

# 基于支持向量回归的轴承故障定量诊断应用\*

鞠 华<sup>1</sup>, 沈长青<sup>2</sup>, 黄伟国<sup>1</sup>, 李 双<sup>1</sup>, 朱忠奎<sup>1</sup>

(1. 苏州大学城市轨道交通学院 苏州, 215131) (2. 苏州大学机电工程学院 苏州, 215021)

**摘要** 针对轴承故障状态特征与故障大小之间存在非线性关系, 提出利用支持向量回归机建立轴承故障大小与状态特征之间的定量诊断模型, 并给出了基于支持向量回归的定量诊断策略和诊断流程。在获取轴承不同故障大小的特征量的基础上, 建立了轴承故障定量诊断的支持向量回归模型, 将其用于轴承故障的定量识别。结果表明, 该方法能够有效地判断出故障的大小。进一步将该方法与人工神经网络方法比较, 结果说明了支持向量回归方法在轴承故障定量诊断方面具有更好的适应性。

**关键词** 轴承; 定量诊断; 支持向量回归; 故障诊断

**中图分类号** TH133

## 引 言

滚动轴承是旋转机械系统的重要零件, 现有的旋转机械振动信号的分析方法多为定性指出机组可能存在的故障, 而现实是希望根据定量评价故障的危害程度以及发展趋势作决定, 从而有效避免“维修不足”和“过剩维修”所带来的经济损失。为了提供机械系统运行质量和运行安全的精确信息, 需要对故障大小和发展趋势进行估计, 因此研究故障大小与状态特征之间关系的定量诊断方法具有重要意义。定量故障下的状态特征和故障大小之间一般为非线性关系, 具有表征特征的数据量大、变量多等特点。诊断模型的建立需要一种能针对状态参数多、数量大、状态参数与故障程度之间强烈的非线性的特点, 有效建立故障与状态特征之间关系模型的方法。通过精确的数学模型表示状态参数和定量故障之间的关系是非常困难的。在较少样本下统计的预测方法也是不适合的。人工智能方法是适合表示定量诊断中的状态参数与定量故障之间的有效方法。

支持向量机是一种建立在统计学习理论基础之上的通用学习方法, 包括支持向量分类机和支持向量回归机<sup>[1-2]</sup>, 已被广泛应用于机械故障诊断。文献[3]调查了支持向量机在状态监测和故障诊断中的

应用情况。张超等<sup>[4]</sup>将支持向量机用于齿轮箱的故障诊断。Moura 等<sup>[5]</sup>将支持向量回归机用于失效和可靠性的预测问题。翟永杰等<sup>[6]</sup>将分级聚类的支持向量机应用于汽轮机故障诊断中。

故障定量诊断将故障看成连续过程, 类似于回归问题, 本研究采用支持向量回归机建立轴承故障定量诊断模型。笔者以定量诊断为目的, 将轴承外圈故障看成连续过程<sup>[7-8]</sup>, 通过引入支持向量回归 (support vector regression, 简称 SVR) 方法建立故障定量诊断模型, 研究基于支持向量回归的轴承故障的定量诊断方法与实现。

## 1 支持向量回归

回归问题可以理解为: 根据输入-输出数据集  $(\mathbf{x}_i, \mathbf{y}_i) (i=1, 2, \dots, M)$ , 其中:  $\mathbf{x}_i$  为第  $i$  个  $m$  维输入向量;  $\mathbf{y}_i$  为第  $i$  个标量输出;  $M$  为训练样本数, 求输入和输出之间的关系。

在支持向量回归中, 首先将输入量映射到  $l$  维特征空间, 然后在特征空间中构造优化超平面

$$f(\mathbf{x}) = \langle \mathbf{W}, \Phi(\mathbf{x}) \rangle + \mathbf{b} \quad (1)$$

其中:  $\mathbf{W}$  为  $l$  维权重向量; 映射函数  $\Phi(\mathbf{x})$  是将  $\mathbf{x}$  映射到高维特征空间;  $\mathbf{b}$  为偏置项。

在 SVR 中训练误差通过  $\epsilon$  不敏感损失函数判

\* 国家自然科学基金资助项目(51375322); 江苏省自然科学基金资助项目(BK20140339)

收稿日期: 2013-08-15; 修回日期: 2013-10-10

定,其表达式为

$$L^\epsilon(\mathbf{x}, \mathbf{y}, f) = |\mathbf{y} - f(\mathbf{x})|_\epsilon = \max(0, |\mathbf{y} - f(\mathbf{x})| - \epsilon) \quad (2)$$

其中: $\epsilon$  为一个小的正数。

定义实际输出  $\mathbf{y}$  和估计输出  $f(\mathbf{x})$  之间的残差为

$$D(\mathbf{x}, \mathbf{y}) = \mathbf{y} - f(\mathbf{x}) \quad (3)$$

理想的回归应该是所有的残差均在  $\epsilon$  之内,即

$$-\epsilon \leq D(\mathbf{x}, \mathbf{y}) \leq \epsilon \quad (4)$$

如图 1 所示,考虑到管径区域外数据的存在,引入非负松弛变量  $\xi$  和  $\xi^*$ 。




图 1 损失函数

Fig. 1 Loss function

回归问题转化为

$$\xi_i = \begin{cases} 0 & D(\mathbf{x}_i, \mathbf{y}_i) - \epsilon \leq 0 \\ D(\mathbf{x}_i, \mathbf{y}_i) - \epsilon & \text{其他} \end{cases} \quad (5)$$

$$\xi_i^* = \begin{cases} 0 & \epsilon - D(\mathbf{x}_i, \mathbf{y}_i) \leq 0 \\ \epsilon - D(\mathbf{x}_i, \mathbf{y}_i) & \text{其他} \end{cases} \quad (6)$$

最小化

$$\| \omega \|^2 / 2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (7)$$

约束条件

$$\mathbf{y}_i - \langle \mathbf{W}, \Phi(\mathbf{x}_i) \rangle - \mathbf{b} \leq \epsilon + \xi_i \quad (8)$$

$$-\mathbf{y}_i + \langle \mathbf{W}, \Phi(\mathbf{x}_i) \rangle + \mathbf{b} \leq \epsilon + \xi_i^* \quad (9)$$

$$\xi_i \geq 0 \quad (10)$$

$$\xi_i^* \geq 0 \quad (11)$$

其中: $C$  为平衡最大间隔和回归误差的边际系数, $C$  和  $\epsilon$  都需要事先确定。

通过使用拉格朗日数乘法和 Karush-Kuhn-Tucker 条件,得到了式(8)的对偶问题。

最大化为

$$L(\alpha, \alpha^*) = - \sum_{i,j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i, x_j) - \epsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) + \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) \quad (12)$$

约束条件为

$$\sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \quad (13)$$

$$(0 \leq \alpha_i \leq C; 0 \leq \alpha_i^* \leq C; i = 1, \dots, N)$$

其中: $\alpha_i, \alpha_i^*$  为拉格朗日数乘因子。

最终得到的回归函数为

$$\mathbf{y} = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(\mathbf{x}, \mathbf{x}_i) + \mathbf{b} \quad (14)$$

其中: $K(\mathbf{x}, \mathbf{x}_i)$  为核函数,其值为两个向量  $\mathbf{x}$  和  $\mathbf{x}_i$  在特征空间  $\Phi(\mathbf{x}_i)$  和  $\Phi(\mathbf{x}_j)$  的内积。

本研究使用的核函数为径向基函数,表达式为

$$K(\mathbf{x}_i \cdot \mathbf{x}_j) = \exp(-|\mathbf{x}_i - \mathbf{x}_j|^2 / \sigma^2) \quad (15)$$

采用径向基函数为核函数的支持向量回归机模型,需要确定其参数  $\sigma$ 。

## 2 基于 SVR 的轴承故障定量诊断策略

### 2.1 策略

将支持向量回归方法应用于轴承故障定量诊断的策略如图 2 所示,图 2 中虚线框的步骤为最优参数的获得过程。首先对振动信号进行特征提取,获得数据集,将数据集分为测试集和训练集,训练集用于确定 SVR 模型的最优参数,从而建立有效的回归模型,测试集用于测试模型的有效性。

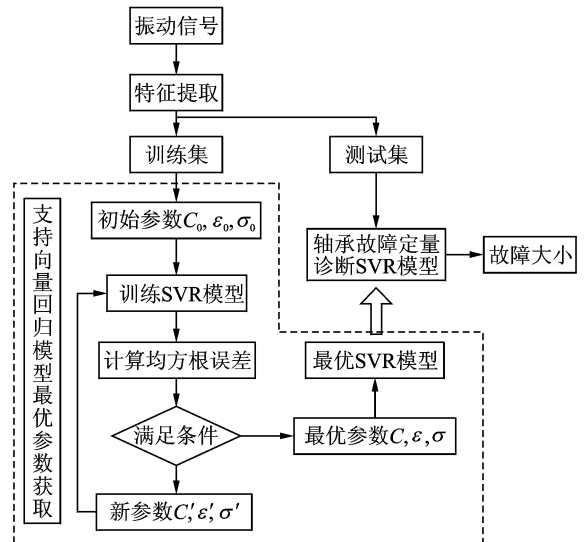


图 2 基于 SVR 的轴承故障定量诊断方法策略

Fig. 2 Quantitative diagnosis method of bearing fault based on SVR

### 2.2 特征提取

本研究提取的用于表示故障大小的故障状态特征参数共 8 个,如表 1 所示。表 1 中: $\mathbf{x}_i$  为信号某一

时刻的幅值;  $\bar{X}$  为信号幅值的平均值;  $N$  为信号的长度;  $\sigma$  为信号幅值的均值。

表 1 提取的 8 个特征参数

Tab. 1 Extracted 8 feature characteristics

特征参数	公式
最大峰值	$\max(x_i)$
均值	$\frac{1}{N} \sum_{i=1}^N  x_i $
方差	$\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{X})^2}$
峭度	$\frac{1}{N} \sum_{i=1}^N \left[ \frac{x_i - \bar{X}}{\sigma} \right]^4$
偏度	$\frac{1}{N} \sum_{i=1}^N \left[ \frac{x_i - \bar{X}}{\sigma} \right]^3$
峰值指标	$X_{\max} / \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
裕度	$\max( x_i ) / \left( \frac{1}{N} \sum_{i=1}^N \sqrt{ x_i } \right)^2$
波形指标	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} /  \bar{X} $

### 2.3 模型的最优参数

支持向量回归模型建立的所需确定的参数有平衡最大间隔和回归误差的边际系数  $C$ , 不敏感损失函数  $\epsilon$  以及核函数参数  $\sigma$ 。笔者采用交叉验证的方法, 以均方根误差最小作为判定模型成绩的指标, 采用网格搜索法确定这些参数。

## 3 在轴承故障定量识别中的应用

### 3.1 支持回归模型在轴承故障定量识别中的应用

将支持向量回归方法用于轴承故障定量诊断, 图 3 为故障定量诊断试验台。采用的被测轴承的型号为 6208。为了模拟故障的演变过程, 设置了不同故障大小的轴承, 用于获得轴承在不同故障程度下的振动信号。表 2 为故障样本信息。图 4 为在图 3 所示的试验台上获取的不同轴承故障下的振动加速度信号。




图 3 故障定量诊断试验台

Fig. 3 Quantitative fault diagnosis test rig

表 2 故障样本信息

Tab. 2 Fault samples

故障部位	故障大小 /mm	训练集 个数	测试集 个数	目标值 /mm
外圈故障	0.2	10	10	0.2
	0.3	10	10	0.3
	0.4	10	10	0.4
	0.5	10	10	0.5
	0.6	10	10	0.6
	0.7	10	10	0.7

将训练集用于训练得到了最优 SVR 模型参数, 得到最优参数为  $C=8, \sigma=2, \epsilon=0.01$ 。建立的模型在训练集和测试集上的结果分别如图 5, 6 所示。由图 5 可知, 模型在训练集上能够有效地判断出故障的大小, 预测值与真实值的误差很小, 根据不同样本下的误差线可知误差变化很小。从图 6 可知, 在测试集上模型在故障为 0.2 mm 以及 0.3 mm 预测值和真实值有一定的误差, 但都很小, 整体来说, 模型在训练集合测试集上的效果都较理想。

### 3.2 与神经网络方法的对比

为了说明基于 SVR 方法的有效性, 笔者设计了一个 3 层 Back Propagation (BP) 神经网络, 训练函数采用 Trainlm, 学习函数采用 Learngdm, 第 1 层的神经元个数为 10 个, 第 2 层神经元的个数为 5 个, 传递函数采用 Tansig, 以均方误差为训练目标。得到的神经网络模型在测试集和训练集上的效果分别如图 7, 8 所示。可以看出, 人工神经网络方法在训练集和测试集上的效果明显没有基于 SVR 方法有效。为了进一步说明两种方法的有效性, 定义了均方根值 (RMSE)、绝对平均误差 (MAE) 以及最大

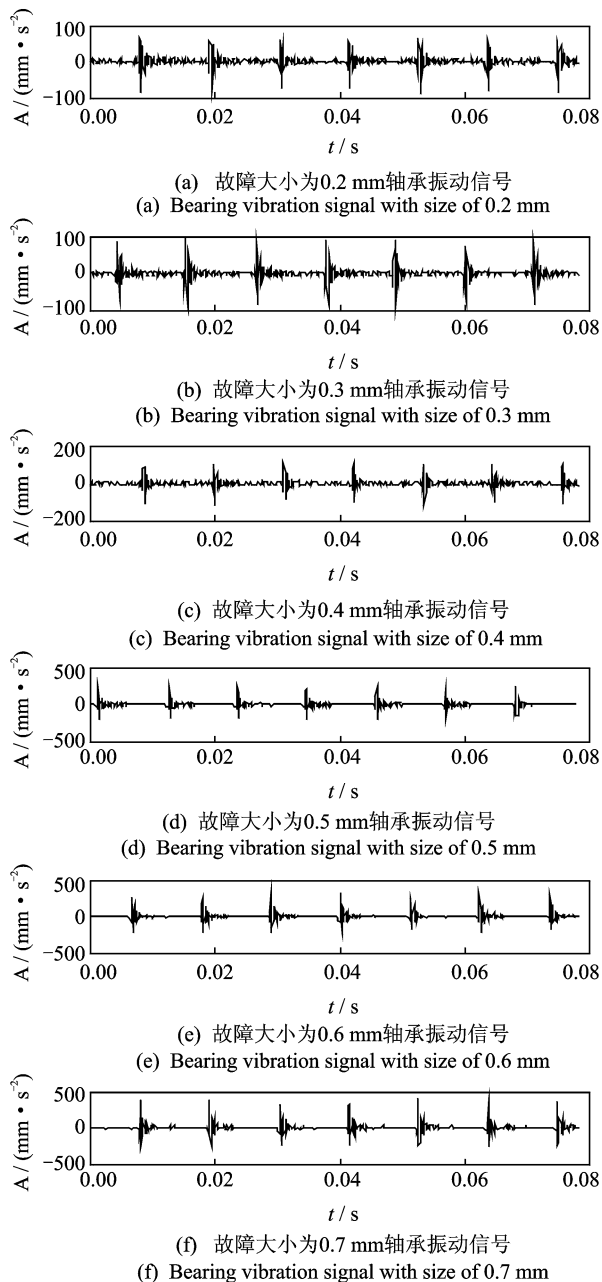


图4 轴承振动信号时域图

Fig. 4 Measured vibration signals of bearing fault

误差(ME)等指标来判断两者的优劣。

均方误差为

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (f_{\text{actual}} - f_{\text{predicted}})^2} \quad (16)$$

绝对平均误差为

$$MAE = \frac{1}{N} \sum_{i=1}^N |f_{\text{actual}} - f_{\text{predicted}}| \quad (17)$$

最大误差为

$$ME = \frac{1}{N} \sum_{i=1}^N |f_{\text{actual}} - f_{\text{predicted}}| \quad (18)$$

其中： $f_{\text{actual}}$ 为实际故障大小； $f_{\text{predicted}}$ 为模型预测的故




图5 模型在训练集上的结果

Fig. 5 Results of model over the training set




图6 模型在测试集上的结果

Fig. 6 Results of model over the testing set




图7 人工神经网络方法在训练集上的结果

Fig. 7 Result of artificial neural network over training set

障大小。

两种方法在训练集和测试集上3个指标的结果如表3所示,该结果表明了支持向量回归方法的成绩优于人工神经网络方法。由表3数据可知,SVR方法建立的模型在训练集和测试集上其成绩指标都要小于人工神经网络方法,且人工神经网络方法的成绩指标在测试集上的变化程度比SVR方法的变化更剧烈。




图 8 人工神经网络方法在测试集上的效果

Fig. 8 Result of artificial neural network over testing set

表 3 轴承外圈故障分析结果对比

Tab. 3 Comparison of the analysis results of bearing outer race fault

数据集	统计指标	模型	
		支持向量回归方法	人工神经网络方法
训练集	均方根	0.004 2	0.007 5
	绝对平均误差	0.003 7	0.005 8
	最大误差	0.011 8	0.029 5
测试集	均方根	0.005 2	0.010 7
	绝对平均误差	0.004 1	0.008 8
	最大误差	0.012 7	0.026 7

## 4 结 论

1) 轴承故障的演变存在一个由轻微到严重的发展过程,故障定量诊断是实现故障演变过程的有效描述方法。针对故障的发展过程中故障大小的定量描述问题,提出并确定了通过支持向量回归建立故障定量诊断模型的方法。

2) 在进行轴承不同故障大小情况下的故障特征提取的基础上,建立了轴承故障定量诊断的支持向量回归模型,该模型可以有效判断轴外圈承故障大小;进一步与人工神经网络方法的比较说明支持向量回归方法在故障的定量诊断方面具有更好的适应性。

### 参 考 文 献

[1] Sain S R. The nature of statistical learning theory[J]. Technometrics, 1996,38(4):406-409.  
 [2] Cristianini N,Shawe-Taylor J. 支持向量机导论[M]. 李国正,等. 译. 北京:电子工业出版社,2004:82-139.

[3] Widodo A, Yang B S. Support vector machine in machine condition monitoring and fault diagnosis[J]. Mechanical Systems and Signal Processing, 2007, 21(6): 2560-2574.  
 [4] 张超,陈建军,郭迅. 基于 EMD 能量熵和支持向量机的齿轮故障诊断方法[J]. 振动与冲击, 2010, 21(29): 216-220.  
 Zhang Chao, Chen Jianjun, Guo Xun. A gear fault diagnosis method based on EMD energy entropy and SVM[J]. Journal of Vibration and Shock, 2010, 21(29):216-220. (in Chinese)  
 [5] Moura M D C, Enrico Z, Isis D L, et al. Failure and reliability prediction by support vector machines regression of time series data[J]. Reliability Engineering and System Safety, 2011,96(11):1527-1534.  
 [6] 翟永杰,毛继珮,于丽敏,等. 分级聚类支持向量机在汽轮机故障诊断中的应用[J]. 华北电力大学学报, 2003,30(1):25-29.  
 Zhai Yongjie, Mao Jipei, Yu Limin, et al. Application of hierarchical clustering support vector machine in turbogenerator fault diagnosis [J]. Journal of North China Electric Power University, 2003,30(1):25-29. (in Chinese)  
 [7] Heng A, Tan A C C, Mathew J, et al. Intelligent condition-based prediction of machinery reliability[J]. Mechanical Systems and Signal Processing, 2009, 23(5):1600-1614.  
 [8] 何正嘉,訾艳阳,陈雪峰,等. 机械故障预示中的若干科学问题[J]. 振动与冲击, 2010, 21(S):144-147.  
 He Zhengjia, Zi Yanyang, Chen Xuefeng, et al. Some scientific issues in mechanical fault prognosis [J]. Journal of Vibration and Shock, 2010,21(S):144-147. (in Chinese)



**第一作者简介:**鞠华,女,1973 年 1 月生,博士、讲师。主要研究方向为机械 CAD/CAM,机械可靠性评估。曾发表《CNC non-contact measuring system for freeform surface》(《Chinese Journal of Mechanical Engineering: English Version》2002, Vol. 15, No. 2)等论文。  
 E-mail:juhua@suda.edu.cn

**通信作者简介:**沈长青,男,1987 年 1 月生,博士、副教授。主要研究方向为旋转设备关键部件在线监测与故障诊断、寿命预测。  
 E-mail:cqshen@suda.edu.cn

