

基于 AR 和 PSO_SVR 的故障趋势预测

刘玉茹¹, 宁芊^{1,2}

(1. 四川大学 电子信息学院, 成都 610065; 2. 电子信息控制重点实验室, 成都 610065)

摘要: 针对机械设备产生的非线性、非平稳时间序列, 首先使用自回归模型对非平稳数据进行平稳化处理并确定模型的阶数, 再使用支持向量回归算法对平稳后的数据进行拟合, 并使用粒子群算法优化支持向量回归算法参数; 最后, 将该模型用于滚动轴承的退化趋势预测, 通过提取滚动轴承的时域和频域特征, 以经过主成分分析降维后的数据为基础进行趋势预测; 将该模型预测的结果与单独使用自回归模型和支持向量机模型预测的结果进行对比, 实验结果表明该模型预测的效果较好。

关键词: 自回归模型; 支持向量回归; 主成分分析; 特征提取; 故障趋势预测

Fault Trend Prediction Based on AR and PSO_SVR

Liu Yuru¹, Ning Qian^{1,2}

(1. College of Electronic Information, Sichuan University, Chengdu 610015, China;

2. Science and Technology on Electronic Information Control Laboratory, Chengdu 610015, China)

Abstract: Aiming at the nonlinear and non-stationary time series generated by mechanical equipment, the AR algorithm is used to smooth the non-stationary data and determine the order of the model. Then, the SVR algorithm is used to fit the stationary data, and the PSO Algorithm to optimize SVR algorithm parameters. The model is used to predict the degradation trend of rolling bearings. Firstly, the time domain and frequency domain characteristics of the bearings are extracted, and then the data are predicted based on the data after PCA dimension reduction. Finally, the results of this model are compared with those of AR and PSO_SVR alone. The experimental results show that the model is better.

Keywords: AR, PSO, SVR, fault trend prediction, feature extraction, PCA

0 引言

故障趋势预测是机械装备预测与健康管理的核心内容, 对机械装备关键部件进行准确有效的预测是保证保障关键设备安全可靠运行的关键。目前故障趋势预测是通过分析机械设备在使用过程中产生的具有时间序列特征的数据, 来推测故障的发展过程。由于机械设备在运行过程中, 其状态参数的变化往往是非线性、非平稳的, 对于这类非线性时间序列数据, 文献 [2] 使用神经网络非线性的特点来对轴承设备进行故障趋势预测, 但神经网络结构存在结构难以确定、需要大量样本、易陷入局部极小等特点。文献 [3] 采用支持向量机的方法来推测轴承的故障发展趋势, 但其输入数据的维度是根据经验来选取, 不具有说服力。文献 [4] 采用自回归滑动平均 (Auto-Regressive and Moving Average Model, ARMA) 方法, 该方法将自回归模型与滑动平均模型结合起来对时间序列数据进行预测, 但其参数确定比较麻烦。文中将自回归模型 (Auto-Regressive, AR) 模型和 PSO_SVR 算法相结合, 使用 AR 模型将非平稳数据平稳化, 并确定 SVR 算法训练数据的输入维度, 随后利用 SVR 对非线性数据进行拟合。

1 AR_PSO_SVR 模型

AR_PSO_SVR 模型主要包含两个方面: (1) AR 模型定阶 (2) PSO_SVR 模型预测^[5]。

收稿日期: 2017-09-11; 修回日期: 2017-10-18。

作者简介: 刘玉茹 (1992-), 女, 河南南阳人, 硕士研究生, 主要从事模式识别与智能系统方向的研究。

宁芊 (1969-), 女, 四川成都人, 副教授, 硕士研究生导师, 主要从事模式识别与智能系统方向的研究。

1.1 AR 模型定阶

1.1.1 数据平稳化

经典的回归模型是建立在平稳数据的基础上, 对非平稳数据进行回归会出现伪回归等问题, 因而首先要对数据进行平稳性检验。目前最常用的检验方法有 DF 校验和 ADF 校验, 它们都是通过检验是否存在单位根来检验时间序列的平稳性。其中 ADF 校验是对 DF 校验进行了扩充, ADF 校验的原理如下:

对于 AR (P) 过程, 如果其特征方程的所有特征根都在单位圆内, 则序列 $\{x_t\}$ 平稳, 如果有一个特征根 ϕ 存在且为 1, 则序列平稳, 且自回归系数之和切好等于 1。因此, 对于 AR (P) 过程可以通过检验自回归系数之和是否等于 1 来检验序列的平稳性。作如下假设检验:

$$H_0: \rho = 0 \leftrightarrow H_1: \rho < 0$$

其中:

$$\rho = \Phi_1 + \Phi_2 + \dots + \Phi_p - 1 \quad (1)$$

ADF 检验统计量: $\tau = \frac{\hat{\rho}}{S(\hat{\rho})}$, 其中 $S(\hat{\rho})$ 为参数 ρ 的样本标准差。

对于非平稳序列, 常用的是差分处理, 以下所有的讨论都是基于平稳化的时间序列。

1.1.2 确定模型阶数

AR 模型建立首先要确定模型的阶数, 当模型阶数较高时, 模型预测的结果就比较逼近真实值, 但模型阶数的增高时则模型参数的随之增大, 因而又会使预测误差增大。故应综合考虑两方面, 确定一个合适的阶数。

目前常用的模型定阶的方法有很多, 如 F 准则, FPE 准则, AIC 准则等。文中使用 AIC 准则等。AIC 是衡量统计模

型拟合优良性的一种标准, 由日本统计学家赤池弘次在 1974 年提出, 它建立在熵的概念上, 提供了权衡估计模型复杂度和拟合数据优良性的标准。通常情况下, AIC 定义为:

$$AIC = 2K - 2\ln(L) \quad (2)$$

其中: K 是模型参数个数, L 是似然函数。从一组可供选择的模型中选择最佳模型时, 通常选择 AIC 最小的模型。

1.2 PSO_SVR 模型

1.2.1 SVR 算法介绍

对于训练样本数据集 $(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)$, 其中 $x_i \in R^n$ 作为输入, $y_i \in R$ 作为输出, 则 SVR 预测的最优化问题为:

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{S. T.} \quad & \begin{cases} y_i - (w \cdot x_i) - b \leq \epsilon + \xi_i \\ (w \cdot x_i) + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \end{aligned} \quad (3)$$

其中, 惩罚因子 C 决定了在函数的偏平度和对大于 ϵ 的偏差的容忍之间的均衡, 模型对数据的拟合能力与 C 呈正相关; 松弛因子 ξ_i 和 ξ_i^* 主要用于控制线性不可分边界。

线性 SVR 可以通过引入核函数 $K(x, x')$ 推广到高维空间中, 通过求解下面的优化问题在高维空间中构造决策超平面:

$$\begin{aligned} \max \quad & W(\alpha) = -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j) - \\ & \epsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \end{aligned} \quad (4)$$

$$\text{S. T.} \quad \begin{cases} \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \\ \alpha_i, \alpha_i^* \in [0, C] \end{cases} \quad (5)$$

对应的决策函数形式为:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (6)$$

1.2.2 PSO 优化 SVR 参数

对于 SVR, 不敏感损失系数、惩罚系数 C 、核函数及其参数的优化选择对回归模型的学习精度和推广能力的好坏起着决定性的作用。PSO 算法是基于种群的一种搜索策略, 没有很多参数需要调整, 且收敛速度快, 在处理高维问题上有一定的优势^[6]。因而文中使用 PSO 优化 SVR 模型的参数 C (惩罚系数)、 g (核函数参数)、 p (损失函数参数), 提高其学习精度。

选用 (C, g, p) 来决定 PSO 粒子群粒子的位置和速度, 适应度也函数选用能够直接反应 SVR 回归性能的均方差 (MSE)。PSO 优化 SVR 的具体步骤如下:

- 1) 初始化参数, 确定粒子群的大小以及算法的最大迭代次数;
- 2) 计算每个粒子的适应度, 选取当前适应度最好的粒子作为初始全局的最优值;
- 3) 更新粒子的速度与位置;
- 4) 计算当前种群粒子的适应度, 选取最优的粒子与全局最优进行比较, 选其中的较优值作为新的全局最优值。
- 5) 判断是否达到迭代条件, 若否, 则跳转到继续执行; 若是, 则停止。

1.3 AR_PSO_SVR 预测模型

对于时间序列 $\{x_1, x_2, \dots, x_n\}$, $\{x_n\}$ 为预测值, 首先使用

AR 模型判断时间序列的平稳性, 其次确定 AR 的模型的阶数 m , 该阶数作为 SVR 学习样本的输入维数。构造输入 $x = \{x_{n-1}, x_{n-2}, \dots, x_{n-m}\}$, 对应输出 $y = \{x_n\}$ 的映射关系: $R^m \rightarrow R$, 则 SVR 的学习样本如下:

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_m \\ x_2 & x_3 & \cdots & x_{m+1} \\ \cdots & \cdots & \cdots & \cdots \\ x_{n-m} & x_{n-m+1} & \cdots & x_{n-1} \end{bmatrix} \quad (7)$$

$$Y = \begin{bmatrix} x_{m+1} \\ x_{m+2} \\ \cdots \\ x_n \end{bmatrix} \quad (8)$$

回归函数为:

$$y_t = \sum_{i=1}^{n-m} (\alpha_i - \alpha_i^*) K(x_i, x_{n-m+1}) + b, t = m+1, \dots, n \quad (9)$$

AR_PSO_SVR 模型用于滚动轴承趋势预测的整体流程如图 1 所示。

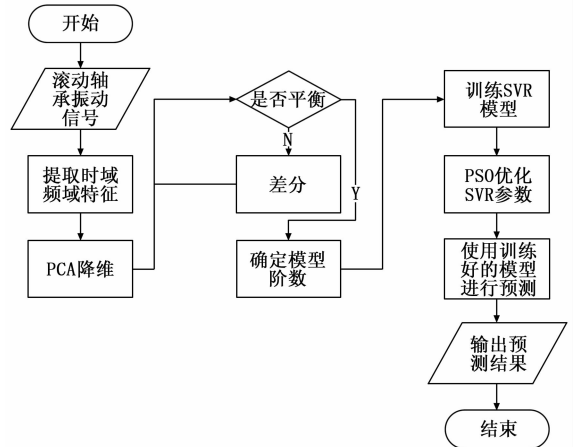


图 1 AR_PSO_SVR 模型流程图

2 实验数据分析

2.1 实验数据来源

文中使用的实验数据是由美国辛辛那提大学智能系统维护中心提供的滚动轴承全寿命周期加速轴承性能退化实验数据。该数据的采样时间间隔是 10 分钟, 采样频率是 20 kHz, 采样点数为 20 480 个, 图 2 是轴承运行后期的一个振动信号幅值图。




图 2 轴承振动信号幅值图

2.2 特征提取

滚动轴承的原始信号数据量比较大且含有大量的噪声,

为了提高预测的准确度, 需要对获取的全寿命数据进行特征提取^[7-9], 参考文献 [10] 中的方法提取时域与频域指标共 29 个, 具体的时域特征指标如表 1 所示, 频域特征如表 2 所示。

表 1 时域特征

特征	特征表达式	特征	特征表达式
均值	$\bar{X} = \frac{1}{N} \sum_{i=1}^N x_i$	峭度	$\beta = \frac{1}{N} \sum_{i=1}^N x_i^3$
均方根值	$X_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	方差	$\sigma_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{X})^2$
方根幅值	$X_r = \left[\frac{1}{N} \sum_{i=1}^N x_i \right]^2$	最大值	$X_{max} = \max \{ x_i \}$ ($i = 1, 2, \dots, N$)
绝对平均幅值	$ \bar{X} = \frac{1}{N} \sum_{i=1}^N x_i $	最小值	$X_{min} = \min \{ x_i \}$ ($i = 1, 2, \dots, N$)
偏斜度	$\alpha = \frac{1}{N} \sum_{i=1}^N x_i^3$	峰峰值	$X_{p-p} = \max(x_i) - \min(x_i)$
波形指标	$S_f = \frac{X_{rms}}{ \bar{X} }$	峰值指标	$C_f = \frac{X_{max}}{X_{rms}}$
脉冲指标	$I_f = \frac{X_{max}}{ \bar{X} }$	裕度指标	$CL_f = \frac{X_{max}}{X_r}$
峭度指标	$K_v = \frac{\beta}{X_{rms}^3}$	偏斜度指标	$P = \frac{\alpha}{X_{rms}^3}$

表 2 频域特征

特征	表达式	特征	表达式
均值 频率	$p_1 = \frac{\sum_{k=1}^K s(k)}{K}$	频率 特征 4	$p_8 = \sqrt{\frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K f_k^2 s(k)}}$
频率标 准差	$p_2 = \frac{\sum_{k=1}^K (s(k) - p_1)^2}{K-1}$	频率 特征 5	$p_9 = \frac{\sum_{k=1}^K f_k^2 s(k)}{\sqrt{\sum_{k=1}^K s(k) \sum_{k=1}^K f_k^2 s(k)}}$
频率 特征 1	$p_3 = \frac{\sum_{k=1}^K (s(k) - p_1)^3}{K(\sqrt{p_2})^3}$	频率 特征 6	$p_{10} = \frac{p_6}{p_5}$
频率 特征 2	$p_4 = \frac{\sum_{k=1}^K (s(k) - p_1)}{Kp_2^2}$	频率 特征 7	$p_{11} = \frac{\sum_{k=1}^K (f_k - p_5)^3 s(k)}{Kp_3^3}$
频率 中心	$p_5 = \frac{\sum_{k=1}^K f_k s(k)}{\sum_{k=1}^K s(k)}$	频率 特征 8	$p_{12} = \frac{\sum_{k=1}^K (f_k - p_5)^4 s(k)}{Kp_3^3}$
频率 特征 3	$p_6 = \sqrt{\frac{\sum_{k=1}^K (f_k - p_5)^2 s(k)}{K}}$	频率 特征 9	$p_{13} = \frac{\sum_{k=1}^K (f_k - p_5)^{\frac{1}{2}} s(k)}{Kp_6}$
均方 根频率	$p_7 = \sqrt{\frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K s(k)}}$		

2.3 PCA 降维

由于提取的指标不统一且存在一定的冗余性, 为有效的提

取特征量, 需要对特征向量通过主成分分析 (Principal Component Analysis, PCA) 进行降维。PCA 是一种将多个指标归结为线性无关的少数主成分的降维技术, 这些主成分能够反映原始变量的绝大部分信息, 他们通常表示为原始变量的线性组合^[11]。更主要的是经过 PCA 降维后的数据去除了噪声。根据主成分的特征值的方差贡献率, 选取 PCA 主成分最大的一个特征量来检验 AR_PSO_SVR 模型的预测效果, 该主成分的趋势如图 3 所示。




图 3 PCA 第一主成分量趋势图

从图中可以看出在 700 点之前, 特征的信息变化较小, 此时轴承处于正常运行阶段, 700 点以后提取的特征值发生了较大的变化, 反映出了轴承的退化趋势。因此选取 700 点到 900 点作为训练数据, 901 点到 920 点作为预测数据。

3 实验结果分析

为了检验 AR 和 PSO_SVR 模型的预测效果, 使用 AR 模型以及 PSO_SVR 模型与其进行对比。选用均方根误差 MSE、绝对平均误差 MAE 以及决定系数 R^2 作为评价指标来评价预测效果。图 4 为原始数据与 AR_PSO_SVR 模型预测值的比较图。

$$\begin{aligned}
 MSE &= \frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \\
 MAE &= \frac{1}{N} \sum_{i=1}^n |y_i - \hat{y}_i| \\
 R^2 &= 1 - \frac{\sum_{i=0}^n (y_i - \hat{y}_i)^2}{\sum_{i=0}^n (y_i - \bar{y})^2} \tag{10}
 \end{aligned}$$

式中, y_i 表示原始值, \hat{y}_i 表示预测值, \bar{y} 表示原始值得平均值。

图 4 中第一个图是使用训练好的模型对训练数据进行回判得到的结果与实际值进行比较, 从图中可以看出二者的结果比较吻合, 回判的 MSE 值是 0.0028, R^2 值为 0.9701。第二个图是对测试数据进行预测得到的结果与实际值进行比较, 预测的 MSE 值为 0.0117, R^2 为 0.8276。

图 5 比较 AR_PSO_SVR 模型和 AR 模型以及 PSO_SVR 模型的效果, 从图中可以看出 AR 模型的预测曲线和原始曲线相比不够平滑, 有很多拐点; 单独使用 PSO_SVR 模型的预测趋势和原始趋势相比误差较大; AR_PSO_SVR 模型的预测效果较好。各个模型的各项指标如表 3 所示。AR_PSO_SVR 模型预测的 MSE、MAE 和 R^2 值均低于 AR 模型和 PSO_SVR 模型, 其中 R^2 值较 AR 模型和 PSO_SVR 模型分别提高了 25.89% 和 53.83%。这些数据表明文中使用模型的预测效果较好。