表示两类样本集, $\mathbf{A} \in \mathbf{R}^{m_1 \times n}$, $\mathbf{B} \in \mathbf{R}^{m_2 \times n}$, m_1, m_2 分别表示样本数量, n 表示维度。将双核函数 K_{mix} 带入 TWSVM 中,可以得到双核函数的 TWSVM 分类优化问题,如下

超平面 1

$$\begin{aligned} \min_{\alpha} \quad & \frac{1}{2} \alpha^T \mathbf{G} (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{G}^T \alpha - e_2^T \alpha \\ \text{s. t.} \quad & 0 \leq \alpha \leq c_1 \end{aligned} \quad (6)$$

其中: $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_{m_2})^T$; $\mathbf{G} = [K_{\text{mix}}(\mathbf{B}, \mathbf{C}^T) e_2]$; $\mathbf{H} = [K_{\text{mix}}(\mathbf{A}, \mathbf{C}^T) e_1]$; $\mathbf{C}^T = [\mathbf{A}^T, \mathbf{B}^T]$; $\mathbf{z}_1 = [\mathbf{u}^{(1)}, \mathbf{b}^{(1)}]^T = -(\mathbf{H}^T \mathbf{H})^{-1} \mathbf{G}^T \alpha$; e_1, e_2 为单位向量; c_1 为惩罚因子。

超平面 2

$$\begin{aligned} \min_{\gamma} \quad & \frac{1}{2} \gamma^T \mathbf{P} (\mathbf{Q}^T \mathbf{Q})^{-1} \mathbf{P}^T \gamma - e_1^T \gamma \\ \text{s. t.} \quad & 0 \leq \gamma \leq c_2 \end{aligned} \quad (7)$$

其中: $\gamma = (\gamma_1, \gamma_2, \dots, \gamma_{m_1})^T$; $\mathbf{P} = [K_{\text{mix}}(\mathbf{A}, \mathbf{C}^T) e_1]$; $\mathbf{Q} = [K_{\text{mix}}(\mathbf{B}, \mathbf{C}^T) e_2]$; $\mathbf{z}_2 = [\mathbf{u}^{(2)}, \mathbf{b}^{(2)}]^T = (\mathbf{Q}^T \mathbf{Q})^{-1} \cdot \mathbf{P}^T \gamma$; c_2 为惩罚因子。

最终判别公式为

$$\begin{aligned} \text{Label}(x) = \arg \min_{i=1,2} \{d_i\} = \\ \arg \min_{i=1,2} |K_{\text{mix}}(x, \mathbf{C}^T) \mathbf{u}^{(i)} + \mathbf{b}^{(i)}| = \\ \begin{cases} d_1 \Rightarrow x \in \text{class } 1 \\ d_2 \Rightarrow x \in \text{class } 2 \end{cases} \end{aligned} \quad (8)$$

其中: Label 为类别变量; class 为具体类别。

从式(3)~(8)可看出,双核 TWSVM 要优化的参数有惩罚因子 c_1 和 c_2 ,高斯核参数 σ ,多项式核参数 d, c 以及双核函数权值 m 。这些参数的选取对双核函数 TWSVM 的学习能力及泛化能力有很大的影响,只有选择出更优化的参数才能保证该方法的可靠性和稳定性,因此拟采用 SPSO^[12] 的方法来确定最优参数,由粒子位置来控制粒子的更新,解决了算法后期收敛慢的问题。

SPSO 算法首先是设定粒子数并对种群进行初始化,然后在每次迭代的过程中通过适应值函数来更新粒子的个体极值和全局极值,然后根据本次迭代后的个体极值和全局极值更新种群中所有粒子的位置。其位置更新方程为

$$\mathbf{x}_{\text{id}}^{t+1} = \omega \mathbf{x}_{\text{id}}^t + b_1 r_1 (\mathbf{p}_{\text{id}} - \mathbf{x}_{\text{id}}^t) + b_2 r_2 (\mathbf{p}_{\text{gd}} - \mathbf{x}_{\text{id}}^t) \quad (9)$$

其中: b_1 和 b_2 为常数项,一般取值为 2; r_1 和 r_2 为 $[0, 1]$ 的随机数; P_{id} 为个体极值; P_{gd} 为全局极值; x_{id} 为粒子位置; ω 为惯性权重。

式(1)右边第 1 项代表前一代粒子对后一代粒子的影响,第 2 项表示个体极值对粒子自身的反馈,第 3 项表示整个粒子种群的信息共享。SPSO 只有位置更新方程而没有速度参数项,其简化和优化了粒子群计算规模。

3 实验

为了研究笔者提出的非线性特征提取方法和 SPSO 优化的双核 TWSVM 对滚动轴承状态类别的辨识性能,本研究选取由凯斯西储大学提供的不同状态类别的滚动轴承振动信号作为研究对象,实验台如图 1 所示,包含了一个 1.5 kW 的电机,扭矩传感器,译码器以及一个示功器。选择驱动端轴承座上采集的加速度信号作为原始数据集,其采样频率为 12 kHz,选择的实验轴承为 SKF 的深沟球轴承,采用电火花加工以模拟轴承故障类型和故障程度。




图 1 滚动轴承模拟故障振动实验台

Fig. 1 Test board of fault simulation of rolling bearings

数据集共包含 4 种状态类别,分别为内圈故障,外圈故障,滚动体故障和正常状态,每种故障类别包含有 3 种故障尺寸,分别为 0.017 78, 0.035 56, 0.053 34 cm,再加上正常状态,共计 10 种状态类别,分别为正常,内圈故障为 0.017 78,外圈故障为 0.017 78,滚动体故障为 0.017 78,内圈故障为 0.035 56,外圈故障为 0.035 56,滚动体故障为

0.035 56, 内圈故障为 0.053 34, 外圈故障为 0.053 34, 滚动体故障为 0.053 34 cm。

在数据样本的 10 种标签类别中, 每类标签选取 50 个信号样本, 每个样本信号截取 2 048 个点, 一共构成 500 个信号样本。对 500 个信号样本提取非线性

性特征, 即每个样本分别提取关联维数, 盒维数, 近似熵, 样本熵, 模糊熵和 Kolmogorov 熵。由此组成维数为 500×6 的特征矩阵, 所列特征值都经归一化处理, 去除量纲影响, 其中 6 种故障类型部分特征向量参数如表 1 所示。

表 1 非线性特征值表

Tab. 1 Table of nonlinear eigenvalue

标签	状态类别(单位:cm)	关联维数	盒维数	近似熵	样本熵	模糊熵	K 熵
1	正常	2.339 1	0.096 2	1.266 4	1.326 7	1.171 1	0.141 0
2	内圈故障(0.017 78)	4.431 8	0.246 3	1.499 7	1.591 1	1.641 6	0.57 25
3	外圈故障(0.017 78)	-0.279 9	0.318 9	0.919 9	0.821 8	1.242 4	1.075 2
4	滚动体故障(0.017 78)	2.736 6	0.168 9	1.512 2	1.628 7	2.121 7	0.285 2
5	内圈故障(0.035 56)	0.233 5	0.169 12	1.409 3	1.387 6	1.515 5	0.282 9
6	外圈故障(0.035 56)	3.021 6	0.140 8	1.747 5	1.952 7	2.072 2	0.196 1
7	滚动体故障(0.035 56)	1.388 0	0.162 4	1.534 3	1.580 1	1.651 2	0.286 3
8	内圈故障(0.053 34)	0.126 0	0.290 7	1.038 4	0.930 3	1.567 4	0.930 6
9	外圈故障(0.053 34)	-0.080 2	0.287 1	0.963 7	0.659 5	0.806 1	1.047 7
10	滚动体故障(0.053 34)	2.475 0	0.141 9	1.753 6	1.981 0	1.985 7	0.204 1

从表 1 中可以看出, 本研究所选取的 6 个特征对故障类别有很强的辨识能力, 即参考某一特征下不同的状态类型所对应的特征值大小不同, 这是区别轴承状态类别的一个基础指标, 也即特征值不同对应的状态不同, 当参考某一个特征下不同状态的特征值会有相同, 但是这只是在 1 个特征下(也即 1 维空间下)的样本聚类特征, 当特征越多进而特征向量的维度越高, 在高维空间中不同状态类别的数据样本之间的区分度将会更好, 重叠现象将会减少甚至消失。

另外, 图 2 中的 (a)~(f) 分别为关联维数、盒维数、近似熵、样本熵、模糊熵和 Kolmogorov 熵的特征值图, 横坐标表示样本数, 即总共 500 个样本, 纵坐标表示特征值。从图 2 中可以看出, 不同状态类别特征值的相互区分度较好, 与表 1 所反映的情况基本一致, 也出现了某些特征值图在某些状态类别下的特征值出现了重叠, 正如前文所述那只是在 1 个特征也即 1 维空间下的样本聚类特性。文中共选取了 6 个特征, 这 6 个特征向量所组成的 6 维空间中, 每个状态类别样本可以聚集在不同的空间区域, 这有利于双核 TWSVM 建立分类超平面。

为了能够直观地观察不同故障类别的样本在空间中的聚集状态, 下面将画出不同类别样本的聚类图, 但是由于 6 维空间的点不能在人们所熟悉的笛卡尔坐标系中表示, 笛卡尔坐标系最多只能表示三维空间的点。因此为了简化该问题须在这 6 个特征中选择每 3 个特征为一组, 共 4 个组分别如图 3(a)~

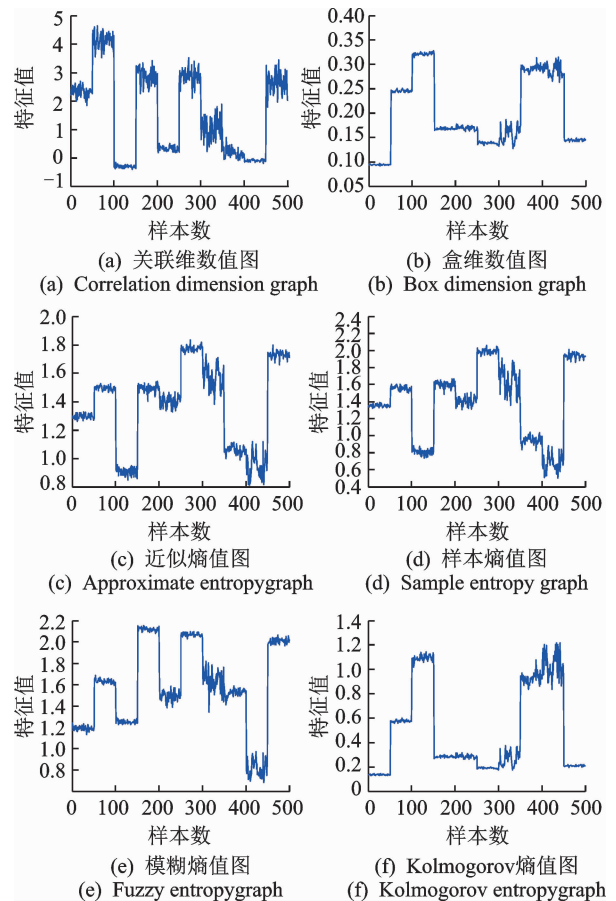


图 2 关联维数、盒维数、近似熵、样本熵、模糊熵和 Kolmogorov 熵的特征值图

Fig. 2 Eigenvalues map about correlation dimension, Box dimension, approximate entropy, sample entropy, fuzzy entropy and Kolmogorov entropy

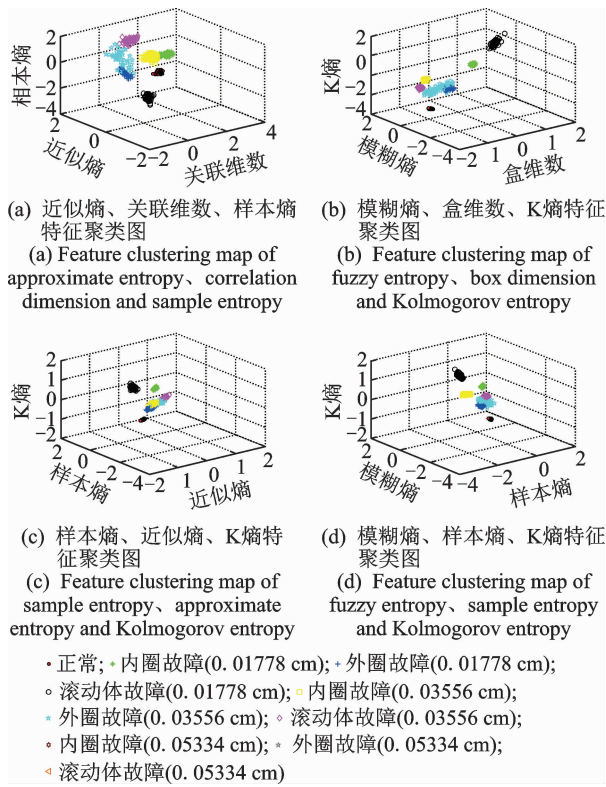


图 3 3 个特征值维度下的特征聚类分析

Fig. 3 Clustering analysis of features based on three characteristic value

(d)所示,以研究特征的聚类程度。从图 3 中可以看出,10 种状态类型的 3 维样本点在空间中表现出分类聚集特点,每一个块状或云状聚集点为一种故障类别,因此可以看出所选特征的聚类性很好。虽然观察图 3 可以发现不同状态类别的样本之间任有一些重叠,分析原因是因为所选取的特征值的维度只有 3 维,在将特征值维度扩展到 6 维之后,特征向量将被映射到更高维的空间中,将会具有更加明显的特征聚类特性。

本实验中对训练样本和测试样本分配策略是在总共 500 个样本中固定训练样本和测试样本数,文中选定训练样本数为 400 个,测试样本数为 100 个,

并且训练样本和测试样本互不交叉,然后再在总的 400 个训练样本中按 25%,50%,75%和 100%的比例抽取训练样本对分类模型进行训练,用 100 个测试样本进行分类预测得出当前比例下的分类准确率。

单核的 TWSVM 所用到的核函数是高斯核函数,高斯核函数是一种局部核函数,其分类能力强而泛化能力弱,为了兼顾 TWSVM 的泛化性能和分类能力,现将高斯核函数和多项式核函数通过加权的方式组成双核函数引入到 TWSVM 中,在双核 TWSVM 模型的训练中采用的 SPSO 方法对参数进行优化。在第 2 节中提到了需要优化的参数有惩罚因子 c_1 和 c_2 ,高斯核参数 σ ,多项式核参数 d 和 c 以及双核函数权值 m ,上述参数均无量纲。由于 SPSO 算法的计算量会随着优化参数的增加呈现近乎指数型增长,因此为了提高优化效率需减少待优化参数个数,多项式核函数中参数 c 和 d 的选择^[24]一般比较固定,取 $c=1, d=2$ 。需要优化的参数只剩下 c_1 和 c_2, σ 和 m ,试验表明只需设置种群大小为 30,当迭代次数为 30 次时适应度函数就可达到最大值。

表 2 列出了在训练样本比例为 50%的情况下 SPSO 对上述 4 个参数的优化情况。针对 10 种状态类别需要采用偏二叉树的方法来建立训练模型,因为 TWSVM 与 SVM 一样都是二分类模型,即一次只能进行两种状态类别的划分,如果遇到多分类问题,就要采用二叉树或者偏二叉树的方法来实现,采用偏二叉树对 10 种状态类别进行分类就需要训练 9 层分类模型,第 1 层区分第 1 类和第 2345678910 类,第 2 层区分第 2 类和第 3456789 类,以此类推,第 9 层区分第 9 类和第 10 类。 m 表示高斯核函数的权重,多项式核函数的权重自然为 $1 \sim m$ 。从表中可以看出,分类模型的不同层次中,高斯核和多项式核的权重有很大的差别,这就说明双核能通过调整权重的大小来适应不同的训练样本的空间分布特性以平衡分类超平面的泛化性能和分类能力。

表 2 训练样本比例为 50%时各层双核 TWSVM 模型参数取值情况

Tab. 2 The parameter values of each layer of double kernels TWSVM when the training sample ratio is 50%

各层双核 TWSVM 模型	σ	c_1	c_2	m	$1 \sim m$
第 1 层模型(区别标签 1 和标签 2345678910)	2.912 0	2.283 8	2.512 8	1.000 0	0
第 2 层模型(区别标签 2 和标签 345678910)	1.976 2	2.815 4	2.899 9	0.43 55	0.564 5
第 3 层模型(区别标签 3 和标签 45678910)	3.299 5	1.792 6	1.409 9	0.838 3	0.1617
第 4 层模型(区别标签 4 和标签 5678910)	0.618 8	1.729 4	1.560 2	0.540 2	0.459 8
第 5 层模型(区别标签 5 和标签 678910)	1.588 6	1.727 9	3.562 0	0.125 1	0.874 9
第 6 层模型(区别标签 6 和标签 78910)	2.655 0	0.849 3	2.222 6	0.486 2	0.513 8
第 7 层模型(区别标签 7 和标签 8910)	1.561 5	1.898 3	1.414 8	0.494 9	0.505 1
第 8 层模型(区别标签 8 和标签 910)	0.497 0	1.684 3	1.085 7	0.446 6	0.553 4
第 9 层模型(区别标签 9 和标签 10)	2.925 5	2.067 2	0.597 0	0.275 6	0.724 4

为了得到最终稳定的分类准确率,将每个训练样本比例下的训练和预测重复进行 10 次,由于训练样本的抽取是随机的,因此重复 10 次取平均能够得到较为稳定的预测精度。

表 3 给出了单核 TWSVM,双核 TWSVM 和 BP 神经网络在不同的训练和测试样本比例情况下的识别性能。从表中可以看出,3 种分类模型的识别准确率不管是在小样本和多样本情况下都能达到 90%以上,仔细分析主要是因为笔者提出的非线性特征提取方法所提取出的特征向量具有很高的聚类特性,也即类别辨识度高,这有助于建立精准的分类

超平面。另外,对比 TWSVM 和 BP 神经网络两种分类方法,TWSVM 整体上要高于 BP 神经网络,这是 TWSVM 分类性能优越能够有效提高故障辨识精度^[8],这也证明了 TWSVM 具有很强的泛化性能。在保证 TWSVM 泛化性能的基础上并提高 TWSVM 的分类精度,根据表 3 可以看出,基于双核的 TWSVM 相对于单核的 TWSVM 整体有一定提升,双核 TWSVM 的分类准确率能够达到 100%左右,特别是在小样本情况下,即训练样本比例只有 25%时,双核 TWSVM 相对于单核 TWSVM 分类准确率提高了 8%左右。

表 3 单核 TWSVM、双核 TWSVM 和 BP 神经网络在不同训练样本比例下识别性能

Tab. 3 Recognition performance of single kernel TWSVM, double kernels TWSVM and BP in different training samples

训练样本比例/%	总训练样本数	总测试样本数	单核 TWSVM		双核 TWSVM		BP 神经网络	
			正确分类样本 (10)次	平均准确率/ %	正确分类样本 (10)次	平均准确率/ %	正确分类样本 (10)次	平均准确率/ %
25	100	100	921	92.1	1 000	100.0	929	92.9
50	200	100	980	98.0	1 000	100.0	913	91.3
75	300	100	983	98.3	1 000	100.0	951	95.1
100	400	100	990	99.0	1 000	100.0	936	93.6

4 结束语

笔者将非线性特征分析方法用来对 10 种状态类型的滚动轴承振动信号进行特征提取。实验结果表明,所提取的特征样本具有很好的类别辨识度,这为双核函数的 TWSVM 模型的训练提供了准确的样本依据。另外,由于 TWSVM 本身具有解决两类样本交叉分布的分类问题时,具有更强的泛化能力以及分类准确性,实验中也证实了 TWSVM 的预测精度整体上要优于 BP 神经网络。但是 TWSVM 核函数的选择对于分类模型的泛化能力和分类性能有较大影响,而泛化能力和分类性能又是相互制约的,为了寻找平衡点,本研究将加权的高斯核和多项式核组成双核函数引入到 TWSVM 以提高其泛化能力和分类性能。从实验结果可以看出,在不同的训练样本比例下特别是小样本比例下,双核 TWSVM 的预测精度都要高于单核 TWSVM,这说明双核函数能通过调整权重的大小来适应和平衡分类超平面的泛化性能和分类能力。因此笔者提出的非线性特征提取方法和双核 TWSVM 分类模型对提高滚动轴承故障诊断准确率具有重要意义。

参 考 文 献

[1] 刘永斌. 基于非线性信号分析的滚动轴承状态监测诊

断研究 [D]. 合肥:中国科学技术大学, 2011.

[2] 吕金虎, 陆君安, 陈士华. 混沌时间序列分析及其应用 [M]. 武汉:武汉大学出版社, 2002.

[3] 郝研. 分形维数特性分析及故障诊断分形方法研究 [D]. 天津:天津大学, 2012.

[4] 朱明, 吴思东, 付克昌. 基于熵特征的高速列车故障诊断方法 [J]. 振动、测试与诊断, 2015, 35(2): 381-387.

Zhu Ming, Wu Sidong, Fu Kechang. Characteristic analysis of high-speed train vibration based on entropy feature [J]. Journal of Vibration, Measurement & Diagnosis, 2015, 35(2):381-387. (in Chinese)

[5] 董洪波, 申中杰, 姚亚峰. 基于 TWSVM 的煤矿井下钻机轴承故障诊断 [J]. 煤矿机械, 2015, 36(5): 298-300.

Dong Hongbo, Shen Zhongjie, Yao Yafeng. Based on TWSVM drill bearing in coal mine fault diagnosis [J]. Coal Mine Machinery, 2015, 36(5):298-300. (in Chinese)

[6] 王震. 基于双重支持向量机的分类算法研究 [D]. 长春:吉林大学, 2010.

[7] Jayadev A, Khemchandani R, Chandra S. Twin support vector machines for pattern classification [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2007, 29(5): 905-910.

[8] 于俊钊. 孪生支持向量机及其优化方法研究 [D]. 徐州:中国矿业大学, 2014.

- [9] 刘子军. 基于TSVM的铁路电力系统谐波检测方法研究[D]. 重庆:重庆大学, 2015.
- [10] Smits G F, Jordaan E M. Improved SVM regression using mixtures of kernels[C]// Proceeding of the 2002 International Joint Conference on Neural Networks. [S. l.]:IEEE, 2002: 2785-2790.
- [11] 薛欣, 贺国平. 基于多个混合核函数的SVM决策树算法设计[J]. 计算机工程与应用, 2007, 43(8): 142-144.
Xue Xin, He Guoping. Designing the algorithm of SVM decision tree based on many mixture of kernels[J]. Computer Engineering and Applications, 2007, 43(8):142-144. (in Chinese)
- [12] 胡旺, 李志蜀. 一种更简化而高效的粒子群优化算法[J]. 软件学报, 2007, 18(4): 861-868.
Hu Wang, Li Zhishu. A simpler and more effective particle swarm optimization algorithm[J]. Journal of Software, 2007, 18(4):861-868. (in Chinese)
- [13] Grassberger P, Procaccia I. Measuring the strangeness of strange attractors[J]. Physica D: Nonlinear Phenomena, 1983, 9(1/2): 189-208.
- [14] Takens F. Detecting strange attractors in turbulence [C]// Dynamical Systems and Turbulence, Warwick 1980. Heidelberg, Berlin: Springer, 1981, 898: 366-381.
- [15] 陈铿, 韩伯棠. 混沌时间序列分析中的相空间重构技术综述[J]. 计算机科学, 2005, 32(4): 67-70.
Chen Keng, Han Botang. A survey of state space reconstruction of chaotic time series analysis[J]. Computer Science, 2005, 32(4):67-70. (in Chinese)
- [16] Cao L. Practical method for determining the minimum embedding dimension of a scalar time series [J]. Physica D: Nonlinear Phenomena, 1997, 110(1/2): 43-50.
- [17] Grassberger P, Procaccia I. Characterization of strange attractors[J]. Physical Review Letters, 1983, 50(5): 346-349.
- [18] 刘希亮, 陈小虎, 王汉功. 基于分形盒维数的齿轮泵故障诊断[J]. 机床与液压, 2009, 37(7): 255-257.
Liu Xiliang, Chen Xiaohu, Wang Hangong. Fault diagnosis for gear pump based on fractal box dimension [J]. Machine tool & Hydraulics, 2009, 37(7): 255-257. (in Chinese)
- [19] 胥永刚, 何正嘉. 分形维数和近似熵用于度量信号复杂性的比较研究[J]. 振动与冲击, 2003, 22(3): 25-27.
Xu Yonggang, He Zhengjia. Research on comparison between approximate entropy and fractal dimension for complexity measure of signals [J]. Journal of Vibration and Shock, 2003, 22(3): 25-27. (in Chinese)
- [20] 刘慧, 谢洪波, 和卫星, 等. 基于模糊熵的脑电睡眠分期特征提取与分类[J]. 数据采集与处理, 2010, 25(4): 484-489. (in Chinese)
Liu Hui, Xie Hongbo, He Weixing, et al. Characterization and classification of EEG sleep stage based on fuzzy entropy [J]. Journal of Data Acquisition & Processing, 2010, 25(4):484-489. (in Chinese)
- [21] 赵志宏, 杨绍普. 一种基于样本熵的轴承故障诊断方法[J]. 振动与冲击, 2012, 31(6): 136-140.
Zhao Zhihong, Yang Shaopu. Sample entropy-based roller bearing fault diagnosis method [J]. Journal of Vibration and Shock, 2012, 31(6):136-140. (in Chinese)
- [22] 徐可君, 夏毅锐, 江龙平. 基于Kolmogorov熵的转子-机匣系统故障诊断研究[J]. 海军航空工程学院学报, 2006, 21(4): 437-440.
Xu Kejun, Xia Yirui, Jiang Longping. Fault diagnosis research of rotor-case system based on Kolmogorov entropy [J]. Journal of Naval Aeronautical Engineering Institute, 2006, 21(4):437-440. (in Chinese)
- [23] 黄明英, 王德明, 朱志宇. Kolmogorov熵在船舶电力系统可靠性研究中的应用[J]. 舰船科学技术, 2009, 31(3): 60-63.
Huang Mingying, Wang Deming, Zhu Zhiyu. Application of Kolmogorov entropy in reliability research of ship power system [J]. Ship Science And Technology, 2009, 31(3):60-63. (in Chinese)
- [24] 梁俊. 基于多核支持向量机的货币识别[D]. 长沙:中南大学, 2014.



第一作者简介:徐冠基,男,1986年5月生,博士、高级工程师。主要研究方向为虚拟仪器与智能测试、轨道交通装备故障预测与健康管理及智能运维技术。曾发表《基于阶比分析的风力发电机噪声音调判定》(《振动、测试与诊断》2010年第30卷第4期)等论文。

E-mail: xuguanji@sina.com