

基于有理双树复小波和 SVM 的滚动轴承故障诊断方法

孙珊珊 何光辉 崔 建

(重庆大学数学与统计学院 重庆 401331)

摘 要 滚动轴承故障类型被支持向量机(SVM)智能识别的关键是故障特征的提取。为了提取最优的故障特征,提高 SVM 的分类识别精度,提出了基于有理双树复小波和 SVM 的滚动轴承故障诊断方法。首先通过双树复小波包变换将非平稳的振动信号分解得到不同频带的分量,然后对每个分量求能量并作归一化处理,最后将从各个频带分量中提取的能量特征参数作为支持向量机的输入来识别滚动轴承的故障类型。研究结果表明该方法可以有效、准确地识别轴承的故障模式。

关键词 有理双树复小波变换,特征提取,支持向量机,滚动轴承,故障分类

中图分类号 TH133.3, TH165 **文献标识码** A

Fault Diagnosis Method of Rolling Bearing Based on Dual-tree Rational-dilation Complex Wavelet Packet Transform and SVM

SUN Shan-shan HE Guang-hui CUI Jian

(School of Mathematics and Statistics, Chongqing University, Chongqing 401331, China)

Abstract In order to improve the recognition accuracy of SVM classification, a fault diagnosis method was proposed based on dual-tree rational-dilation complex wavelet transform and support vector machine(SVM), according to the characteristics of rolling bearing fault vibration signal. Firstly, the fault signal is decomposed into several different frequency band components through dual-tree rational-dilation complex wavelet transform. Secondly, normalization processing is made from the energy of each component. Finally, the energy characteristics parameters of each frequency band component are taken as input of the SVM to identify the fault type of rolling bearing. The experimental results prove that the proposed method can identify the fault type accurately and effectively.

Keywords Dual-tree rational-dilation complex wavelet transform, Feature extraction, SVM, Rolling bearing, Fault identification

1 引言

滚动轴承在各种机械设备中应用非常广泛,因此滚动轴承故障检测与诊断具有重要的意义^[1]。故障诊断的关键是故障特征提取机理的研究^[2]。为了提取出滚动轴承的故障特征,人们提出了很多方法^[3],小波分析(WT)是一种全新的时频分析方法,对非平稳信号具有宽频响应的特点,在低频处有较高的频率分辨率,在高频处有较高的时间分辨率,适合分析非平稳信号,但小波变换中输入信号一个很小的平移会使小波系数产生非常明显的变化,而且信号分解和重构中容易产生频率混叠,不能真实反映信号的频率成分;双树复小波变换^[4]不仅具有近似平移不变性,而且能有效消除频率混叠;但是同传统的小波变换相比,双树复小波变换对高频部分没有进行细分,从而也不能更准确地提高故障信息;有理双树复小波变换(dual-Tree Rational-Dilation Complex Wavelet Transform, DT-RADWT)^[5]作为一种新型的振动信号处理方法,同传统的双树复小波变换相比^[6]能更精细地划分信号分析频

带,具有更高的时频分辨率,从很大程度上减少了频率的混叠现象。为此,提出了基于有理双树复小波变换的轴承故障诊断方法,并将其应用于轴承故障振动信号故障特征信息的提取。

支持向量机(SVM)^[7]是基于统计学习理论的机器学习新方法。SVM 把原数据空间映射到高维的特征空间,在特征空间通过最大化分类间隔构造最优超平面,而且只需少量的支持向量就能表示这个最优超平面。从理论上说,SVM 算法得到的将是全局最优解,解决了神经网络方法^[8]始终无法避免的局部极值问题,特别是能对多故障进行较好的分类。它弥补了神经网络的不足,在解决小样本、非线性及高维模式识别问题中表现出结构简单、全局最优、泛化能力强等优势。

本文将有理双树复小波变换和支持向量机结合,充分利用二者的优点,对滚动轴承的正常状态、外圈裂纹故障、内圈裂纹故障和滚动体点蚀故障的实验信号的分析表明,该方法成功地实现了轴承故障模式的识别和分类。

2 有理双树复小波变换

为了有效地消除信号分析中的频率混叠,得到更高的频

本文受国家自然科学基金项目(61173030)资助。

孙珊珊(1989—),女,硕士生,主要研究方向为小波分析、信号处理、模式识别,E-mail:374598818@qq.com;何光辉(1976—),男,副教授,硕士生导师,主要研究方向为数据挖掘、模式识别、小波分析、时频分析与处理、软件工程等。

率分辨率, Ilker Bayram 提出了有理双树复小波变换 (dual-Tree Rational-Dilation Complex Wavelet Transform, DT-RAD-WT) 的分解和重构算法。有理双树复小波采用两棵并行的有理小波变换树来实现对信号的分解, 在低通通道采用上 p 下 q 的采样频率, 在高通通道采用下 s 的采样频率, 从而提高了时频分辨率, 从很大程度上减少了频率的混叠现象。有理双树复小波变换实部树采用过完备有理小波滤波器^[9], 过完备有理小波变换^[10] (Overcomplete Rational dilation discrete Wavelet Transform, ORDWT) 的伸缩因子是 $1 < p/q < 2$,

p 和 q 互质, 且 $q = p + 1$, 其尺度函数和小波函数如下:

$$\varphi(t) = \left(\frac{q}{p}\right)^{1/2} \sum_{n \in \mathbb{Z}} h_0(n) \varphi\left(\frac{q}{p}t - n\right) \quad (1)$$

$$\psi(t) = \left(\frac{q}{p}\right)^{1/2} \sum_{n \in \mathbb{Z}} g_0(n) \psi\left(\frac{q}{p}t - n\right) \quad (2)$$

虚部树为实部树的 Hilbert 变换, 通过综合利用实部树和虚部树的小波分解系数, 从而实现了实部树和虚部树的信息互补, 充分地提取了故障信息。图 1 为有理双树复小波变换的分解和重构示意图。

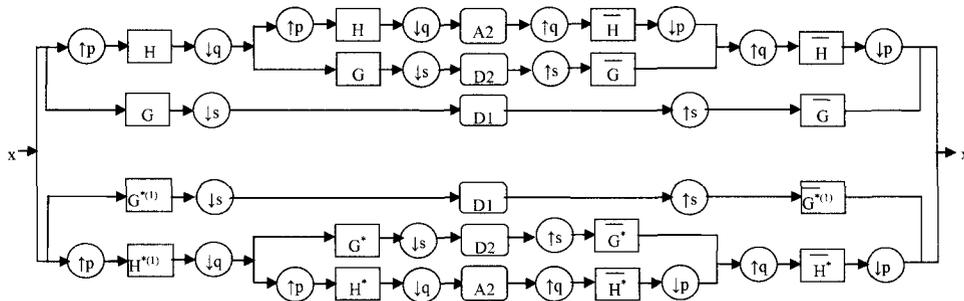


图 1 有理双树复小波分解和重构示意图^[2]

根据有理双树复小波变换原理, 实部滤波器 $h(n)$ 和 $g(n)$ 的频率响应^[11] 为:

$$H(\omega) = \begin{cases} \sqrt{pq}, & \omega \in [0, (1 - \frac{1}{s})\frac{1}{p}\pi] \\ \sqrt{pq}\theta_H(\frac{\omega - a}{b}), & \omega \in [(1 - \frac{1}{s})\frac{1}{p}\pi, \frac{p}{q}\pi] \\ 0, & \omega \in [\frac{1}{q}\pi, \pi] \end{cases} \quad (3)$$

$$G(\omega) = \begin{cases} 0, & \omega \in [0, (1 - \frac{1}{s})\frac{1}{p}\pi] \\ \sqrt{s}\theta_G(\frac{\omega - pa}{pb}), & \omega \in [(1 - \frac{1}{s})\frac{1}{p}\pi, \frac{p}{q}\pi] \\ \sqrt{s}, & \omega \in [\frac{p}{q}\pi, \pi] \end{cases} \quad (4)$$

其中, $a = (1 - \frac{1}{s})\frac{1}{p}\pi$, $b = \frac{1}{q} - (1 - \frac{1}{s})\frac{1}{p}$, $\theta_H(\omega) = \frac{1}{2}(1 + \cos\omega)\sqrt{2 - \cos\omega}$, $\omega \in [0, \pi]$, $\theta_G(\omega) = \frac{1}{2}(1 - \cos\omega)\sqrt{2 + \cos\omega}$, $\omega \in [0, \pi]$ 。

虚部树滤波器为 $\mathcal{H}_i\{h(n)\}$, 其中 $\mathcal{H}_i\{\cdot\}$ 代表离散的 Hilbert 变换, 虚部树滤波器的频率响应为

$$H^*(\omega) = H(\omega)e^{-j(q-p)\frac{\omega}{2}} \quad (5)$$

$$G^*(\omega) = G(\omega)e^{j\theta(\omega)} \quad (6)$$

$$H^{*(1)} = H(\omega)e^{-j\theta\frac{\omega}{2}} \quad (7)$$

其中, $\theta(\omega) = -\text{sgn}(\omega)\frac{\pi}{2} + \frac{\omega}{2}$ 。

为简单起见, 本文采取的参数为 $p=2, q=3, s=2$ 。

3 支持向量机

支持向量机的主要原理如图 2 所示, 其核心思想是建立一个决策超平面, 使两类样本间的隔离区最大化。

H 为分类线, H_1, H_2 分别为过各类分类线最近的样本, 且与分类线平行, 它们之间的距离称为分类间隔。当分类线 H 不但能将两类正确分开, 而且使分类间隔最大时, 此分类线

称为最优分类线。对分类线方程 $wx + b = 0$ 进行归一化处理, 使得对线性可分的样本集 $x \in \mathbb{R}^d, y \in \{1, -1\}$ 满足 $y_i[(w \cdot x_i) + b] - 1 \geq 0, i = 1, \dots, n$ 。此时分类间隔等于 $2/\|w\|$, 使间隔最大等价于使 $\|w\|^2$ 最小。满足上述条件的分类面就叫最优分类面, H_1, H_2 上的训练样本点就称作支持向量。

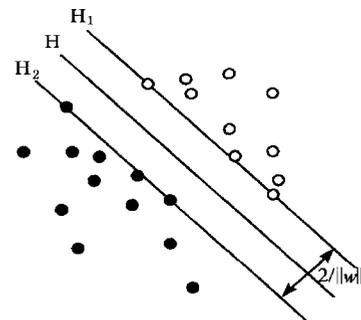


图 2 决策超平面^[12]

线性可分的支持向量机表示为

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (8)$$

$$\text{s. t. } y_i(w \cdot x_i + b) \geq 1, i = 1, 2, \dots, l$$

上式是一个优化求解的问题, 最终解出 w, b , 求出分类决策函数:

$$f(x, w, b) = \text{sgn}\{(w \cdot x) + b\} \quad (9)$$

对于非线性问题, 可以通过非线性变换将其转化为某个高维空间的线性问题。在高维空间, 实际上用适当的内积函数 $K(x_i, x_j)$ 就可以实现某一非线性变换后的线性分类。此时相应的分类函数变为

$$\begin{aligned} f(x) &= \text{sgn}\{(w^* \cdot x) + b^*\} \\ &= \text{sgn}\left\{\sum_{i=1}^n \alpha_i y_i K(x_i \cdot x) + b^*\right\} \end{aligned} \quad (10)$$

根据此决策函数的正负来判别样本所属的类别。选择不同的核函数可以构成不同的 SVM, 本文选择高斯径向核函数。

单个 SVM 只能解决二分类问题, 对滚动轴承故障类型

进行识别,必然是多分类问题识别。对于多分类问题,主要有3种组合SVM方法:一对多法、一对一法和决策导向无环图^[12]。本文选择一对多算法进行分类,结合4种轴承模式,支持向量机分类过程如图3所示。

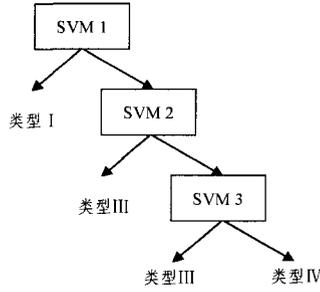


图3 多分类器结构图

4 有理双树复小波-SVM 故障诊断方法

利用双树有理复小波分解得到各频带分量的能量归一化处理后,将其作为支持向量机的输入参数进行故障模式识别。该方法具体步骤如下:

(1)对滚动轴承正常状态、外圈裂纹故障、内圈裂纹故障和滚动体点蚀故障的4种模式按一定的采样频率分别进行 N 次采样,共获得 $4N$ 个振动信号并将其作为样本;

(2)利用有理双树复小波对每一个样本信号进行 J 层(本文取 $J=2^3$)分解,对分解系数进行重构,求各频带的能量, $D_j = \sum_{k=1}^n D_{jk}^2$, $W_j = \sum_{k=1}^n w_{jk}^2$, $j=1,2,\dots,J$,其中 d_{jk} 为实部重构信号的离散值, w_{jk} 为虚部重构信号的离散值, n 为频带信号的长度。

每个频带的能量为 $E_j' = (D_j + W_j)$,总能量为 $E = \sum_{j=1}^J E_j'$,归一化能量为 $E_j = E_j' / E$;

(3)以各频带的归一化能量作为元素,令 $x = \{E_1, E_2, E_3, \dots, E_7, E_8\}$, x 构成一个特征向量,作为支持向量机的输入;

(4)利用SVM分类器进行滚动轴承状态识别和故障诊断。

5 实验与结果分析

实验数据来自美国凯斯西储大学(Case Western Reserve University, CWRU)轴承数据中心的科研人员利用加速度传感器获取的不同状态下SKF 6205-2RS轴承数据(<http://csegroups.case.edu/bearingdatacenter/pages/download-data-file>)。根据轴承中心的介绍,该轴承的转速约为1772r/min,采样频率为12kHz。根据轴承在内圈、滚动体、外圈人工划痕的直径深浅,可以细分为轻微损伤(直径7mils,深度11mils),较重损伤(直径14mils,深度11mils)和严重损伤(直径21mils,深度11mils)3种情况。

本文的实验数据样本取自不同损伤情况下滚动轴承的正常状态、内圈裂纹故障、滚动体点蚀故障和外圈裂纹故障这4种模式。在每一种模式下采样90次,每次采点 2^{10} 个。这样在4种模式下就可以得到 4×90 个样本,每个样本的维数为 $2^{10} = 1024$ 维。按照第3节中的算法提取特征向量,得到一个 360×8 维的归一化能量特征向量。图4为分别在3种不同程度的损伤状态下从每一种模式中随机抽取一个能量特征的特征图。

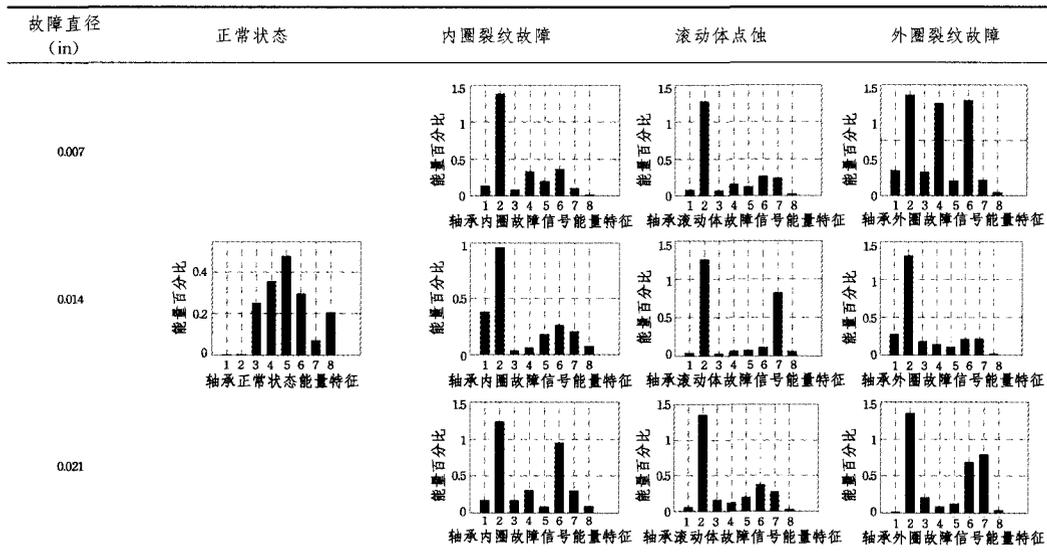


图4 不同状态下的归一化能量特征示意图

把每一种模式下的任意 $\frac{1}{3}$ 特征向量拿出来组成训练样本集,其余 $\frac{2}{3}$ 组成测试样本集,选择高斯径向基核函数以一对多的方法构造分类器,实现多分类。应用交叉验证方法得到核函数的最优参数值,最后通过评估测试数据得到训练结果的正确率。对比传统的小波包+SVM方法^[13]以及双树复小波包(DT-CWPT)+SVM方法^[14],得到的测试结果如表1所列,可以看出基于有理双树复小波和SVM的故障识别效

率最高。图5为采用不同方法的平均识别率对比图。

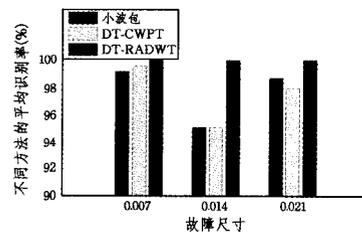


图5 不同方法的平均识别率对比图

表1 CWRU 数据库下不同方法对比分析

故障直径 (in)	小波类型+ SVM	故障识别率(%)				平均识别率 (%)
		正常状态	内圈裂纹故障	滚动体点蚀	外圈裂纹故障	
0.007	小波包	100	100	98.33	98.33	99.17
	DT-CWPT	100	100	100	98.33	99.58
	DT-RADWT(本文方法)	100	100	100	100	100
0.014	小波包	100	95	88.33	96.67	95
	DT-CWPT	100	98.33	81.67	100	95
	DT-RADWT(本文方法)	100	100	100	100	100
0.021	小波包	99.58	98.33	96.67	100	98.65
	DT-CWPT	100	100	91.67	100	97.92
	DT-RADWT(本文方法)	100	100	100	100	100

结束语 本文讨论了有理双树复小波特征提取法和支持向量机模式识别法在滚动轴承故障诊断中的应用,利用 DT-RADWT 的优良特性,将故障信号进行分解,得到不同频段的信号分量,很好地提取了故障信号的特征,SVM 建立的多分类器可以对滚动轴承不同状态进行准确识别。对滚动轴承正常状态、外圈裂纹故障、内圈裂纹故障和滚动体点蚀故障 4 种模式的分析结果表明了该方法可以有效地识别滚动轴承的故障类型。

参考文献

- [1] 何正嘉,袁静,皆艳阳. 机械故障诊断的内积变换原理与应用[M]. 北京:科学出版社,2012:407-470
- [2] 王国彪,何正嘉,陈雪峰. 机械故障诊断基础研究“何去何从”[J]. 机械工程学报,2013,49(1):63-72
- [3] Yan R, Gao R X, Chen X. Wavelets for fault diagnosis of rotary machines: A review with applications[J]. Signal Processing, 2014, 96:1-15
- [4] 艾树峰. 基于双树复小波变换的轴承故障诊断研究[J]. 中国机械工程,2011,22(20):2446-2451
- [5] Bayram I, Selesnick I W. A dual-tree rational-dilation complex wavelet transform[J]. IEEE Transactions on Signal Processing, 2011, 59(12):6251-6256
- [6] Kingsbury N G. The dual-tree complex wavelet transform: A

- new efficient tool for image restoration and enhancement[C]// Proc. European Signal Processing Conf. . Rhodes,1998:319-322
- [7] Vapnik V N. The Nature of Statistical Learning Theory[M]. New York:SpringVerag,1995:21-22
- [8] Akben S B, Subasi A. Comparison of artificial neural network and support vector machine classification methods in diagnosis of migraine by using EEG[C]//2010 IEEE 18th Signal Processing and Communications Applications Conference(SIU). 2010: 637-640
- [9] Bayram I, Selesnick I. Overcomplete discrete wavelet transforms with rational dilation factors[J]. IEEE Trans on Signal Process, 2009, 57(1):131-145
- [10] 毛永芳,秦毅,汤宝平. 过完备有理小波变换在轴承故障诊断中的应用[J]. 振动,测试与诊断,2011,31(5):626-630
- [11] Bayram I, Selesnick I W. Frequency-domain design of overcomplete rational-dilation wavelet transforms[J]. IEEE Trans. Signal Process, 2009, 57(8):2957-2972
- [12] 余辉,赵晖. 支持向量机多类分类算法新研究[J]. 计算机工程与应用,2008,44(7):185-189
- [13] 李永龙,邵忍平,曹精明. 基于小波包与支持向量机结合的齿轮故障分类研究[J]. 西北工业大学学报,2010,28(4):530-535
- [14] 胥永刚,孟志鹏,陆明. 基于双树复小波包变换和 SVM 的滚动轴承故障诊断方法[J]. 航空动力学报,2014,29(1):67-73

(上接第 112 页)

(1) 不论色彩繁多或单一、主体对象是否明确,只要色彩比较接近,其检索精确度较 IRM 算法都有很大提升;

(2) 对于图像的空间位置不敏感,任意旋转、调换均可以很好地检索出结果;

(3) 对于图像的颜色比较敏感,如同一个对象若颜色发生变化,则其检索精确度便会降低。

IRM 距离可采用多种计算方法,如 1-范数、2-范数、 ∞ -范数等,本文采用的是 2-范数(欧氏距离),tNM 方法尽管对图像特征距离的计算目前仅限于一维,距离计算方法比较局限,但仍表现出良好的性能。在以后的研究中,如果能将 tNM 算法中特征距离的计算从一维扩展到二维甚至高维空间,以此来划分相容类,或者加入除颜色和纹理外如轮廓等特征进行检索,其结果将会得到大幅度的提升。

参考文献

- [1] Datta R, Joshi D, Li Jia, et al. Image Retrieval: Ideas, Influence, and Trend of the New Age[J]. ACM Computing Surveys (CSUR), 2008, 40(2):1-60

- [2] Henry C J, Ramanna S. Signature-based Perceptual Nearness: Application of Near Sets to Image Retrieval[J]. Mathematics in Computer Science, 2013, 7(1):71-85
- [3] Peters J F, Wasilewski P. Foundations of near sets[J]. Information Science, 2009, 179(18):3091-3109
- [4] Skowron A, Stepaniuk J. Tolerance Approximation Spaces[J]. Fundamenta Informaticae, 1996, 27(2):245-253
- [5] Li Jia, Wang J Z, Wiederhold G. IRM: Integrated Region Matching for Image Retrieval[C]//Proceedings of the eighth ACM international conference on Multimedia. 2000:147-156
- [6] Rubner Y, Tomasi C, Guibas L J. The Earth Mover's Distance as a Metric or Image Retrieval[J]. International Journal of Computer Vision, 2000, 40(2):99-121
- [7] 肖秦琨,刘米娜,高嵩. 基于颜色和纹理特征的遥感图像检索[J]. 计算机技术与发展,2013,23(4):107-110
- [8] Tuceryan M, Jain A K. Texture Analysis(2nd Edition)[M]// Chen C H, Pau L F, Wang P S P. The Handbook of Pattern Recognition and Computer Vision. 1998:207-248
- [9] Swain M J, Ballard D H. Color Indexing[J]. International Journal of Computer Vision, 1991, 7(1):11-32