

## 基于神经网络的航空发动机滑油监测分析

王 广 李 军

(空军工程大学工程学院 西安 710038)

**摘要:** 提出了一种基于 BP 神经网络的航空发动机滑油金属含量预测方法, 给出了运用自回归模型 (AR 模型) 预测模型和神经网络进行预测的一般公式。将其应用于某型发动机滑油的铁金属含量预测, 结果表明, 与传统的 AR 预测模型相比, 神经网络表现出优秀的推广能力。经过数值仿真得出 AR 模型仅能预测出序列的变化趋势; 神经网络预测推广能力强、具有较强的鲁棒性和容错性, 可以为发动机的监控提供重要的依据。

**关键词:** 航空发动机; 滑油预测; 自回归模型; BP 网络; 时间序列预测

**中图分类号:** V317.1; TP183 **文献标识码:** A **文章编号:** 0254-0150 (2005) 5-123-3

## Aeroengine Lube Monitoring Analysis Based on Neural Net

Wang Guang Li Jun

(Engineering Institute, Air Force Engineering University, Xi'an 710038, China)

**Abstract:** A method was proposed which can be used to forecast lube oil metal content of aviation motor based on BP neural net, and the ordinary application formula of auto-regressive (AR) forecasting model and neural net model was given out. The two methods were used to forecast lube oil metal content of a kind of motor, the result shows that, in contrast to AR forecasting model, the neural net model has excellent popularization capability. The numeric value imitation show that AR model can only forecast the array's alternation tendency, but the neural net has powerful rousting and fault-tolerance, it can be used in the motor supervision.

**Keywords:** aeroengine; lube monitoring; auto-regressive model; BP net; time series forecasting

随着航空发动机性能的不断提高, 发动机各部件的工作状况更加恶劣。滑油的消耗量及滑油中金属含量值能比较准确地反映发动机的轴承、附件和齿轮的工作情况。当滑油消耗量或滑油中某些金属含量偏高时, 则说明轴承、机匣或齿轮磨损严重。通过对滑油消耗量及滑油中镁、铝、铁和铜含量值及其发展趋势监控, 可实现对发动机轴承、机匣或齿轮工作情况的监控, 从而减少不必要的零部件更换, 并能降低故障模式的二次损伤, 有效地监视发动机传动系统零部件的磨损情况及故障特征<sup>[1,2]</sup>。

时间序列预测模型可用来预测分析金属含量的变化趋势。常规的时间序列预测方法主要以自回归模型 (AR 模型) 为主, 这种模型在理论上十分成熟, 但其精度不高, 且容错性差, 仅仅适合做短区间预报; 而神经网络由于采用了新型的学习机制, 泛化能力很强, 使得预测模型具有相当的精度。

某型飞机发动机飞参系统记录了大量关于滑油的数据, 本文作者依据现有的滑油金属含量历史数据, 分别建立了 AR 和神经网络预测模型, 然后将其应用

于该发动机的滑油金属含量的预测, 并对两种模型得出的结论作了比较。

## 1 自回归模型

对于一个平稳的时间序列  $\{x_1, x_2, \dots, x_n\}$ , 可以建立一个线性时间反演的时序模型:

$$x_t - \varphi_1 x_{t-1} - \dots - \varphi_p x_{t-p} = a_t + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} \quad (1)$$

式中:  $x_t, t=1, 2, \dots, n$  为离散时间数列;  $\varphi_i, i=1, 2, \dots, p$  为自回归系数;  $\theta_i, i=1, 2, \dots, q$  为滑动平均系数;  $a_t, t=1, 2, \dots, n$  为方差为  $\sigma_a^2$  的白噪声序列。

该时序模型称为  $(p, q)$  阶自回归滑动平均模型, 简称为 ARMA  $(p, q)$ 。当  $q=0$ , 得到的即为  $p$  阶自回归模型, 简称为 AR  $(p)$ 。

## 1.1 AR 模型的系数和阶次确定

时间序列  $\{x_i\}, i=1, 2, \dots, n$  可写成以下矩阵形式的线性组合。

$$Y = \varphi X + a \quad (2)$$

其中

$$Y = \begin{bmatrix} x_{p+1} \\ x_{p+2} \\ \vdots \\ x_n \end{bmatrix} \quad \varphi = \begin{bmatrix} \varphi_1 \\ \varphi_2 \\ \vdots \\ \varphi_p \end{bmatrix} \quad a = \begin{bmatrix} a_{p+1} \\ a_{p+2} \\ \vdots \\ a_n \end{bmatrix}$$

收稿日期: 2004-09-06

作者简介: 王广 (1981-), 男, 在读硕士研究生, 研究方向为航空发动机性能与故障诊断. E-mail: wwwmy007@eyou.com.

$$X = \begin{bmatrix} x_p & x_{p-1} & \cdots & x_1 \\ x_{p+1} & x_{p+2} & \cdots & x_2 \\ \vdots & \vdots & \ddots & \vdots \\ x_{n-1} & x_{n-2} & \cdots & x_{n-p} \end{bmatrix}$$

根据多元回归理论, 可得到参数矩阵的最小二乘估计为:

$$\hat{\varphi} = (X^T X)^{-1} X^T Y \quad (3)$$

可以证明  $\hat{\varphi}$  为真值  $\varphi$  的无偏估计, 因此采用最小二乘估计精度较高。从理论上讲, ARMA 模型成立的条件是  $\{a_t\}$  为白噪声。因此, 模型适用性的准则是检验  $\{a_t\}$  是否为白噪声。实际中常用的准则有 FPE 准则、AIC 准则、BIC 准则等。本文采用最终预报误差 (FPE) 准则。

$$FPE(k) = \frac{n+k}{n-k} \sigma_a^2 \quad (4)$$

其中

$$\sigma_a^2 = E(a_t^2) = \frac{1}{n-k} \sum_{t=k+1}^n [x_t - \varphi_1 x_{t-1} - \cdots - \varphi_k x_{t-k}]^2$$

当  $k$  值增大时, 残差  $\sigma_a^2$  将减少, 因此可以找到一个最优值  $p$  使得 FPE 达到最小。

## 1.2 AR 模型预测机理

参照文献 [1] 的论述可知, AR( $p$ ) 模型在  $t$  时刻向前预测  $l$  步的结果为:

$$\hat{x}_t(l) = \sum_{i=1}^p \varphi_i x_{t+l-i} + \sum_{i=1}^{l-1} \varphi_i \hat{x}_t(l-i) + \sum_{i=1}^p \varphi_i x_{t+l-i} + \sum_{i=1}^p \varphi_i \hat{x}_t(l-i) \quad (5)$$

从中可以看出, 其中预测结果只与  $x_t, x_{t-1}, \dots, x_{t+1-p}$  相关, 而不需要求解  $\{a_t\}$ 。

## 2 神经网络用于时间序列预测<sup>[4]</sup>

### 2.1 BP 网络

BP 网络是一种多层前馈性的神经网络, 是神经网络中用得最广泛的一种网络结构。经过训练的 BP 神经网络, 对于不是样本集合的输入也能给出合适的输出, 这种泛化的功能, 从函数拟合的角度来看, 说明神经网络具有插值的功能。因此, 通过 BP 神经网络对滑油序列数据进行学习后, 实现网络对输入输出的准确映射后, 就可以用来对已知的数据进行预测。

### 2.2 基于 BP 网络的时间序列预测模型

#### 2.2.1 数据准备

对于平稳时间序列  $\{x_1, x_2, \dots, x_n\}$ , 为了能够采用神经网络进行预测, 关键是如何重构线性空间, 如何将其转化成矩阵形式获得数据间的相互关联关系以便于挖掘尽可能大的信息量。朴素的讲就是如果  $\{x_t\}$  是预测的目标值, 将先前的目标值  $\{x_{t-1}, x_{t-2}, \dots, x_{t-p}\}$  作为相关量, 由于先前的目标值可

会影响到未来值, 因此在模型中考虑先前值的影响将有助于更好地预测。建立自相关输入  $\hat{x}_t = \{x_{t-1}, x_{t-2}, \dots, x_{t-p}\}$  与输出  $y_t = \{x_t\}$  之间的一一映射关系  $f: R^p \rightarrow R$ , 其中  $p$  值称为映射维数, 可以看出  $p$  值的选取实际隐含反映了转换后矩阵蕴涵的知识量。本文采用 FPE 准则评价预测误差, 并根据误差值大小来优化选取映射维数  $p$ 。经过这样的变换之后, 可以得到用于网络学习的样本:

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_p \\ x_2 & x_3 & \cdots & x_{p+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n-p} & x_{n-p+1} & \cdots & x_{n-1} \end{bmatrix}, Y = \begin{bmatrix} x_{p+1} \\ x_{p+2} \\ \vdots \\ x_n \end{bmatrix}$$

#### 2.2.2 预测模型

在得到学习样本之后, 就可对神经网络进行训练, 注意到在上面的数据项中还有一项没有利用, 即  $\vec{x}_{n-p+1} = \{x_{n-p+1}, x_{n-p+2}, \dots, x_n\}$ , 因此可得到对第  $n+1$  点的预测为:

$$y_{n+1} = \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) k(\vec{x}_i \cdot \vec{x}_{n-p+1}) + b \quad (6)$$

得到第  $n+1$  点后, 又可以得到一个样本数据

$$\vec{x}_{n-p+2} = \{x_{n-p+2}, x_{n-p+3}, \dots, x_n, \hat{x}_{n+1}\}$$

其中  $\hat{x}_{n+1}$  表示第  $n+1$  个数据的预测值, 可得第  $n+2$  点的预测值:

$$y_{n+2} = \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) k(\vec{x}_i \cdot \vec{x}_{n-p+2}) + b \quad (7)$$

一般地可以得到预测第  $l$  步的神经网络数学模型为:

$$y_{n+l} = \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) k(\vec{x}_i \cdot \vec{x}_{n-p+l}) + b \quad (8)$$

其中  $\vec{x}_{n-p+l} = \{x_{n-p+l}, \dots, \hat{x}_{n+1}, \dots, \hat{x}_{n+l-1}\}$

### 3 应用实例

本文采用的数据来自某型发动机从一次换油到另一次换油的完整工作阶段的滑油光谱分析数据, 并按照光谱分析的时间排序得到金属含量数据序列 (共 100 个), 因为在滑油监测中以 Fe 的金属含量为主要监控对象, 因此本文仅以含 Fe 量的时间序列分析为例。

#### 3.1 数据的预处理

首先, 对数据进行相对化处理, 得到的时间序列结果如图 1 所示, 再对数据零化处理得到新的 Fe 相对含量时间序列  $\{x_t\}$ 。本文采用工程处理方法不对其进行正态性检验, 认为经过处

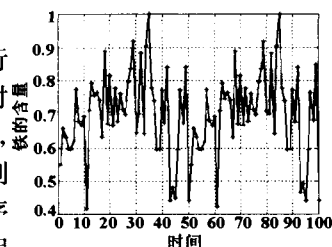


图 1 Fe 相对含量时间序列

理之后的时间序列  $\{x_t\}$  满足平稳、正态要求。

### 3.2 AR 模型与 BP 网络预测模型的建立

从图 2 中可以看出当  $p_{AR}=7$  时 AR 模型 FPE 值达到最小; 为了简化运算、便于比较, BP 网络的  $p$  值我们也取为 7, 即神经网络的输入个数为 7。

### 3.3 训练与测试结果比较

将数据分成两组: 前 60 次数据作为训练数据, 后 40 次作为测试数据, 采用 AR 模型、BP 网络模型分别进行一步预测, 其结果分别见图 3、图 4。

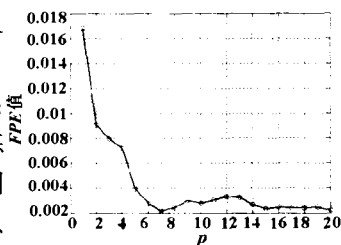


图 2  $p$  与 FPE 值

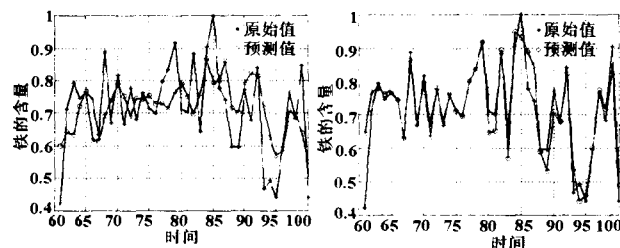


图 3 AR 模型预测结果与原始数据对比图

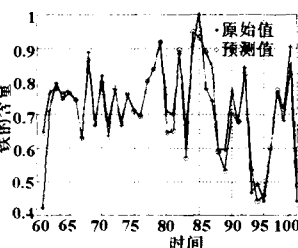


图 4 BP 网络模型预测结果与原始数据对比图

(上接第 92 页) 套管对胶筒的摩擦力小, 接触应力分布趋于对称, 当载荷较高时, 胶筒受摩擦力的影响, 靠加载端接触应力增高。在轴向载荷为 10 kN 时, 下胶筒还未与套管内壁接触, 此时先与套管内壁接触的中胶筒的接触应力比上胶筒的接触应力高, 而且接触区域也大; 当轴向载荷为 20 kN 时, 上胶筒与中胶筒的接触应力相当; 当轴向载荷为 30 kN 时, 上胶筒的接触应力已经开始大于中胶筒的接触应力, 并开始出现两个峰值, 之后随着载荷的增加, 3 个胶筒的接触应力都继续增大; 当坐封完成后, 上胶筒的接触应力最大, 中胶筒的接触应力其次, 下胶筒接触应力最小。

### 5 结论

(1) 所选本构模型 Yeoh 超弹模型能很好地模拟胶筒的变形。

(2) 3 个胶筒中上胶筒的接触应力最大, 起主要密封作用。

从图 3、图 4 可以看出, AR 模型只能反映原始时间序列的变化趋势, 而不能精确地预测出它的值; 神经网络的预测平均相对误差均增加, 但神经网络与 AR 模型相比仍然具有较高的精度, 这说明神经网络具有很强的推广能力, 用于航空发动机金属含量的时间序列预测是成功的。

### 4 结论

采用 AR 模型预测滑油金属含量的变化, 只能反映原始时间序列的变化趋势, 而不能精确地预测出它的值; 与 AR 模型相比神经网络预测具有较高的精度, 这说明神经网络应用于航空发动机金属含量的时间序列预测是成功的。神经网络具有很强的推广能力, 可为发动机润滑系统的监控提供重要的依据。

### 参考文献

- [1] 陈大光译. 航空发动机监视系统译文集 [C]. 北京: 航空工业部三零一所, 1992.
- [2] 张津, 李其汉. 航空发动机状态监视与故障诊断 [R]. 北京: 北京航空航天大学动力系, 1993.
- [3] 杨叔子, 吴雅. 时间序列分析的工程应用: 上、下册 [M]. 武汉: 华中理工大学出版社, 1996.
- [4] 楼顺天, 施阳. 基于 MATLAB 的系统分析与设计——神经网络 [M]. 西安: 西安电子科技大学出版社, 2000.
- [5] 靳蕃. 神经计算智能基础 [M]. 上海: 复旦大学出版社, 2000.

(3) 由于所用实验数据为常温下测定的, 而橡胶在高温下会变硬, 同时高温下橡胶材料的应力松弛特性会变得明显, 这些都会引起在同样的坐封力下接触应力的降低, 因此为了得到同样大小的接触应力, 应适当地提高坐封力。

### 参考文献

- [1] 江汉石油学院采油研究室编. 封隔器理论基础与应用. 北京: 石油工业出版社, 1983.
- [2] [美] A N Gent 主编, 张立群, 田明, 刘力, 冯予星译. 橡胶工程. 北京: 化学工业出版社, 2002.
- [3] [美] L R G Treloar 著, 王梦蛟, 王培国, 薛广智译. 橡胶弹性物理学. 北京: 化学工业出版社, 1982.
- [4] O H Yeoh. Some forms of the strain energy function for rubber. Rubber Chemistry and Technology, 1993, 66 (5): 754 ~ 771.
- [5] O H Yeoh. Characterization of elastic properties of carbon black-filled rubber vulcanizates. Rubber Chemistry and Technology, 1990, 63 (5): 792 ~ 805.