

基于 RQA 和 V-VPMCD 的滚动轴承故障识别方法^{*}

柏 林, 曾 柯, 徐冠基, 陆 超

(重庆大学机械传动国家重点实验室 重庆, 400044)

摘要 多变量预测模型模式识别(variable predictive model based class discriminate, 简称 VPMCD)利用样本特征值内在的相关性来建立特征学习模型,但是当训练样本较少时会导致模型预测不准确,因此提出了基于递归定量分析(recurrence quantification analysis,简称 RQA)和投票法多变量预测模型模式识别(voted variable predictive model based class discriminate,简称 V-VPMCD)的故障识别方法。该方法利用了递归定量分析对非线性、非平稳信号分析的鲁棒性和样本质量不高时处理的优势,以 VPMCD 作为分类方法,并用投票法优化了 VPMCD 方法,提升了算法的稳定性和识别率。对滚动轴承不同程度、不同类型故障的模式识别实验表明,该优化算法具有较高的识别准确率和稳定性。

关键词 滚动轴承; 故障诊断; 递归定量分析; 投票法多变量预测模型模式识别

中图分类号 TP206; TH133.33

引 言

在实际的机械故障诊断过程中,提取的蕴含机械故障信息的特征值相互之间往往存在着某种数学关系,而且这种内在在数学关系会因系统或工作状态类别的不同而存在明显的差异^[1]。Raghuraj 等^[2]提出了一种 VPMCD 的模式识别方法,该方法主要利用样本特征值内在的相关性来建立特征学习模型,由于模型可以是非线性的、高阶的,因而 VPMCD 方法可以和支持向量机、神经网络一样处理非线性多变量预测问题。但是 VPMCD 方法对小样本问题的处理能力不佳,在训练样本比例为 15%~30% 之间时, VPMCD 方法的预测精度^[3]只有 76.67%~87.63%,当训练样本比例为 35% 时, VPMCD 方法预测精度^[4]最高只有 82%。VPMCD 方法是基于最小二乘原理,当训练样本较少时会导致 VPM 模型预测不准确。另外单次 VPMCD 模型预测精度不高,在模式识别中可能会将某一预测样本投向错误的标签,即模型稳定性不好。杨宇等^[1]将量子遗传算法应用到了 VPMCD 中克服了 VPMCD 选择模型的单一性和泛化能力较弱的缺点。程军圣等^[5]为了解决 VPMCD 模型拟合过程中最小二乘法存在病态的问题将 BP 神经网络非线性回归

方法代替了最小二乘法解决了该问题。但是他们都没有解决 VPMCD 方法对小样本处理能力不佳的问题,即当训练样本较少时会导致 VPM 模型预测不准确。因此笔者将投票法应用到了 VPMCD 多变量预测模型中。投票法就是将多个分类器的输出值进行组合,形成一个输出值,从而产生一个组合分类器的过程^[6],常对分类存在不稳定或弱分类器集成时使用,是一种具有较强普适性的改进算法,对一次预测不准确的前提下,可以经过重复预测找出最有置信度的预测结果。另外由于滚动轴承的振动信号常常是复杂的非线性和非平稳性信号,因此利用非线性参数估计方法来提取隐藏在滚动轴承振动信号中的故障特征被越来越多的引入到轴承的故障诊断当中^[7]。借助于 RQA 法对非线性、非平稳信号分析的鲁棒性和样本质量不高时处理的优势^[8],在此基础上提出了基于 RQA 和 V-VPMCD 的轴承故障识别方法(RQA+V-VPMCD)。最后通过对滚动轴承不同故障类型的故障模式识别实验,并对比传统 VPMCD 算法, SVM 算法和 BP 神经网络算法的识别准确率,验证了该方法的有效性和准确性。

1 振动信号递归定量分析方法

滚动轴承在各种工况下,由于其载荷分布不均,

^{*} 国家自然科学基金资助项目(51675064,51475052);中央高校基本科研业务费资助项目(106112016CDJZR115502)
收稿日期:2016-07-25;修回日期:2016-10-27

刚度具有时变性, 内外圈与滚动体的间隙以及摩擦等非线性因素影响导致滚动轴承的振动具有强烈的非线性, 因此传统的时域或频域分析方法对于非线性信号的分析具有一定的局限性^[7]。考虑到 RQA 方法是一种有效的时间序列分析工具, 适于分析非线性动力学系统, 该方法对于非线性非平稳信号的分析有较强的鲁棒性, 使用 RQA 分析信号可以获得其他方法难以得到的可靠结论^[8-9]。因此本研究选择 RQA 方法对振动信号的非线性特征进行提取。

递归图^[10]可以表示为

$$R_{i,j}^{m,\epsilon} = \Theta(\epsilon - D_{i,j}^{m,\epsilon}) = \begin{cases} 0 & (D_{i,j}^{m,\epsilon} > \epsilon) \\ 1 & (D_{i,j}^{m,\epsilon} \leq \epsilon) \end{cases} \quad (1)$$

其中: ϵ 为参考阈值; $D_{i,j}^{m,\epsilon}$ 为递归图距离计算式。

$$D_{i,j}^{m,\epsilon} = \| \mathbf{X}(i)_m - \mathbf{X}(j)_m \| \quad (2)$$

其中: $\mathbf{X}(i)_m, \mathbf{X}(j)_m$ 为空间嵌入矢量。

$$\mathbf{X} = \{x(i), x(i + \tau), \dots, x(i + (m - 1)\tau)\}^T \quad (3)$$

其中: m 为重构维数; τ 为延迟时间; \mathbf{x}^T 表示 \mathbf{x} 矩阵的转置; i 满足 $1 \leq i \leq N_0 - (m - 1)\tau$ 。

由于 $\mathbf{X}(i)_m$ 与自身的距离为 0, 故递归图总有一条主对角线存在, 递归图中不规则的散列点反应了该系统中的随机成分, 与主对角线平行的线段代表系统中的某些周期成分。几个常见的递归定量分析特征^[8]如表 1 所示。

表 1 递归定量分析特征
Tab. 1 Features of RQA

特征	公式
递归率	$\alpha_{RR} = \frac{1}{N^2} \sum_{i,j=1}^N R_{i,j}^{m,\epsilon}$
确定率	$\alpha_{DET} = \frac{\sum_{l=l_{\min}}^N lp(l)}{\sum_{i=1}^N R_{i,i}^{m,\epsilon}}$
递归熵	$\alpha_{ENTR} = - \sum_{l=l_{\min}}^N p(l) \ln p(l)$
平均对角线长	$\alpha_L = \frac{\sum_{l=l_{\min}}^{N-1} lp(l)}{\sum_{l=l_{\min}}^{N-1} p(l)}$
层流率	$\alpha_{LAM} = \frac{\sum_{v=v_{\min}}^N vp(v)}{\sum_{v=1}^N vp(v)}$

2 VPMCD 算法及其存在的问题

在传统的 VPMCD 方法中^[2], 常用的特征 X_i 变量预测模型 VPM_i (the i th variable predictive model, 简称 VPM_i) 主要有以下几种形式: 线型模型 L、线型交互模型 LI、二次模型 Q 和二次交互模型

QI。以任一模型为例, 对特征量 X_i 建立预测模型 VPM_i , 采用特征向量中其余特征值 X_j ($j \neq i$) 来预测特征量 X_i , 有

$$X_i = f(X_j, b_0, b_j, b_{jj}, b_{jk}) + \zeta_i \quad (4)$$

其中: ζ_i 为预测模型误差; b_0, b_j, b_{jj}, b_{jk} 为模型参数, 通过训练样本拟合获得, 算法流程见参考文献^[2]。

VPMCD 算法基于最小二乘原则, 在真实情况中, 常常会遇到训练样本数量较少的小样本问题, 小样本情况下会产生两类问题: a. 样本数量 P 少于参数个数 Q 时, 拟合会舍去后面的 $Q - P$ 个参数, 导致拟合的不准确, 最终影响预测结果; b. 由于 VPMCD 算法基于拟合特性, 当样本数较少时, 训练样本的质量对最终预测结果影响非常大。图 1 给出了训练样本为较优子集和较劣子集两种情况下的 VPM_i 训练模型质量对比, 图中黑色和灰色圆点表示类别 1 样本聚类, 白色圆点表示类别 2 样本聚类, 每个样本由 (X_1, X_2) 两个特征组成。当训练样本集合能够反映出真实的样本群特性时, 预测效果较优, 当训练样本中离群点相对较多, 聚类特性不明显时, 拟合偏差较大, 造成与真实的样本群特性差异较大, 影响识别精度。

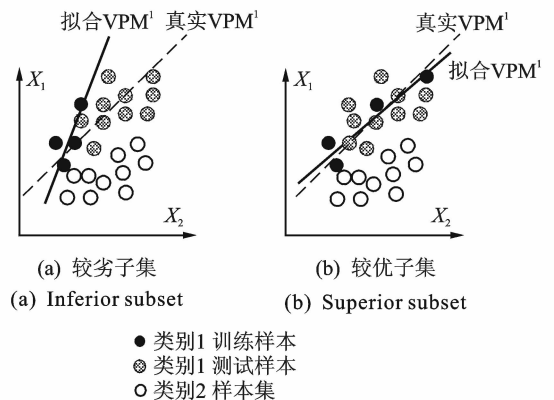


图 1 训练子集质量对拟合结果的影响

Fig. 1 The influence of the quality of training subsets on the fitting results

3 基于递归定量分析和 V-VPMCD 的轴承故障识别方法

在无法增加训练样本数量的情况下, 改进 VPMCD 算法抑制其不稳定性就显得尤为重要, 现将投票法引入到 VPMCD 算法中, 提出 V-VPMCD (Voted-VPMCD) 算法来改进针对小样本下 VPMCD 模型预测精度不高的问题。投票法常用于对分类存在不稳定性或弱分类器集成时使用, 是一种具有较强普适性的改进算法。投票法的分类很多, 其

中 Breiman^[11]提出的装袋算法是用多数投票法将多个预测结果合并成最终结果输出。算法基本原理首先是选定迭代次数,也即投票次数 $i(i=1,2,3,\dots,k)$,在样本集 $D=\{X_1, X_2, X_3, \dots, X_N\}$ 中有效地组合 n 个样本得到训练样本集 D_i ,用训练样本集训练分类器可以得到分类模型 M_i ,再将测试样本输入分类模型 M_i 返回预测标签,并对该标签计一票,最后由复合模型 M^* 统计得票数,所得票数最多的标签即为测试样本最终标签。已经证明,只要单个分类器相互独立,分类器的个数趋向无穷时,组合分类器的分类错误会趋向于 0^[6]。将投票法引入到 VPMCD 算法中,可以解决小样本学习时训练子集选取的不确定性对分类精度造成影响,因为 VPMCD 变量预测模型下的一次分类预测相当于在原 VPMCD 模型下多次分类预测的寻优,因此 VPMCD 算法可以保持小样本数下较高的分类精度。算法流程如下。

1) 获取需要分析的时间序列 $\{x(i) | i=1,2,\dots,N_0\}$ 。

2) 利用互信息法求取延迟时间 τ ,利用 CAO 法求取重构维数。

3) 重构至高维空间 $X=\{x(i), x(i+\tau), \dots, x(i+(m-1)\tau)\}^T$ 。

4) 设置递归阈值 ϵ 进行递归分析。

5) 计算 RQA 中共计 r 个递归量化参数: $\alpha_{RR}, \alpha_{DET}, \alpha_{ENTR}$ 等。

6) 重复步骤 1~5,计算得到 N 个信号样本的 r 个递归量化值,组成 $N \times r$ 的递归量化参数矩阵。对每一行样本所属的标签打上标记,对一个 p 分类问题总计有 p 类标签。

7) 随机选取训练样本集 $N_{train}^k, 1 \leq k \leq K, K$ 为投票次数,因而同一样本可能被多次选中,位于多个训练样本子集中。每一次投票中针对 r 个特征值的 p 分类问题可训练得 $r \times p$ 个预测模型 $VPM_i^n, i=1,2,\dots,r; n=1,2,\dots,p$ 。

8) 利用训练完的预测模型 VPM_i^n 对预测样本 N_{test} 下的某个未知样本的特征值 $[X_1, X_2, \dots, X_r]$ 进行预测计算,所有标签总共计算可获得 $r \times p$ 个预测值 \tilde{X}_i^n ,利用同一标签下预测值与真实值误差的平方和最小为判据,确定该次投票中预测样本所属标签类别。

9) 多次投票结果组成预测矩阵 $P_{i \times k}, 1 \leq i \leq N_{test}$,对某个预测样本统计多次投票中出现次数最多的标签作为该预测样本的最终标签。

4 实验验证

文中选取由 Case Western Reserve University 提供的滚动轴承故障实验数据,单位样本信号截取 $L=1024$ 个点,针对滚动轴承的 10 种故障状态,即 10 种标签类型,分别为正常、内圈故障(0.177 8 mm)、内圈故障(0.355 6 mm)、内圈故障(0.533 4 mm)、滚动体故障(0.177 8 mm)、滚动体故障(0.355 6 mm)、滚动体故障(0.533 4 mm)、外圈故障(0.177 8 mm)、外圈故障(0.355 6 mm)和外圈故障(0.533 4 mm),括号中的数字代表故障尺寸,采用电火花加工,为单点损伤。每种故障状态选取 50 组样本,10 类故障总计 500 组样本。

然后利用 RQA 对上述样本集提取特征。在进行递归分析的时候,以下 3 个参数的选取对于特征提取至关重要,即重构维数 m ,延时时间 τ 和参考阈值 ϵ 。CAO 法^[12]可选择合适的重构维数 m ,而延迟时间 τ 的选择多采用自相关函数法或互信息法^[13]。参考阈值 ϵ 一般取使得递归率 α_{RR} 约为 10% 时的值^[14]。然后计算得到由递归率 α_{RR} 、确定率 α_{DET} 、平均对角线长 α_L 、递归熵 α_{ENTR} 和层流率 α_{LAM} 这 5 个特征组成特征向量,得到一个维数为 500×5 的特征矩阵,即为特征样本集。

为了说明以 RQA 作为特征提取方法对 VPMCD 预测精度的提升,将 EMD 能量熵特征提取方法与其进行对比,得到如图 2 所示的 RQA-VPMCD 和 EMD 能量熵-VPMCD 准确率对比。从图 2 中可以看出 RQA 对于 VPMCD 的预测精度,特别是小样本情况下的预测精度提升作用明显。

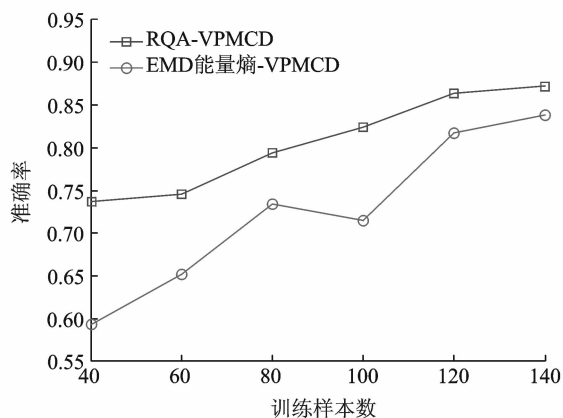


图2 RQA-VPMCD 和 EMD 能量熵-VPMCD 准确率对比

Fig. 2 The accuracy rate of RQA-VPMCD and EMD - VPMCD

分别随机选取 100 和 300 组样本作为训练样本集,输入 VPMCD 方法进行模型拟合。表 2 给出了不同训练样本数下 VPMCD 的最佳拟合模型,其中 X_i 表示第 i 个特征的预测模型 VPM_i 。在较少样本

的情况下,各类特征的预测模型会倾向于选择低阶模型,如线性模型 L 和线性交互模型 LI,而当样本数目较多,预测模型会更倾向于选择高阶模型,尤其是最复杂的二次交互模型 QI,其拟合残差最小。

表 2 训练所得各特征最佳拟合模型类型
Tab. 2 Best fitting model type of features after training

模型状态	训练样本少(100 个为例)					训练样本多(300 个为例)				
	X_1	X_2	X_3	X_4	X_5	X_1	X_2	X_3	X_4	X_5
正常状态	LI	LI	LI	Q	Q	QI	QI	QI	QI	QI
内圈(0.177 8 mm)	QI	Q	LI	LI	QI	QI	QI	QI	QI	QI
滚动体(0.177 8 mm)	QI	QI	LI	LI	QI	QI	QI	QI	QI	QI
外圈(0.177 8 mm)	QI	QI	QI	QI	QI	QI	QI	QI	QI	QI
内圈(0.355 6 mm)	Q	QI	LI	Q	Q	QI	QI	QI	QI	QI
滚动体(0.355 6 mm)	QI	QI	QI	QI	QI	QI	QI	QI	QI	QI
外圈(0.355 6 mm)	QI	LI	QI	QI	QI	QI	QI	QI	QI	QI
内圈(0.533 4 mm)	QI	QI	QI	QI	QI	QI	QI	QI	QI	QI
滚动体(0.533 4 mm)	QI	QI	LI	LI	LI	QI	QI	QI	QI	QI
外圈(0.533 4 mm)	QI	QI	L	L	LI	QI	QI	QI	QI	QI

表 3 给出了 VPMCD 算法对不同训练样本数和测试样本数情况下其预测模型的识别准确性。由表 3 可知,VPMCD 算法分类精度总体上随着训练样本的增加而增加,当训练样本数与预测样本数接近或相同时其分类性能达到较优状态。随着训练样本的增多,测试样本的减少,VPMCD 算法的计算耗

时呈现下降趋势。这主要是由于训练的计算开销主要为构建各个预测类型的 VPM_i ,其中包括最小二乘的拟合过程,只需对矩阵 QR 分解后求解即可;另外,对每个标签每类特征寻找其最小残差的拟合模型也具有一定的计算量。而预测的开销主要是将预测样本代入多类 VPM_i 中并计算比对误差最小的平方和标签,这是一个多次迭代和比较的过程,因此,原则上单位样本的预测耗时要大于训练耗时,文献[15]中的结论也证实了这点。

表 3 VPMCD 不同训练、测试样本数情况下识别性能
Tab. 3 Recognition performance of VPMCD based on different numbers of training and testing samples

总训练样本数	总测试样本数	正确分类样本(10 次)	平均准确率/%	平均耗时/s
100	400	3 297	82.43	0.281
120	380	3 283	86.40	0.250
140	360	3 140	87.22	0.218
160	340	2 997	88.15	0.174
180	320	2 854	89.19	0.124
200	300	2 738	91.27	0.086
220	280	2 585	92.32	0.081
240	260	2 422	93.15	0.072
260	240	2 261	94.21	0.068
280	220	2 070	94.10	0.064
300	200	1 872	93.60	0.060
320	180	1 697	94.28	0.051
340	160	1 500	93.75	0.050
360	140	1 316	94.00	0.047
380	120	1 138	94.83	0.044
400	100	945	94.50	0.042

表 4 给出了训练样本数为 100 时 10 种滚动轴承状态的投票的样例,表 4 中黑色加粗的数字即为该次投票投向的错误标签号,这也是单次 VPMCD 算法的准确率不是很高的原因。有许多测试样本在某一些训练样本拟合的模型情况下被预测正确,而在另外一些训练样本拟合的模型情况下被预测错误,即模型稳定性不高,因此多次投票就显示出了其优越性。在多次投票情况下,将出现次数最多的标签作为测试样本的最终标签,可以看到样例中的样本都获得了正确的预测标签。若出现像第 9 个样本在 10 次投票过程中标签“7”和标签“9”得票相同这种情况,根据装袋投票法^[11],若投票次数越多那么最后投票结果就越接近于真实结果,因此规定重新做 10 次投票,综合 20 次投票得出投票结果。若还是不能分出结果,就根据这两类得票数相同的标签中哪个标签在 20 次投票中第一次出现作为最后投票结果,经过 20 次投票后最终投票结果为“9”号标签,其与真实标签是相符的。

表4 V-VPMCD 算法的投票样例

Tab.4 Vote samples of V-VPMCD

标签	投票次数										投票结果
	1	2	3	4	5	6	7	8	9	10	
1	1	6	1	1	6	1	1	1	1	1	1
2	2	2	2	6	2	2	2	1	2	2	2
3	3	3	3	3	3	3	3	3	3	3	3
4	4	4	10	4	4	4	4	4	10	4	4
5	5	5	5	5	5	5	8	5	5	5	5
6	6	6	6	6	6	6	6	9	6	6	6
7	7	9	9	7	7	9	7	7	7	9	7
8	8	8	8	4	8	8	8	8	8	8	8
9	7	9	9	9	7	7	7	7	9	9	9
9	9	9	9	9	7	9	9	7	9	9	9
10	10	10	10	10	4	10	10	10	10	10	10

表5给出了V-VPMCD算法在不同训练样本数目下其预测模型识别性能概况。对比表3和表5可以看出,在训练样本数较少时,经过投票后的VPMCD算法其预测模型的准确度可以获得大约12%的提升,那是因为投票法增加了算法的稳定性,异常样本对整体识别精度的影响被弱化了。总体而言,相较于VPMCD预测模型,V-VPMCD预测模型在预测准确率方面提高3%~12%,因为一次预测相当于在多次VPMCD投票的综合结果中寻优,但是也正因为这个原因V-VPMCD算法的平均耗时要大于VPMCD算法。

表5 V-VPMCD不同训练、测试样本数情况下识别性能

Tab.5 Recognition performance of V-VPMCD based on different numbers of training and testing samples

总训练样本数	总测试样本数	正确分类样本(10次)	平均准确率/%	平均耗时/s
100	400	381	95.28	7.367
120	380	367	96.73	5.782
140	360	349	96.97	4.674
160	340	328	96.55	5.016
180	320	311	97.45	2.393
200	300	293	97.85	1.913
220	280	273	97.61	1.707
240	260	253	97.68	1.623
260	240	233	97.20	1.682
280	220	212	96.64	1.648
300	200	193	96.60	1.665
320	180	174	97.00	1.003
340	160	154	96.63	0.938
360	140	135	96.71	0.890
380	120	115	96.33	0.839
400	100	95	95.60	0.789

图3给出了在同一RQA特征样本集下V-VPMCD,VPMCD,SVM和BP神经网络这4种分类模型的预测准确率比较。

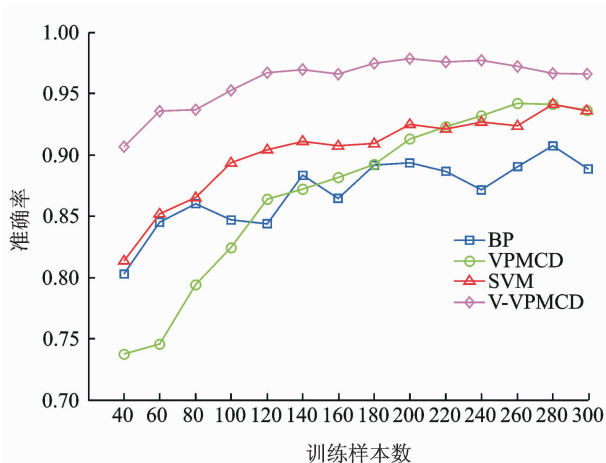


图3 BP,VPMCD,SVM和V-VPMCD识别率对比
Fig.3 General recognition rate of BP, VPMCD, SVM and V-VPMCD

从图中可以看出在各种训练样本数情况下,经过投票法改进的VPMCD分类模型较其余分类模型有明显的优势,并且在当训练样本极少(即40个样本,占总特征样本集的8%)的情况下其准确率也能达到90%以上。并且V-VPMCD分类模型当训练样本数与预测样本数接近或相同时其分类性能达到最优状态,但是当训练样本较充足时随着训练样本的增加V-VPMCD预测模型预测精度有微小下降,这是因为当训练样本较充足时影响预测精度的不再是训练样本的数量,并且文中在样本总和保持不变的情况下训练样本增加而测试样本减少,这时测试样本中的极少数离群样本对预测准确率的负面影响较测试样本量多时要大,文献[16-17]中也证实了这一点。VPMCD分类模型的识别准确率与训练样本数呈现很强的正相关性,在小样本情况下其预测精度很低。

对比其他文献,例如文献[3]中可以看到在训练样本比例为15%~30%之间时,VPMCD方法的预测精度只有76.67%~87.63%,文献[4]中当训练样本比例为35%时,VPMCD方法预测精度最高只有82%,这足以说明VPMCD方法在小样本情况下的识别性能不佳,而通过RQA+V-VPMCD方法能极大地提高其识别性能。

5 结束语

VPMCD算法识别准确率随着训练样本的递增呈现很强的正相关性,因而会面临很严重的小样本问题。因此笔者将投票法应用到了VPMCD多变量预测模型中,该方法核心思想就是对一次预测不准确的前提下,可以经过重复预测找出最有置信度的预测结果。同时利用RAQ对非线性、非平稳信

号分析的鲁棒性和样本质量不高时处理的优势,来提取滚动轴承振动信号的非线性特征。在此基础上提出的基于RQA和V-VPMCD的滚动轴承故障识别方法,根据其在滚动轴承故障模式识别实验中的应用分析可知:a. RQA有对过程平稳性要求低,分析鲁棒性好的优势,它能准确提取出滚动轴承振动信号中的非线性特征,对分类准确率的提升有很大贡献;b. 经过投票法优化后的VPMCD算法结合了VPMCD算法利用特征关联性作为分类依据的优越性,以投票的机制克服了单次拟合结果不稳定的情况,从多次投票中选取出现次数最多的标签来标记预测样本。预测标签准确性得到较大提升,提高了模式识别的精度和稳定性。

参 考 文 献

- [1] 杨宇,李紫珠,何知义,等. QGA-VPMCD智能诊断模型研究[J]. 振动与冲击, 2015, 34(13): 31-35.
Yang Yu, Li Zizhu, He Zhiyi, et al. QGA-VPMCD intelligent diagnosis model[J]. Journal of Vibration and Shock, 2015, 34(13): 31-35. (in Chinese)
- [2] Raghuraj R, Lakshminarayanan S. Variable predictive models—a new multivariate classification approach for pattern recognition applications[J]. Pattern Recognition, 2009, 42(1): 7-16.
- [3] 罗颂荣,程军圣,郑近德,等. GA-VPMCD方法及其在机械故障智能诊断中的应用[J]. 振动工程学报, 2014, 27(2): 289-295.
Luo Songrong, Cheng Junsheng, Zheng Jinde, et al. GA-VPMCD method and its application in machinery fault intelligent diagnosis[J]. Journal of Vibration Engineering, 2014, 27(2): 289-295. (in Chinese)
- [4] 刘吉彪,程军圣,马利. 基于PSODACCIW-VPMCD的滚动轴承智能检测方法[J]. 振动与冲击, 2015, 34(23): 42-47.
Liu Jibiao, Cheng Junsheng, Ma Li. An intelligent detection method for rolling bearings based on PSODACCIW-VPMCD[J]. Journal of Vibration and Shock, 2015, 34(23): 42-47. (in Chinese)
- [5] 程军圣,马利,潘海洋,等. 基于EEMD和改进VPMCD的滚动轴承故障诊断方法[J]. 湖南大学学报:自然科学版, 2014, 41(10): 22-26.
Cheng Junsheng, Ma Li, Pan Haiyang, et al. A fault diagnosis method for rolling bearing based on EEMD and improved VPMCD[J]. Journal of Hunan University: Natural Sciences, 2014, 41(10): 22-26. (in Chinese)
- [6] 王素格,杨军玲,张武. 基于最大熵模型与投票法的汉语动词与动词搭配识别[J]. 小型微型计算机系统, 2007, 28(7): 1306-1310.
Wang Suge, Yang Junling, Zhang Wu. Chinese Verb-verb collocation recognition based on maximum entropy model and voting[J]. Journal of Chinese Computer systems, 2007, 28(7): 1306-1310. (in Chinese)
- [7] 朱可恒. 滚动轴承振动信号特征提取及诊断方法研究[D]. 大连:大连理工大学, 2013.
- [8] Trulla L L, Giuliani A, Zbilut J P, et al. Recurrence quantification analysis of the logistic equation with transients[J]. Physics Letters A, 1996, 223(4): 255-260.
- [9] 尹少华,杨基海,梁政,等. 基于递归量化分析的表面肌电特征提取和分类[J]. 中国科学技术大学学报, 2006, 36(5): 550-555.
Yin Shaohua, Yang Jihai, Liang Zheng, et al. Recurrence quantification analysis based on surface EMG signal feature extraction and classification[J]. Journal of University of Science and Technology of China, 2006, 36(5): 550-555. (in Chinese)
- [10] Eckmann J P, Kamphorst S O, Ruelle D. Recurrence plots of dynamical systems[J]. Europhysics Letters, 1987, 4(9): 973-977.
- [11] Breiman L. Bagging predictors[J]. Machine Learning, 1996, 24(2): 123-140.
- [12] Cao Liangyue. Practical method for determining the minimum embedding dimension of a scalar time series[J]. Physica D: Nonlinear Phenomena, 1997, 110(1): 43-50.
- [13] 许岩. 含噪混沌时间序列相空间重构参数估计[D]. 重庆:重庆大学, 2013.
- [14] Marwan N, Romano M C, Thiel M, et al. Recurrence plots for the analysis of complex systems[J]. Physics Reports, 2007, 438(5): 237-329.
- [15] 程军圣,马兴伟,杨宇. 基于排列熵和VPMCD的滚动轴承故障诊断方法[J]. 振动与冲击, 2014, 33(11): 119-123.
Cheng Junsheng, Ma Xingwei, Yang Yu. Rolling bearing fault diagnosis method based on permutation entropy and VPMCD[J]. Journal of Vibration and Shock, 2014, 33(11): 119-123. (in Chinese)
- [16] 程军圣,马兴伟,杨宇. 基于VPMCD和EMD的齿轮故障诊断方法[J]. 振动与冲击, 2013, 32(20): 9-13.
Cheng Junsheng, Ma Xingwei, Yang Yu. Gear fault diagnosis method based on VPMCD and EMD[J]. Journal of Vibration and Shock, 2013, 32(20): 9-13. (in Chinese)
- [17] 刘刚,张洪刚,郭军. 不同训练样本对识别系统的影响[J]. 计算机学报, 2005, 28(11): 1923-1928.
Liu Gang, Zhang Honggang, Guo Jun. The influence of different training samples to recognition system[J]. Chinese Journal of Computers, 2005, 28(11): 1923-1928. (in Chinese)



第一作者简介:柏林,男,1972年11月生,博士、教授、博士生导师。主要研究方向为机械测试理论及方法、虚拟仪器、动态测试及故障诊断。曾发表《Measurement system for wind turbines noises assessment based on LabVIEW》(《Measurement》2011, Vol. 44, No. 2)等论文。
E-mail: Bolin0001@aliyun.com

