

光谱油样分析监测技术中的神经网络预测方法

杨虞微, 陈 果

南京航空航天大学民航学院, 江苏 南京 210016

摘 要 光谱油样分析是机械磨损状态监测与故障诊断的重要技术, 基于光谱数据的机械状态预测有利于发现机械系统的早期磨损故障。由于神经网络对于非线性模型的辨识和非平稳信号的预测, 与传统预测模型相比具有明显的优势, 文章将神经网络预测方法运用于光谱分析, 提出了基于神经网络预测的光谱分析监测技术。在预测模型中采用了三层 BP 网络模型, 针对神经网络的结构对于信号预测或模型辨识的精度具有影响很大的问题, 文章利用遗传算法, 对神经网络输入节点数、隐层节点数和网络收敛的均方误差 (MSE) 目标值进行了优化, 得到了最优的网络预测模型。最后, 对某发动机实际的光谱分析数据进行了预测和分析, 并与传统 ARMA 模型的预测结果进行了比较, 结果充分表明了本方法的有效性和优越性。

主题词 光谱油样分析; 预测; 神经网络; 遗传算法; 状态监测

中图分类号: TH165. 3; O329; F201 **文献标识码**: A **文章编号**: 1000-0593(2005)08-1339-05

引 言

光谱分析法分为原子吸收光谱和原子发射光谱法两种。主要是根据油样中各种金属磨粒在离子状态下受到激发时所发射的特定波长的光谱来检测油样金属类型和含量的。光谱分析操作简单, 精度高, 分析速度快, 而且在有色金属元素的检测方面具有独特的优势。因此, 在国内外, 目前光谱分析技术广泛应用于机械设备的故障诊断中, 其应用领域涉及到机车柴油机、船舶柴油机、航空发动机及大型柴油机发电机组等机械设备的有色金属磨粒的检测和识别及早期故障监测。

目前, 对机械系统润滑油的光谱分析, 一方面, 由于磨损金属成分与对应的摩擦副材质相对应, 所以可以利用光谱分析进行故障定位, 另一方面, 机械磨损状态是一个逐步发展的过程, 因此可以利用光谱分析来进行机械系统磨损状态的预测, 以期尽早对故障的发展趋势进行预测和评估, 从而避免重大事故的发生和及时安排维修工作。前者属于诊断范畴, 后者属于监测范畴, 只有建立在监测基础上的诊断才具有针对性, 从而避免盲目, 所以有效地对机械系统磨损状态进行可靠的预测具有十分重大的意义。

传统的预测模型是 ARMA 模型, 它要求时间序列是平稳的, 且服从正态分布, 文献 [1] 运用 Box-Jenkins 法建立了 ARMA 模型, 并对光谱分析数据进行了预测分析。但是机械系统本身具有很多非线性因素, 特别是机械系统出现故障时, 其磨损状态将产生很大的变化, 磨损进程将发展得很

快, 所以表现出的光谱分析得到的元素含量也将出现非线性变化, 当对机械系统从正常运行到出现故障的整个阶段进行光谱分析时, 所得到的金属元素含量序列将出现严重的非平稳特征, 并表现出明显的磨损趋势, 因此, 在这种情况下, 传统的 ARMA 模型将不能有效, 从而不能对机械系统磨损状态进行准确的预测和评估。因此, 有必要寻找其他预测方法。

由于神经网络能拟合任意的非线性函数并且具有很强泛化能力, 因此进行非线性预测具有很大的潜力。Lapedes^[2] 等最早将神经网络应用于预测, 用神经网络对由计算机产生的时间序列仿真数据进行了学习和预测。Weigend^[3] 等利用神经网络研究了太阳黑子的年平均活动情况, 将神经网络与回归分析方法作了比较, 其研究结果表明神经网络预测优于统计预测。

但是, 神经网络应用到预测还有许多问题需要解决^[4], 其中最为突出的问题就是难于确定最合适的神经网络结构。本文将神经网络方法引入光谱分析的监测技术中, 同时对神经网络的结构进行优化, 从而实现了对机械磨损故障的精确预测。

1 BP 网络的预测方法

利用神经网络进行多变量时间序列的预测原理与单变量时间序列预测相同, 多步预测可以由单步预测迭代而成, 因此不失一般性, 可以以单变量单步预测为例进行研究。设一个单变量时间序列 $\{x_1, x_2, \dots\}$, 对它进行预测的前提是认

收稿日期: 2004-04-08, 修订日期: 2004-07-21

作者简介: 杨虞微, 1972 年生, 南京航空航天大学民航学院博士研究生

为其未来值与其前面的 m 个值之间有着某种函数关系, 可描述为

$$x_{n+k} = F(x_n, x_{n-1}, \dots, x_{n-m+1}) \quad (1)$$

利用神经网络来拟合这种函数关系 F , 并用它来推导未来的值。进行时间序列预测的神经网络结构可以分为两种, 一种是单步预测网络, 一种是多步预测网络。单步预测网络输出个数为 1 个, 一次可计算一步预测值。多步预测网络的输出个数不止一个而是多个 (k 个), 每次可计算出 k 步的预测值。在预测过程中, 可将得到的预测值作为下一步预测的输入来计算进一步的预测值, 这样通过迭代来进行多步预测。

2 神经网络预测精度评价函数

在实际应用中, 对于实际测得的时间序列 $\{x_1, x_2, \dots\}$, 可以利用其一部分数据 (通常为前半) 来建模, 而用另一部分数据 (后半) 来对所建模型进行验证, 如果预测值与实测值相差越少, 显然模型越理想, 理想情况是预测值与实测值相等, 则达到完美预测。通常衡量预测值与实测值差别的变量采用平均相对变动值 (Average relative variance: ARV)^[5], 其定义为

$$ARV = \frac{\sum_{i=1}^N [x(i) - \hat{x}(i)]^2}{\sum_{i=1}^N [x(i) - \bar{x}]^2} \quad (2)$$

其中: N -比较数据个数; $x(i)$ -实测数据值; \bar{x} -实测数据平均值; $\hat{x}(i)$ -预测值。显然, 平均相对变动值 ARV 越小, 也表明预测效果越好, $ARV=0$ 表示达到了理想预测效果, 当 $ARV=1$ 时, 表明模型仅达到平均值的预测效果。

为了分析神经网络的泛化能力, 设训练点数为 N_1 , 测试点数为 N_2 , 根据 ARV 的定义再定义三个函数, 即综合 ARV 值 ARV1、训练 ARV 值 ARV2、预测 ARV 值 ARV3,

$$ARV1 = \frac{\sum_{i=1}^{N_1+N_2} [x(i) - \hat{x}(i)]^2}{\sum_{i=1}^{N_1+N_2} [x(i) - \bar{x}(i)]^2}$$

$$ARV2 = \frac{\sum_{i=1}^{N_1} [x(i) - \hat{x}(i)]^2}{\sum_{i=1}^{N_1} [x(i) - \bar{x}(i)]^2}$$

$$ARV3 = \frac{\sum_{i=1}^{N_2} [x(i) - \hat{x}(i)]^2}{\sum_{i=1}^{N_2} [x(i) - \bar{x}(i)]^2} \quad (3)$$

显然, ARV1 综合反映了网络对训练点和预测点的拟合程度、ARV2 仅反映了网络对训练点的拟合程度、ARV3 仅反映了网络对预测点的拟合程度。

3 BP 网络预测模型及对预测精度的影响分析

在 BP 网络的单变量单步预测模型中, 输入层的节点数、隐层数和隐层节点数成为了 BP 网络预测模型中影响网络预测能力的最重要参数。Lippmann^[6] 和 Cyberko^[7] 曾指出, 有两个隐层, 就可以解决任何形式的分类问题; 后来 Robert Hecht Nielson^[8] 等人研究进一步指出: 只有一个隐层的神经网络, 只要隐层节点足够多, 就可以以任意精度逼近一个非线性函数。由此可见, 用于预测的 BP 网络只需要三层, 且输出节点数可以根据预测的功能事先确定, 所以影响 BP 网络预测能力的参数只剩下输入节点数和隐层节点数。因此本文选取输入节点数和隐层节点数来作为网络预测精度的影响因素来分析。三层的 BP 网络预测模型拓扑结构如图 1 所示。选取 1700 至 1987 年的太阳黑子数据, 其中用前半数据进行三层 BP 网络建模, 用后半数据来对模型进行检验。可以对神经网络的输入节点数和隐层节点数对预测精度的影响进行分析, 表 1 在网络收敛允许的均方误差 MSE (Mean of squared error) 等于 0.001 时, 通过穷举法得到的前 5 个最优网络。由表可见, 不同的输入层和隐层节点数, 网络的预测精度将不同。

Table 1 Five good network structures according to ARV's order (MSE=0.001)

No	输入层节点数	隐层节点数	ARV1	ARV2	ARV3
1	7	37	0.116 2	0.027 5	0.177 6
2	6	37	0.120 9	0.027 7	0.185 6
3	14	45	0.129 2	0.027 4	0.194
4	7	25	0.137 1	0.028	0.212 5
5	8	32	0.137 6	0.028 5	0.212 5




Fig 1 BP Network forecasting model

另外, 网络收敛允许的均方误差 MSE 直接反映了其收敛位置和收敛情况, 对网络的预测精度也有很大的影响。图 2 为用上面同样的太阳黑子数据, 对拓扑结构为输入层节点数为 7 和隐层节点数为 37 的网络在不同的 MSE 目标值下进行训练, 并用训练好的网络进行预测, 得到的 ARV1, ARV2 及 ARV3 函数随 MSE 目标值的变化情况。由图 2 可见, 存在一个最优的 MSE, 使网络预测精度最高。

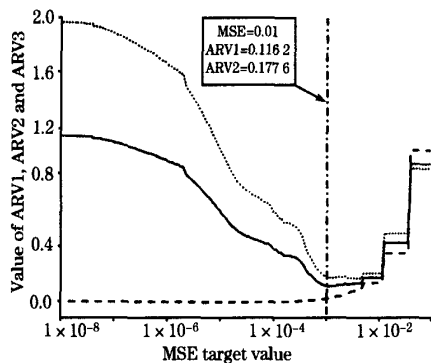


Fig 2 Relation of forecasting precision with MSE target value

—, ARV1; - - -, ARV2; ·····, ARV3

由此可见,对于 BP 网络,对其预测精度影响最大的参数为:输入层节点数 N 、隐层节点数 M 及网络收敛的 MSE 目标值。显然,存在一个最优的 N 、 M 和 MSE,使 BP 网络的预测精度达到最佳。

4 BP 网络预测模型优化的遗传算法构造

通过上述分析发现, BP 网络预测能力的影响参数为输入层节点数 N 、中间隐层节点数 M 及 MSE 目标值,为了获取最佳预测性能的 BP 网络,需要得到最佳的 N 、 M 和 MSE 目标值。显然这是一个优化问题,如果采取穷举的方式搜索最优值,计算量将十分巨大以至于无法实现。由于遗传算法^[9]具有隐含的并行性和强大全局搜索能力,可以在很短的时间内搜索到全局最优点。因此本文利用遗传算法来进行 BP 网络的预测模型的结构优化。

如图 3 所示,构造 BP 网络预测模型优化的遗传算法需要以下步骤,

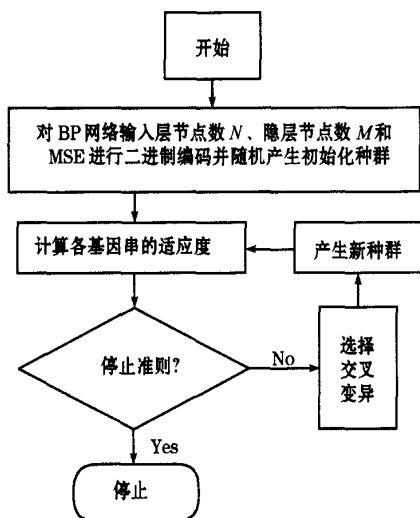


Fig 3 GA flow chart of BP network structure optimizing

(1) 设定种群数目 n , 种群数目太小,遗传算法的性能将变得很差或根本找不出问题的解,太大,则会增加计算量,使收敛时间增长,种群数目一般取为 30~50 个。

(2) 对输入层节点数 N 、中间隐层节点数 M 和 MSE 进行二进制编码,并随机产生初始种群。根据优化参数的取值范围,将其量化值(用二进制串表示)编码成基因串 $a = [a_0, \dots, a_{B-1}; B, \dots, a_{2B-1}; 2B, \dots, a_{3B-1}]$,其中 a 中的前 B 个量化值代表输入层节点数 N ,中间 B 个量化值代表中间隐层节点数 M ,最后 B 个量化值代表 MSE。所以每个基因串长度为 $3B$ 个比特位,此时的搜索空间有 2^{3B} 个点。

(3) 适应度函数的确定。由于 ARV1 综合反映了网络对训练点和预测点的拟合程度, ARV2 仅反映了网络对训练点的拟合程度, ARV3 仅反映了网络对预测点的拟合程度,显然 ARV2 不能用作确定适应度函数,而 ARV1 和 ARV3 可以用作确定适应度函数,但 ARV1 反映了神经网络内插和外推泛化能力,显然更为合理。因此,所以定义适应度函数为

$$f = \frac{1}{ARV1} \quad (4)$$

(4) 对种群解码,计算每条基因串的适应度。

(5) 将适应度最大的个体,即种群中最好的个体无条件地复制到下一代新种群中,然后对父代种群进行选择、交叉和变异等遗传算子运算,从而繁殖出下一代新种群其他 $n-1$ 个基因串。通常采用轮转法作为选取方法,适应度大的基因串选择的机会大,从而被遗传到下一代的机会大,相反,适应度小的基因串选择的机会小,从而被淘汰的概率大。交叉和变异是产生新个体的遗传算子,交叉率太大,将使高适应度的基因串结构很快被破坏掉,太小则使搜索停止不前,一般取为 0.5~0.9。变异率太大,将使遗传算法变为随机搜索,太小则不会产生新个体,一般取为 0.01~0.1。

(5) 如果达到设定的繁衍代数,返回最好的基因串,并将其作为输入层节点数和隐层节点数,算法结束。否则,回到(4)继续下一代的繁衍。

Table 2 Fe content ($10^{-6} \mu\text{g} \cdot \text{mL}^{-1}$) in some aeroengine spectrometric oil analysis

编号	含量	编号	含量	编号	含量	编号	含量
1	0.96	18	2.19	35	0.52	52	1.82
2	0.85	19	1.53	36	0.89	53	1.82
3	1.01	20	1.72	37	1.54	54	2.1
4	0.95	21	1.34	38	0.48	55	2.05
5	1.13	22	1.83	39	0.59	56	2.05
6	1.12	23	0.65	40	0.77	57	1.19
7	1.29	24	1.19	41	1.39	58	2.01
8	1.59	25	1.44	42	0.61	59	2.31
9	1.1	26	1.2	43	0.78	60	2.5
10	1.26	27	1.51	44	1.33	61	2.67
11	1.28	28	1.27	45	1.74	62	2.6
12	1.88	29	1.26	46	1.25	63	2.83
13	1.23	30	1.66	47	1.2	64	3.28
14	0.98	31	1.14	48	2.01	65	3.36
15	1.48	32	1.03	49	1.79	66	3.47
16	1.51	33	0.38	50	1.35	67	5.24
17	1.85	34	0.51	51	1.17	68	5.64

5 算例

为了验证本文方法的有效性,选取某航空发动机的光谱数据作为算例,表 2 为定期对油样进行光谱分析,得出的油样中 Fe 元素的含量($10^{-6} \mu\text{g} \cdot \text{mL}^{-1}$),所采用的仪器为美国 Bird 公司的原子发射光谱仪。

本文遗传算法参数为:种群数 $n=30$ 、基因串(染色体)采用二进制编码,交叉率和变异率分别为 0.50 和 0.05、进化代数 100 代。

N 、 M 及 MSE 均用 5 位二进制编码,为了避免节点数为 0,规定解码后,对于输入层节点数加上 2 得到 N ,而隐层节点数加上 10 以得到 M ,对 MSE,通过计算 $\text{MSE} = 10^{-(1+\text{MSE} \times 5/32)}$ 得到网络训练允许误差目标值。适应度函数取为 $f = 1/\text{ARV1}$ 。




Fig 4 Comparison of measured value and forecasted value (ANN model)
—, 测量值; ·····, 预测值

经过 50 代进化后,适应度函数达到了最大值,得到了最优的输入层节点数 N 和隐层节点数 M 。其优化结果为:最优的适应度值为 10.2467, ARV1 为 0.0976, 输入层节点数 $N=9$, 隐层节点数 $M=33$, $\text{MSE}=0.00022067$ 。图 4 为该网络对 Fe 元素的光谱数据的预测值与实测值的比较,其中,用前 50 个数据建模,用后 18 个数据来验证。从图中可以看出,尽管数据呈现出了明显的增长趋势,但测试数据与预测值的拟合程度达到了很高的精度。为了与传统 ARMA 模型进行比较,采用穷举法得到最佳的 ARMA 预测模型为 ARMA(27, 8)。用相同的数据建模和验证后,得到的实测值与预测值的比较如图 5 所示, ARV1 为 0.2127。对比图 4 和图 5,不难看出,神经网络预测模型得到了最佳的预测效果,而且整个建模过程实现了自动化,克服了人为选取参数的弊端。由此可见,实例充分验证了本文方法的正确合理性。

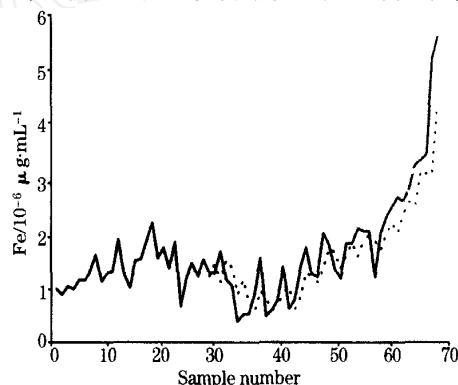


Fig 5 Comparison of measured value and forecasted value (ARMA model)
—, 测量值; ·····, 预测值

6 结论

(1) 提出用神经网络进行光谱数据预测的方法,从而对机械磨损故障实现有效的监测;

(2) 分析了神经网络进行非线性预测、多变量预测的优越性以及神经网络用于预测的缺点所在;

(3) 提出了影响 BP 网络预测能力的三个重要参数——输入层节点数、隐层节点数及网络训练允许误差 MSE 目标值;用遗传算法构造了同时优化影响神经网络预测精度的参

数(输入层节点数、隐层节点数及样本允许训练误差)的算法,得到了最优的网络预测模型;

(4) 用某航空发动机的实测光谱数据为例,通过遗传算法得到了最佳的网络预测模型,实现了发动机油样光谱数据的精确预测,并与 ARMA 模型进行了比较,充分验证了本文方法的有效性。

(5) 本文系统性地进行了这方面的工作,得到了一些有创新性的结果,有一定的实际意义。先前,王丽等^[10]也曾使用其他方法鉴别油样。

参 考 文 献

- [1] GAN Min-liang, ZUO Hong-fu, YANG Zhong, et al(干敏梁, 左洪福, 杨 忠, 等). Spectroscopy and Spectral Analysis(光谱学与光谱分析), 2000, 20(1): 64.
- [2] Lapedes A Farber. Nonlinear Signal Processing using Neural Network: Prediction and System Modeling, Technical Report LA-UR-87-2662, Los Alamos National Laboratory. Los Alamos. NM, 1987.
- [3] Weigend A B, et al. International Journal of Neural System, 1990, (1): 193.
- [4] LIU Bao, HU Dai-ping(刘 豹, 胡代平). Journal of System Engineering(系统工程学报), 1999, 14(4): 338.
- [5] Cholewo T, Zurada J M. Sequential Network Construction for Time Series Prediction. Proceedings of the IEEE International Joint Conference on Neural Networks, 1997, 2034.
- [6] Lippmann R P. IEEE ASSP Magazine, 1987, April, 12.
- [7] Cyberko G. Math. Control Signal System, 1989. 34.
- [8] ZHANG Li-ming(张立明). Artificial Network Model and Its Application(人工神经网络的模型及其应用). Shanghai: Fudan University Press(上海: 复旦大学出版社), 1995. 1.
- [9] Goldberg D. Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley, Reading, MA, 1989.
- [10] WANG Li, ZHUO Lin, HE Ying, et al(王 丽, 卓 林, 何 鹰, 等). Spectroscopy and Spectral Analysis(光谱学与光谱分析), 2004, 24(12): 1537.

Artificial Neural Network Forecasting Method in Monitoring Technique by Spectrometric Oil Analysis

YANG Yu-wei, CHEN Guo

Civil Aviation College, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China

Abstract The spectrometric oil analysis (SOA) is an important technique for machine state monitoring and fault diagnosis, and forecasting machine state through SOA results has an advantage of finding out machine system wear fault early. Because Artificial Neural Network (ANN) possesses obvious advantages over traditional forecasting models for identifying non-linear model and forecasting non-even signal, the ANN forecasting approach was applied to monitoring technique by SOA, and the monitoring technique by SOA based on ANN forecasting was put forward. In the forecasting model, a 3-layer BP network structure was adopted. Aiming at the problem that ANN structure has a great effect on forecasting precision, the authors utilized the Genetic Algorithm (GA) to optimize the node number of input layer, the node number of hidden layer, and MSE (Mean of Squared Error) target value which was required for ANN training, and obtained the optimum forecasting model of ANN. Finally, the practical SOA data of some engine was analyzed and forecasted by ANN, and the forecasting result was compared with that of traditional ARMA model. The result fully shows the superiority and effectivity of the new method.

Keywords Spectrometric oil analysis (SOA); Forecasting; Artificial neural Network (ANN); Genetic Algorithm (GA); State monitoring

(Received Apr. 8, 2004; accepted Jul. 21, 2004)