

利用非线性流形学习的轴承早期故障特征提取方法

栗茂林¹, 王孙安¹, 梁霖^{1,2}

(1. 西安交通大学机械工程学院, 710049, 西安; 2. 西安交通大学机械制造系统工程国家重点实验室, 710049, 西安)

摘要: 针对早期故障微弱特征难以提取的问题,提出了一种基于非线性流形学习的滚动轴承早期故障特征提取方法. 在由时域指标和小波频带能量组成的原始特征空间中,结合局部切空间排列学习算法的特点,采用散布矩阵分类测度指标,实现了局部邻域的优化选取,从而提取出最优的敏感故障特征. 通过实例应用,表明该方法有效地克服了主分量分析和非线性核主分量分析方法的不足,提取的融合特征敏感性更好,从而提高了故障模式的分类性能,实现了轴承的早期故障诊断.

关键词: 特征提取;流形学习;故障诊断;滚动轴承

中图分类号: TH17 **文献标志码:** A **文章编号:** 0253-987X(2010)05-0045-05

Feature Extraction for Incipient Fault Diagnosis of Rolling Bearings
Based on Nonlinear Manifold Learning

LI Maolin¹, WANG Sun'an¹, LIANG Lin²

(1. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To extract the incipient fault feature of rolling bearings, a novel feature extraction approach based on the nonlinear manifold learning algorithm is proposed. Constructing the original feature space with the time domain indexes and the wavelet frequency domain energies, the local target space alignment algorithm is employed for extracting nonlinear low dimensional manifold. According to the characteristics of the scatter matrix classification measure, the selection criterion of local neighborhood parameter is introduced to acquire the sensitive fault features. The experimental results for fault diagnosis of rolling bearings show that this approach, compared with the linear principal component analysis and nonlinear kernel principal component analysis, is more effective to extract the fault features from vibration signals, and enhances the classification ability of failure pattern.

Keywords: feature extraction; manifold learning; fault diagnosis; rolling bearing

滚动轴承的运行状态可直接影响整机的性能,其故障检测已成为一个重要的研究内容. 基于信号处理的冲击特征提取方法不断被提出,如文献[1]根据冲击响应设计了时频原子,提高了匹配追踪效果,文献[2]采用对冲击敏感的峭度指标来衡量增强型滤波器的提取质量,文献[3]从频域出发,采用提升小波包变换来提取信号的敏感频带特征. 但是,由于分解频带中包含了大量的信息,敏感特征的提取需

要人工干预,并受采样条件等因素影响,状态样本往往在特征空间中产生重叠,因此降低了特征的敏感性,使得后续分类的智能判别系统变得庞大.

对于从不同方面提取的反映设备状态的量化指标,依据其内在的线性或非线性关联特点,通过优化融合策略可以提高特征的敏感性,从而有效地提取出故障特征. 如基于线性降维的主分量分析方法^[4](PCA)、核主分量分析方法(KPCA)以及流形学习

方法^[5]等,都被应用于轴承的特征融合提取中.研究表明:PCA 由于忽略了非线性数据集存在的凸性和凹性,因此仅能提取出线性特征,不能找到真正的数据分布结构;KPCA 中的核函数对于类可分性测度的影响很大,选择不当会导致类可分性测度很小,使得不同类别的样本点在特征空间中相互重叠覆盖.流形学习为基于数据分布的内在维数分析提供了一种新的研究途径,如黎敏等人对高维相空间中重构的流形拓扑结构进行综合信息提取^[5],蒋全胜等人运用拉普拉斯特征映射的非线性降维方法保留了振动信号中内含的整体几何结构信息^[6].此研究成果为流形学习在故障诊断中的应用开辟了新思路.

本文针对轴承早期故障的特点,在局部切空间流形学习的基础上,在轴承振动信号提取的时频域原始特征空间中,基于散布矩阵分类测度指标,实现局部邻域优化选择和敏感特征提取,提出了一种基于切空间流形学习的轴承早期特征融合方法,通过与通用特征提取方法以及 PCA 和 KPCA 方法的对比分析,验证了该方法的有效性.

1 局部切空间排列算法

局部切空间排列算法^[7](LTSA)是通过逼近每个样本的切空间来构建低维流形的局部几何,并利用局部切空间排列求出整体低维嵌入坐标,恢复出流形等距的低维空间子集的方法.

1.1 局部线性拟合

对于样本空间矩阵 $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, $\mathbf{x}_i \in \mathbf{R}^m$, 每个样本向量 $\mathbf{x}_i$ 的 k 个邻域点可以构成局部邻域矩阵 $\mathbf{X}_i=[\mathbf{x}_{i_1}, \mathbf{x}_{i_2}, \dots, \mathbf{x}_{i_k}]$. 选择一组正交基向量 $\mathbf{Q}_i$ 构成邻域 $\mathbf{X}_i$ 的 d 维切空间, 计算邻域中每个样本向量 $\mathbf{x}_{i_j}$ ($j=1, 2, \dots, k$) 到切空间的正交投影向量 $\boldsymbol{\theta}_j^{(i)}=\mathbf{Q}_i^T(\mathbf{x}_{i_j}-\bar{\mathbf{x}}_i)$, 其中, $\bar{\mathbf{x}}_i$ 为邻域均值, $\mathbf{Q}_i$ 取 $\mathbf{X}_i(\mathbf{I}-\mathbf{e}\mathbf{e}^T/k)$ ($\mathbf{e}$ 为全 1 向量) 的前 d 个最大的左奇异向量. 因此, $\mathbf{X}_i$ 在切空间的投影所构成的局部坐标矩阵 $\boldsymbol{\Theta}=[\boldsymbol{\theta}_1^{(i)}, \boldsymbol{\theta}_2^{(i)}, \dots, \boldsymbol{\theta}_k^{(i)}]$ 描述了该邻域内最主要的几何结构信息.

1.2 局部坐标全局排列

LTSA 方法认为全局坐标应该反映由 $\boldsymbol{\theta}_j^{(i)}$ ($i=1, 2, \dots, N$, $j=1, 2, \dots, k$) 所决定的局部几何结构, 因此低维全局坐标向量需要满足

$$\boldsymbol{\tau}_{i_j}=\bar{\boldsymbol{\tau}}_i+\mathbf{L}_i\boldsymbol{\theta}_j^{(i)}+\boldsymbol{\varepsilon}_j^{(i)} \quad (1)$$

式中: $\mathbf{L}_i$ 是局部仿射变换矩阵; $\boldsymbol{\varepsilon}_j^{(i)}$ 表示重构误差向量. 记 $\mathbf{T}_i=[\boldsymbol{\tau}_{i_1}, \dots, \boldsymbol{\tau}_{i_k}]$, 则局部重构误差矩阵为

$$\mathbf{E}_i=[\boldsymbol{\varepsilon}_1^{(i)}, \dots, \boldsymbol{\varepsilon}_k^{(i)}]=$$

$$\mathbf{T}_i(\mathbf{I}-\mathbf{e}\mathbf{e}^T/k)-\mathbf{L}_i\boldsymbol{\Theta}_i \quad (2)$$

为了在低维特征空间中尽可能多地保留局部几何信息, 需要重构误差最小化, 即

$$\sum_i \|\mathbf{E}_i\|^2 = \sum_i \|\mathbf{T}_i(\mathbf{I}-\mathbf{e}\mathbf{e}^T/k)-\mathbf{L}_i\boldsymbol{\Theta}_i\|^2 = \min \quad (3)$$

显然, 式(3)取得最小值, 则

$$\mathbf{L}_i=\mathbf{T}_i(\mathbf{I}-\mathbf{e}\mathbf{e}^T/k)\boldsymbol{\Theta}_i^+ \quad (4)$$

$$\mathbf{E}_i=\mathbf{T}_i(\mathbf{I}-\mathbf{e}\mathbf{e}^T/k)(\mathbf{I}-\boldsymbol{\Theta}_i^+\boldsymbol{\Theta}_i) \quad (5)$$

式中: $\boldsymbol{\Theta}_i^+$ 是 $\boldsymbol{\Theta}_i$ 的 Moore-Penrose 广义逆. 设

$$\mathbf{B}=\mathbf{S}\mathbf{W}\mathbf{W}^T\mathbf{S}^T;$$

$$\mathbf{S}=[\mathbf{S}_1, \mathbf{S}_2, \dots, \mathbf{S}_N]; \quad \mathbf{T}\mathbf{S}_i=\mathbf{T}_i \quad (6)$$

式中: $\mathbf{S}_i$ 为 0-1 选择矩阵; $\mathbf{T}$ 为全局坐标矩阵, 其权值矩阵为

$$\mathbf{W}=\text{diag}(\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_N) \quad (7)$$

且有

$$\mathbf{W}_i=(\mathbf{I}-\mathbf{e}\mathbf{e}^T/k)(\mathbf{I}-\boldsymbol{\Theta}_i^+\boldsymbol{\Theta}_i) \quad (8)$$

为了唯一地确定 $\mathbf{T}$, 引入约束 $\mathbf{T}\mathbf{T}^T=\mathbf{I}_d$.

由于 $\mathbf{e}$ 是矩阵 $\mathbf{B}$ 的零特征值对应的特征向量, 所以取 $\mathbf{B}$ 的第 2 到第 $(d+1)$ 个最小的特征值对应的特征向量所组成的矩阵就是所求的 $\mathbf{T}$, 即为 $\mathbf{X}$ 中非线性主流形的正交低维全局坐标映射矩阵.

对于 LTSA 算法, 由于局部方法只需要考虑流形邻近点之间的关系, 无需求流形所对应的低维空间子集的凸凹性, 因此该算法有着更广泛的适用对象, 但也有着与其他流形学习方法同样的缺点, 即对于噪声和样本点密度比较敏感.

2 基于流形学习的故障特征提取方法

本文结合轴承早期故障特征提取的需求以及 LTSA 算法的优势, 提出了基于局部切空间流形学习的故障特征提取方法, 具体步骤如下.

2.1 原始特征空间构建

依据滚动轴承故障诊断的特点, 在时域波形中选择对冲击敏感的峭度特征、其他典型特征以及归一化特征, 来全面反映振动信号的时域微弱变化. 其次, 针对时域特征指标的局限性, 再从频域中提取出特征. 采用 db4 小波包函数进行 3 层正交小波包分解, 得到由全频带均匀划分的 8 个子频带的滤波信号, 将各频带信号的能量比作为频域统计特征, 即 $\left[\frac{E_{30}}{E}, \frac{E_{31}}{E}, \dots, \frac{E_{37}}{E}\right]$, 其中 $E=\sum_{j=0}^7 |E_{3j}|$ ($j=1, 2, \dots, 7$), E_{3j} 为频带 j 下的重构信号能量. 表 1 所列的时域和频域的 16 个特征构成数据表示 $\mathbf{X} \in \mathbf{R}^{N \times m}$,

其中 N 为样本数, m 为原始特征数, $m=16$.

表 1 特征维数和原始特征列表

特征维数	时域统计特征	特征维数	频域统计特征
1	标准差	9	E_{30}/E
2	峭度	10	E_{31}/E
3	均方根	11	E_{32}/E
4	平均幅值	12	E_{33}/E
5	峰值	13	E_{34}/E
6	峰值指标	14	E_{35}/E
7	波形指标	15	E_{36}/E
8	裕度指标	16	E_{37}/E

2.2 特征空间的局部邻域选取

对于原始特征空间中的点 $\mathbf{x}_i$, 基于欧氏距离确定出 k 个邻近点组成的 $\mathbf{X}_i = [\mathbf{x}_{i_1}, \mathbf{x}_{i_2}, \dots, \mathbf{x}_{i_k}]$, 由 LTSA 算法可知, 局部邻域的大小将直接影响低维流形的提取效果. 因此, 本文采用分类质量来衡量选取效果, 基于样本散布矩阵中的分类测度指标来优化 k , 即最优的邻域点数 k_{op} 将满足较大的类间距, 并保持较小的类内距

$$k_{\text{op}} = \arg \max_k \left(\frac{\min(\mathbf{D}_{ij}^b, \quad i, j = 1, 2, \dots, n)}{\max(\mathbf{D}_j^w, \quad j = 1, 2, \dots, n)} \right)$$

(9)

式中: $\mathbf{D}_{ij}^b$ 表示第 i 类与第 j 类之间的类间距向量; $\mathbf{D}_j^w$ 表示第 j 类的类内距向量; n 为类别数.

2.3 局部线性投影以及低维特征的提取

对每个样本点的邻域, 计算 $\mathbf{X}_i - \bar{\mathbf{x}}_i \mathbf{e}^T$ 的 d 个最大奇异值对应的左奇异向量, 并将这 d 个左奇异向量组成矩阵 $\mathbf{Q}_i$. 矩阵 $\mathbf{B}$ 的第 2 到第 $(d+1)$ 个最小特征值所对应的特征向量组成的矩阵 $\mathbf{T} = [\mathbf{u}_2, \mathbf{u}_3, \dots, \mathbf{u}_{d+1}]^T$, 即为提取的嵌入结果. 根据文献[8]的研究结果, 最优的嵌入维数 d 为故障类别数减去 1.

将流形学习的非线性约简能力应用于由时域和频域组成的原始特征空间中, 通过对状态样本的低维嵌入聚类来提取敏感特征. 由 LTSA 算法可知, 由邻域点构建的局部切空间决定了 $\mathbf{B}$ 中样本点间的关联性, 因此在敏感特征的融合中, 采用邻域选择的优化策略, 可保证同类样本点间具有强关联的切空间.

3 应用实例

3.1 实验对象

选择美国 Case Western Reserve University 电气工程实验室的滚动轴承实验数据^[9] 进行分析验证. 该数据来源于 SKF6205 滚动轴承, 其采样频率

为 48 kHz, 选择损伤尺寸为 0.355 6 mm 的内环、外环、滚动体故障以及正常状态下的数据, 其中每种状态下抽取了 50 组样本, 则 $\mathbf{X}$ 为 $N \times m$, 其中 $N=200, m=16$.

从图 1 中可知, 轴承内环故障表现出典型的冲击特征, 轴承滚动体故障的波形中随机出现单个冲击分量, 而轴承外环故障和正常状态的时域波形则非常类似. 轴承 3 种故障的特征频率分别为 159.9、139.2 和 105.9 Hz.




图 1 滚动轴承在 4 种状态下的时域波形

3.2 通用方法的特征提取分析

由图 2 可见, 轴承内环故障特征为 159.9 Hz, 其余 2 种故障信号均没有有效提取出轴承故障的特征分量, 因此无法与正常状态进行区分.




图 2 滚动轴承 3 种故障信号的包络解调谱

峭度指标虽然对冲击特征具有敏感性, 但是对于早期故障, 实验中轴承的滚动体故障与内环和外环故障下的峭度值均有重叠, 表明单纯利用峭度指标区分轴承早期故障具有一定的局限性.

3.3 特征融合提取的对比分析

为了验证本文方法的提取效果, 选择 PCA 和 KPCA 方法进行对比分析.

3.3.1 PCA 的特征融合提取 经 PCA 提取的前 3 个主分量 $P_1 \sim P_3$ 的特征值分别为 0.903 84、0.233 36 和 0.090 98, 滚动轴承的 4 种状态样本在三维子空间中的分布如图 3 所示.

由图 3 可见, 正常状态下的轴承振动具有平稳




图 3 PCA 提取的数据分布图

性,聚类质量较好. 轴承的故障状态数据分布较分散,在内环故障样本中有部分样本分布较远,而滚动体故障样本的分布介于外环故障和内环故障之间,这是由于滚动体故障表现为随机的冲击分量,其中没有冲击分量的样本与外环故障样本接近,而包含冲击分量的样本则与内环故障样本相接近. 由此可见,PCA 方法提取出的三维子空间中轴承的 3 种故障状态数据的聚类性较差,因此不能得到较好的分类识别效果.

3.3.2 KPCA 的特征融合提取 通过 KPCA 提取的 3 个主分量为 $K_1 \sim K_3$,滚动轴承的 4 种状态样本在三维子空间上的分布如图 4 所示,选用高斯函数 $k(x,x) = \exp(-\|x-x\|^2/\sigma)$ 作为核函数, σ 取 0.5. 在正常状态下,轴承振动具有较好的聚类质量,内环故障样本中有部分样本分布较远且与滚动体故障样本交叉,而外环故障样本的分布较好. 对比 PCA 的提取效果,由于采用了核函数,因此样本的聚类性能得到一定程度的提高.




图 4 KPCA 提取的数据分布图

3.3.3 局部切空间流形学习的特征融合提取 经 LTSA 提取的 3 个主分量为 $L_1 \sim L_3$,滚动轴承的 4 种状态样本在三维子空间上的分布如图 5 所示,其中最邻域点取为 7,本征维数为 3,即三维流形. 由本文基于流形学习的特征提取算法的特点可知,基于切空间的优化选择策略通过对同类样本间局部切空间的排列,建立了 B 中同类样本间的关联性,使得同种状态样本具有较近似的低维嵌入取值,从而

可以获得较好的聚类效果. 图 5 中所示的每种状态样本基本聚集在同一点,实现了 4 种状态样本数据的完全分离.




图 5 LTSA 提取的数据分布图

3.3.4 特征提取方法的对比分析 表 2 所示为在 PCA、KPCA 以及 LTSA 方法下,不同状态样本在三子空间中的类内距统计结果,并采取散布矩阵规则.

表 2 不同方法提取的样本类内距统计结果

状态模式	类内距		
	PCA	KPCA	LTSA
内环故障	0.282 2	0.106 2	$0.001\ 7 \times 10^{-13}$
滚动体故障	0.294 6	0.206 5	$0.819\ 2 \times 10^{-13}$
外环故障	0.108 8	0.068 4	$0.499\ 0 \times 10^{-13}$
正常状态	0.025 4	0.005 8	$0.090\ 7 \times 10^{-13}$

由表 2 可知,在 3 种算法中,PCA 算法的效果最差,KPCA 由于采用了核函数,聚类性能比 PCA 有一定的提高,其中内环、外环故障和正常状态的类内距均提高较大. LTSA 的聚类效果最好,其类内距均远远小于其他 2 种方法.

为了进一步对比特征融合的效果,从每种状态下选择 50 组测试数据集,利用 3 种方法提取的融合优化特征进行 k 近邻分类测试. 对于 PCA 方法,轴承的内环故障和正常状态样本可以全部识别,而轴承的滚动体故障和外环故障样本由于分布较散,二者的部分样本有重叠,因此产生了误判,状态识别率只有 90%. 在 KPCA 方法中,除了内环故障和正常状态的样本能够全部识别外,外环故障数据也能全部有效识别,但对于轴承的滚动体故障,其聚类性能仍然不理想,没有完全识别,状态识别率为 93.5%. LTSA 的特征提取方法能够完全识别 4 种状态的测试数据集,融合特征的状态识别率达到了 100%.

如图 6 所示,经 LTSA 提取的 $L_1 \sim L_3$ 可确定

出 4 种表示状态,分别为内环故障(0,0,0)、滚动体故障(0,0.14,0)、外环故障(0,0,0.14),以及正常状态(-0.14,0,0)。通过流形学习提取出不同状态的有效信息,为基于流形学习的状态监测提供了一种有效的工具。




图 6 流形学习提取的前 3 个低维嵌入分量

4 结 论

本文在局部切空间流形学习的基础上,提出了一种基于非线性流形学习的轴承早期故障特征提取方法。将流形学习的非线性约简能力应用于由时域和频域组成的原始特征空间中,通过对状态样本的低维嵌入聚类来提取敏感特征。其中,在敏感特征的融合中,提出了基于类内距与类间距分类测度指标的邻域优化选择策略,保证了同类样本点的强关联切空间,从而获得较好的聚类质量。从知识工程的角度来看,基于流形学习的低维嵌入分量可以为知识表达提供一定的借鉴。

参考文献:

[1] 费晓琪,孟庆丰,何正嘉. 基于冲击时频原子的匹配追踪信号分解及机械故障特征提取技术 [J]. 振动与冲击,2003,22(2):26-29.
FEI Xiaoqi, MENG Qingfeng, HE Zhengjia. Signal decomposition with matching pursuits and technology of extracting machinery fault feature based on impulse time-frequency atom [J]. Journal of Vibration and Shock,2003,22(2):26-29.

[2] 邵毅敏,周晓君,欧家福,等. 增强型滤波及冲击性机械故障特征的提取 [J]. 机械工程学报,2009,45(4):166-171.

SHAO Yimin, ZHOU Xiaojun, OU Jiafu, et al. Extracting impact feature of machine fault by using enhanced filtering [J]. Journal of Mechanical Engineering,2009,45(4):166-171.

[3] 胡桥,何正嘉,张周锁,等. 基于提升小波包变换和集成支持矢量机的早期故障智能诊断 [J]. 机械工程学报,2006,42(8):16-22.

HU Qiao, HE Zhengjia, ZHANG Zhousuo, et al. Intelligent diagnosis for incipient fault based on lifting wavelet package transform and support vector machines ensemble [J]. Chinese Journal of Mechanical Engineering,2006,42(8):16-22.

[4] 李常有,徐敏强,郭聿. 声信号的主分量分析应用于滚动轴承故障诊断 [J]. 声学技术,2008,27(2):271-275.

LI Changyou, XU Minqiang, GUO Song. Fault diagnosis of rolling element bearing based on principal component analysis of acoustic signal [J]. Technical Acoustics,2008,27(2):271-275.

[5] 黎敏,徐金梧,阳建宏,等. 一种基于流形拓扑结构的轴承故障分类方法 [J]. 控制工程,2009,16(3):358-362.

LI Min, XU Jinwu, YANG Jianhong, et al. Classification method of bearing faults based on topological structure of manifold [J]. Control Engineering of China,2009,16(3):358-362.

[6] 蒋全胜,贾民平,胡建中,等. 基于拉普拉斯特征映射的故障模式识别方法 [J]. 系统仿真学报,2008,20(20):5710-5715.

JIANG Quansheng, JIA Minping, HU Jianzhong, et al. Method of fault pattern recognition based on Laplacian eigenmaps [J]. Journal of System Simulation,2008,20(20):5710-5715.

[7] ZHANG Z Y, ZHA H Y. Principal manifolds and nonlinear dimensionality reduction via tangent space alignment [J]. SIAM Journal of Scientific Computing,2004,26(1):313-338.

[8] KOUROPTEVA O, OKUN O, HADIID A, et al. Beyond locally linear embedding algorithm,MVG-01-2002 [R]. Finland: Machine Vision Group, University of Oulu,2002:1-49.

[9] The Case Western Reserve University Bearing Data Center. Bearing data center fault test data [EB/OL]. [2009-10-01]. <http://www.eecs.cwru.edu/laboratory/bearing/>.

(编辑 管咏梅)