

小波包结合支持向量机的故障诊断方法

冼广铭, 曾碧卿, 唐 华, 肖应旺
(华南师范大学计算机工程系, 佛山 528225)

摘 要: 提出一种结合小波包分析(WPA)理论和支持向量机(SVM)分类器的机械故障诊断方法。该方法具有重复训练样本少, 简单、直观的优点, 具有很高的分类性能。利用获得的机械故障数据建立故障分类器, 对不同测试集条件下的 3 种 SVM 核函数、SVM 方法与神经网络方法的比较结果证明, 基于小波包和支持向量机的故障诊断方法是机械故障诊断的发展方向。并对实验的最佳训练样本集进行讨论。

关键词: 小波包分析; 支持向量机; 故障诊断

Fault Diagnosis Method Based on WPA-SVM

XIAN Guang-ming, ZENG Bi-qing, TANG Hua, XIAO Ying-wang

(Department of Computer Engineering, South China Normal University, Foshan 528225)

【Abstract】 A novel method for machinery fault diagnosis combining wavelet packet analysis and multiple support vector machine classifier is put forward. The method has little duplicating training samples and is simple, and its classification accuracy rate is very high. Experimental results show that the method proposed above can successfully be applied to diagnosis of machinery faults, and the best training set is discussed in this paper.

【Key words】 Wavelet Packet Analysis(WPA); Support Vector Machine(SVM); fault diagnosis

1 概述

现代机械设备产生故障的原因众多, 甚至一些故障的机理尚不清楚, 这直接导致了故障信号的不平稳性, 故障的不确定性、故障与征兆之间的非线性对应关系^[1]。

小波包分析(Wavelet Packet Analysis, WPA)能为信号提供一种更加精细的分析方法, 它将频带进行多层次划分, 对多分辨分析未作细分的高频部分进一步分解, 并能根据被分析信号的特征, 自适应地选择相应频带, 使之与信号频谱相匹配, 从而提高“时-频”分辨率, 因此, WPA 具有广泛的应用价值^[2]。

支持向量机(Support Vector Machine, SVM)是一种小样本多元数据分析方法, 满足结构风险最小化原则, 将特征空间影射到 Hilbert 高维空间, 从而有效降低求解问题的 VC 维, 达到同时最小经营风险和置信范围的目的。SVM 用于故障诊断的最大优势在于它适用于小样本决策, 能进行实时在线监控。

小波包分析在处理非平稳信号方面具有独特的优势, 而支持向量机是处理不确定性的有效工具, 将 WPA 和 SVM 有机结合是机械故障诊断^[3]的发展方向, 具有广阔的应用前景^[1]。SVM 算法在解决故障诊断等典型的多分类问题时会遇到困难, 目前将 SVM 机器学习方法延伸到多分类问题仍处于初步研究阶段^[4]。

本文提出一种结合 WPA 理论和 SVM 分类器的机械故障诊断方法。将振动信号小波包分解后的频带能量作为特征向量, 输入到支持向量机中进行训练, 找到样本中的支持向量, 并以此决定最优分类超平面, 再根据最优分类超平面, 对测试集的样本进行故障诊断。

2 WPA-SVM 故障诊断模型

2.1 WPA 特征提取

设 $f(t)$ 为时间信号, $p_j^i(t)$ 表示第 j 层上的第 i 个小波包,

称为小波包系数, G, H 为小波包分解过滤器, H 与尺度函数 $\varphi_j(t)$ 有关。二进制小波包分解的快速算法为

$$\begin{cases} p_0^i(t) = f(t) \\ p_j^{2^{j-1}} = \sum_k H(k-2t)p_{j-1}^i(t) \\ p_j^{2^i} = \sum_k G(k-2t)p_{j-1}^i(t) \end{cases} \quad (1)$$

其中, $t=1, 2, \dots, 2^{j-1}; i=1, 2, \dots, 2^j; J=1bN$ 。

式(1)表示: 假设所检测的信号 $f(t)$ 为 $p_0^1(t)$, 信号 $f(t)$ 在第 j 层上共有 2^j 个小波包, 第 $2i-1$ 个小波包是第 $j-1$ 层上第 i 个小波包与小波分解滤波器 H 卷积后再隔点采样的结果; 第 $2i$ 个小波包是第 $j-1$ 层上第 i 个小波包与小波分解滤波器 G 卷积后再隔点采样的结果。

二进制小波包重构的快速算法为

$$p_j^i(t) = 2[\sum_k h(t-2k)p_{j+1}^{2^{j-1}}(t) + \sum_k g(t-2k)p_{j+1}^{2^i}(t)] \quad (2)$$

其中, $j=J-1, J-2, \dots, 1, 0; i=2^j, 2^{j-1}, \dots, 1; J=1bN$; h, g 为小波重构滤波器, h 与尺度函数 $\varphi_j(t)$ 有关, g 与小波函数 $\psi_j(t)$ 有关。

对故障使用 WPA-SVM 进行特征提取的具体步骤^[2]:

(1)对机械故障信号进行 3 层小波包分解。 (i, j) 表示第 i 层的第 j 个节点, 其中, $i=0, 1, 2, 3, j=0, 1, \dots, 7$, 每个节点都代表一定的信号特征。其中, $(0, 0)$ 节点代表原始信号 S ; $(1, 0)$ 代表小波包分解的第一层低频系数 X_{10} , $(1, 1)$ 小波包分解第 1 层的高频系数 X_{11} ; $(3, 0)$ 表示第 3 层第 0 个节点; 其

基金项目: 广东省自然科学基金资助项目“基于 P2P 思想的网格计算任务调度策略与资源动态管理研究”(8151063101000040)

作者简介: 冼广铭(1975 -), 男, 讲师、博士, 主研方向: 人工智能, 模式识别; 曾碧卿、唐 华, 副教授、博士, 肖应旺, 讲师、博士

收稿日期: 2008-05-20 **E-mail:** xgm20011@163.com

它依此类推。

(2)对小波包分解系数进行重构,提取各频带范围的信号。 S_{30} 表示 X_{30} 的重构信号, S_{31} 表示 X_{31} 的重构信号,其他依此类推。本文只对第3层的所有节点进行分析,总信号表示为

$$S = S_{30} + S_{31} + S_{32} + S_{33} + S_{34} + S_{35} + S_{36} + S_{37} \quad (3)$$

假设在原始信号 S 中,最低频率成分为0,最高频率成分为1,则提取的 $S_{3j}, (j=0, 1, \dots, 7)$ 。8个频率成分所代表的频率范围如表1所示。

表1 各个频率成分所代表的频率范围

信号	频带
S_{30}	0.000-0.125
S_{31}	0.125-0.250
S_{32}	0.250-0.375
S_{33}	0.375-0.500
S_{34}	0.500-0.625
S_{35}	0.625-0.750
S_{36}	0.750-0.875
S_{37}	0.875-1.000

(3)求各个频带信号的总能量。设 $S_{3j}, j=0, 1, \dots, 7$ 。对应的能量为 $E_{3j}, j=0, 1, \dots, 7$,则有

$$E_{3j} = \int |S_{3j}(t)|^2 dt = \sum_{k=1}^n |x_{jk}|^2 \quad (4)$$

其中, $x_{jk}, j=0, 1, \dots, 7; k=1, 2, \dots, n$ 表示重构信号 S_{3j} 的离散点的幅值。

(4)构造特征向量。由于系统出现故障时,会对各频带内信号的能量有较大的影响,因此,以能量为元素构造一个特征向量。特征向量的构造如下:

$$T = [E_{30}, E_{31}, E_{32}, E_{33}, E_{34}, E_{35}, E_{36}, E_{37}] \quad (5)$$

2.2 基于SVM的故障诊断阶段

基于SVM算法的故障诊断分为学习和故障模式识别2个阶段^[5]:

(1)学习阶段

1)根据专家经验或动态聚类结果,将机械故障分为3种聚类,然后建立训练集 $\{x_i, y_i\}, y_i \in \{-1, 1\}$ 。

2)按Mercer定理,选择合适的核函数 $K(x, x')$ 及其参数作为高维特征空间在低维输入空间的一个等效形式。在本实验中采用如下所列3种核函数:径向基(RBF)核函数,多层感知机(MLP)核函数和高斯(Gaussian)核函数。

3)输入样本正规化,目的是为了输入数据标定在Kernel函数要求的范围内,例如对于多项式、径向基、Sigmoid函数 x_i 规定在 $[-1, 1]$ 内。

4)构造 $H(l, l)$ 矩阵。

5)在约束条件 $\sum_{i=1}^l \alpha_i y_i = 0, 0 < \alpha_i < C$ 下最大化:

$$Q(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (6)$$

以求解拉格朗日系数 α 。上述步骤是将输入空间映射到高维特征空间,在低维输入空间运用高维空间的内积的等效形式——核函数实现。

6)求支持向量 sv ,求解分类超平面系数 b 。

7)建立训练集的最优决策超平面,完成训练过程。

(2)故障模式识别

1)载入SVM学习阶段的训练集 (x_i, y_i) ,系数 a, b 以及支持向量 sv 等数据。

2)根据公式 $f(x') = \sum_{\text{支持向量}} y_i \alpha_i K(x_i, x') - b$,计算新输入特征数据 x' 决策输出值。

3)利用指示函数将 $f(x')$ 归为 $\{-1, 1\}$,作出分类决策。

由于SVM的基本理论只是考虑了二值分类的情况,因此在多值分类问题上,系统须组合多个SVM进行分类。

2.3 SVM与多层前向网络的比较

同径向基函数和多层感知器相比,SVM避免了前者在设计过程中经常使用的启发式结构,它不依赖于设计者的经验知识。而且SVM的理论基础决定它最终求得的是全局最优解而不是局部最小值,也保证了对于未知样本的良好泛化能力而不会出现过学习现象。

当采用Sigmoid函数作为核函数时,SVM实现的是一种多层感知神经网络。使用SVM方法,隐结点数目(它确定神经网络的结构)、隐结点对输入节点的权值和输出结点对隐结点的权值都是在训练的过程中自动确定的。而多层感知器的隐结点数目是需要依赖经验知识事先确定的。此外,在多层感知器中,模型复杂性的控制是通过使特征数目尽量最小,也就是使隐层神经元数目尽可能小来实现,而 ϵ -SVM是通过控制与维数无关的模型复杂性来实现学习机器的设计。

当采用径向基核函数的时候,SVM实现的是径向基分类机。它与传统的RBF神经网络相比的区别在于:用SVM法,径向基核函数的中心位置以及中心数目、网络的权值都是由训练过程中自动确定,而传统的RBF神经网络对这些参数的确定依赖于经验知识^[6]。

3 实验及分析

(1)SVM核函数的比较

选取900个样本,样本数据的状态分为3种:正常状态样本数据,第1类振动故障和第2类振动故障的状态样本数据。特征提取方法采用小波包("db5"小波),识别方法采用SVM的"One against others"策略,分别采用2种不同大小的测试集(如表2所示)对SVM的RBF核、MLP核和Multinomial核进行测试。

表2 2种不同的测试集

类	测试集较大		测试集较小	
	训练数据	测试数据	训练数据	测试数据
A	90	210	60	30
B	90	210	60	30
C	90	210	60	30

如表3所示,当测试集较小时,RBF核、MLP核和Multinomial核的准确率分别为92.2%,90.0%和88.8%;当测试集较大时,RBF核、MLP核和Multinomial核的准确率分别为92.5%,91.9%和91.7%。测试结果显示选用不同的核函数对SVM识别的正确率有影响,RBF核的识别性能比MLP核和Multinomial核都要好。

表3 2种测试集的识别准确率 (%)

	测试集较小	测试集较大
RBF	92.2	92.5
MLP	90.0	91.9
Multinomial	88.8	91.7

(2)SVM方法与神经网络方法的比较

选择 250 个样本,采用 WPA 作为特征提取方法,使用 SVM, RBF 和 BP 神经网络方法作为识别方法,在机械故障诊断中的识别准确率比较如表 4 所示。

表 4 SVM方法与神经网络方法比较 (%)

故障诊断方法	准确率
SVM	92.0
RBF	83.2
BP	80.4

由上述结果可见,支持向量机具有较好的推广性,能克服神经网络的过学习和局部极小点等问题,较好地解决了有限样本的高维模型构造问题,适用于机械故障诊断。

(3)最佳的训练样本数的选择

3 种 SVM 识别策略(“One against all”, “One against one”和 “One against others”)随着训练集数目变化情况如下:当训练样本数目从 30 增大到 120 时,3 种策略的准确率边际均值上升较大;当训练样本数目从 120 增大到 210 时,3 种 SVM 识别策略的准确率边际均值上升平缓;当训练样本数目大于 210 时,3 种 SVM 识别策略的准确率边际均值已基本达到稳定,随着训练样本数目的增加略有轻微变化。由于训练样本数会增加识别的时间复杂性和空间复杂性,因此只须使用足够的训练样本数目,即可获得满意的识别效果。在本文实验

中,最佳的训练样本数为 210~270。

4 结束语

本文提出一种小波包分析与 SVM 分类器相结合的机械故障诊断方法。采用小波包分析对机械信号提取频域能量特征向量,通过建立多 SVM 分类器完成故障诊断,获得较好的效果。实验结果表明,选用不同的核函数确实会对 SVM 识别的正确率有影响,RBF 核的识别性能比 MLP 核和 Multinomial 核都要好。同时,使用 SVM 在机械故障诊断中的识别准确率比 RBF 和 BP 神经网络方法高。

参考文献

- [1] 杨建国. 小波分析及其工程应用[M]. 北京: 机械工业出版社, 2005.
- [2] 胡昌华, 李国华, 刘涛, 等. 基于 Matlab6.X 的系统分析与设计——小波分析[M]. 西安: 电子科技大学出版社, 2004.
- [3] 何学文, 赵海鸣. 支持向量机及其在机械故障诊断中的应用[J]. 中南大学学报: 自然科学版, 2005, 36(1): 97-101.
- [4] Mcavoy T J, Ye N. Base Control for the Tennessee Eastman Problem[J]. Computers and Chemical Engineering, 1994, 18(5): 383-413.
- [5] 马笑潇, 黄席樾, 柴毅. 基于 SVM 的二叉树多分类算法及其在故障诊断中的应用[J]. 控制与决策, 2003, 18(3): 272-276.
- [6] 高隼. 神经网络原理及仿真实例[M]. 北京: 机械工业出版社, 2003.

(上接第 211 页)

以 20 只蝴蝶为例进行仿真实验,图 3 为运行前 20 只蝴蝶的状态,图 4 为蝴蝶群体运行 480 次时的群体状态。仿真结果表明,基于粒子群优化算法的群体动画是可行的,并表现出群体的人工智能性,并能真实地再现群体觅食等行为。




图 3 蝴蝶群体起始状态




图 4 蝴蝶群体运动状态

6 结束语

本文将粒子群优化算法应用于群体动画中,并选择粒子视野范围内具有最优适应度值的粒子作为该粒子本次迭代的全局极值,还考虑了障碍避让、碰撞避免等真实环境中可能

遇到的问题,从而更加真实地模拟了群体动画。更深入的工作是通过分析改进的化算法视野相关参数,进一步提高算法的优化能力和性能。

参考文献

- [1] Reynolds C. Flocks, Herds, and Schools: A Distributed Behavioral Model[C]//Proceedings of SIGGRAPH'87. [S. l.]: IEEE Press, 1987: 25-34.
- [2] Tu Xing. Artificial Animals for Computer Animation: Biomechanics, Locomotion, Perception, and Behavior[M]. [S. l.]: Springer-Verlag, 1999.
- [3] Kennedy J, Eberhart R. Particle Swarm Optimization[C]//Proc. of IEEE Int'l Conf. on Neural Networks. Perth, Australia: [s. n.], 1995: 1942-1948.
- [4] 童瑩, 吴智铭, 童争雄. 一种自适应的微粒群算法[J]. 计算机科学, 2007, 34(9): 198-199.
- [5] Kennedy J. Small Words and Mega-minds: Effects of Neighborhood Topology on Particle Swarm Performance[C]//Proceedings of the 1999 Conference on Evolutionary Computation, Australia. [S. l.]: IEEE Press, 1999: 1931-1938.