

文章编号: 1000-6893(2007)03-0535-05

用结构自适应神经网络预测航空发动机性能趋势

陈 果

(南京航空航天大学 民航学院, 江苏 南京 210016)

Forecasting Engine Performance Trend by Using Structure Self-Adaptive Neural Network

CHEN Guo

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

摘 要: 将航空发动机作为复杂非线性系统考虑, 运用神经网络超强的非线性映射能力和非线性时间序列分析的相空间重构理论, 建立航空发动机性能趋势预测的神经网络模型, 同时, 针对神经网络的结构设计困难问题, 建立了基于遗传算法的结构自适应神经网络预测模型, 实现了神经网络结构的优化。最后, 利用三组民航飞机发动机的性能数据进行了预测分析, 验证了利用结构自适应神经网络对航空发动机性能趋势进行预测的有效性。

关键词: 航空发动机状态监测; 人工神经网络; 非线性时间序列分析; 预测

中图分类号: TH165.3; O329; F201 **文献标识码:** A

Abstract: In this paper, the aero-engine is considered as a complex non-linear system, and by using the strong non-linear mapping ability of artificial neural network (ANN) and the phase space reconstruction theory, the ANN model of aero-engine performance trend forecasting is established. At the same time, aiming at the problem of ANN structure design, the structure self-adaptive ANN forecasting model is put forward, which can automatically realize structure optimizing by genetic algorithm (GA). Finally, three groups of practical performance data from civil aviation engines are used as forecasting analysis, and the results verify fully the correctness of the method which is put forward in this paper.

Key words: aero-engine condition monitoring; artificial neural network (ANN); non-linear time series analysis; forecasting

趋势分析方法属于航空发动机气路分析技术范畴^[1], 其基本思想是利用测量的气路主要截面的压力、温度、转子转速、燃油流量和可调几何参数来分析、判断和发动机气路有关的单元体和子系统的技术状态是否完好, 并隔离故障到这些单元体和子系统, 是当前发动机性能监视系统普遍采用的一种简单易行的手段。

目前, 世界上各著名的航空发动机制造商均具有相应的发动机性能监控软件, 比较著名的有: 普惠公司的 ECMII 和 TEAMIII 系统, GE 公司的 ADEPT 和 SA GE 系统以及罗罗公司的 COMPASS 系统等, 这些软件均具有发动机的性能趋势分析功能, 但是, 它们均只能对已知的历史数据进行趋势分析, 无法对性能数据的未来发展趋势进行预测和评估。

为了预知发动机的性能参数变化趋势, 需要基于历史数据对航空发动机建立数学模型。由于航空发动机是一个复杂的非线性系统, 常用的线

性时间序列分析模型存在较大的误差, 而神经网络模型的超强非线性映射能力, 其运用于非线性时间序列预测具有更大的优势^[2-6]。

然而, 神经网络结构设计长期以来是一个突出问题, 目前尚无统一解决办法, 有鉴于此, 作者在文献[6]中详细研究了影响神经网络预测精度的结构参数, 并在此基础上建立了基于遗传算法的结构自适应神经网络模型。本文将结构自适应神经网络模型应用于航空发动机性能趋势预测, 并用实际的发动机性能数据进行预测分析。

1 非线性时间序列预测的相空间重构理论

传统的线性时间序列预测方法, 如 ARMA 模型只能对线性系统、平稳的满足正态分布的信号进行辨识和预测, 对于非线性系统的时间序列预测就显得力不从心。为了对非线性时间序列进行预测, 需要研究非线性系统的运动规律, 把握其运动状态, 这就要求从系统产生的时间序列中抽取动力系统, 重构相空间, 最常用的方法是时延法^[7]。

设所研究的时间序列为 $\{x(t)\}$, $t = 1, 2, \dots$,

N , 则当前状态的信息可以表示成 m 维的延迟矢量

$$x(t +) = f [x(t) \quad x(t -) \quad \dots \quad x(t - (m - 1))] \quad (1)$$

式中: m 为嵌入维数; τ 为时间延迟, 通常取为采样间隔。由此可见, 对时间序列的预测, 关键在于根据已知时间序列数据, 对非线性系统相空间的重构, 找出从 m 维空间映射到一维空间的映射函数。而基于神经网络的预测原理, 就是用其来拟合这一非线性函数。

2 结构自适应神经网络预测模型

(1) 神经网络预测原理

经过研究证明: 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。因此, 不失一般性, 本文用三层 BP 网络来进行时间序列的预测。

设三层 BP 神经网络的隐层节点数为 q , 隐层节点的激活函数为 f_H , 阈值为 $\theta_j (j = 1, 2, \dots, q)$; 输出层节点数为 1, 隐层节点的激活函数为 f_o , 阈值为 θ 。第 i 个隐节点与第 j 个输入节点的连接权为 w_{ij} , 则第 i 个隐节点与输出节点的连接权为 w_i , 因此

$$x_{n+1} = f_o \left\{ \sum_{i=1}^q w_i f_H \left[\sum_{j=0}^{m-1} w_{ij} x_{n-j} + \theta_i \right] + \theta \right\} \quad (2)$$

通常 f_H 选取对数 S 函数或正切 S 函数, f_o 通常为线性函数, 但也可选取对数 S 函数或正切 S 函数。显然, 利用神经网络来拟合这种函数关系 F , 并可用它来推导未来的值。单步预测网络输出个数为 1 个, 一次可计算一步预测值。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, 这样通过迭代来实现多步预测。

(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 $\{x_1, x_2, \dots\}$, 可以利用一部分数据来建模, 而另一部分数据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。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)^[8], 即

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

式中: N 为比较数据个数; $x(i)$ 为实测数据值; \hat{x}

为实测数据平均值; $\hat{x}(i)$ 为预测值。显然, 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。

(3) 用遗传算法构造神经网络预测模型优化算法

神经网络预测精度, 关键在于训练后的网络泛化能力的强弱, 通常影响 BP 网络的因素有: 输入层节点数 (嵌入维数)、隐层数、隐层节点数、节点是否带反馈、初始权值、训练精度。因此神经网络预测模型的结构设计通常比较困难。

文献[7]研究发现, BP 网络预测能力的主要影响参数为输入层节点数 N , 中间隐层节点数 M 及网络训练的允许误差 MSE 目标值, 并基于遗传算法构造了结构自适应神经网络预测模型, 其基本思路是利用样本中的一部分数据作为训练样本对网络进行训练, 用其余的样本进行测试, 并以测试得到的预测精度构造遗传算法的适应度函数, 以 N, M 及 MSE 为遗传算法优化参数, 在适当的种群数、进化代数、交叉率及变异率下, 通过逐代遗传最终得到最优的神经网络预测模型。

3 结构自适应神经网络在航空发动机性能趋势预测中的应用研究

(1) 中国东方航空股份有限公司 PW4460 发动机起飞状态下 EGT 裕度预测

民航发动机气路可测参数裕度监控主要是起飞状态下的 EGT 裕度监控。起飞 EGT 裕度即为发动机排气温度 (EGT) 距离发动机红线值的差值。如有起飞 EGT 裕度, 那么在高度恒定条件下, 无论外界温度如何变化, 发动机的排气温度都不会达到或超出红线值, 即不会发生发动机超温。因此, 起飞状态下的 EGT 裕度是民航发动机性能状态的主要衡量指标。

采用中国东方航空股份有限公司实际的 PW4460 发动机的 EGTM 数据进行预测分析。数据点为发动机在两次维修间隔期间的起飞状态下的记录结果。数据时间间隔为 80 个飞行起落, 因此可以认为数据形成的序列为等间隔时间序列。数据总数为 53, 运用前 48 个数据进行建模, 后 5 个数据进行外推预测验证。

采用结构自适应神经网络对前 48 个 EGTM 数据进行预测。遗传算法参数为: 种群数为 30; 进化代数为 10; 交叉率为 0.5; 变异率为 0.05; 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,其二进制码长度分别为 3 位、5 位和 3 位;训练样本比例为 0.8;适应度函数为对所有样本数据的预测误差 ARV 值的倒数。

通过遗传算法优化后得到的神经网络预测模型为:输入层节点数为 4;隐层节点数为 22;训练精度为 0.000 6。应用该模型进行预测分析,图 1 为对前 48 个数据进行建模型所进行的一步预测值与实测值的比较结果,从图中很容易看出优化后得到的神经网络模型对该数据实现了有效预测。表 1 为对运用所得到的模型对后 5 个数据进行一步外推预测的预测值与实际值的比较结果。在一步预测的基础上,进行多步预测,其思路是将上一步预测结果代入下一步预测,通过迭代实现多步预测。表 2 为对后 5 个数据进行多步预测结果。

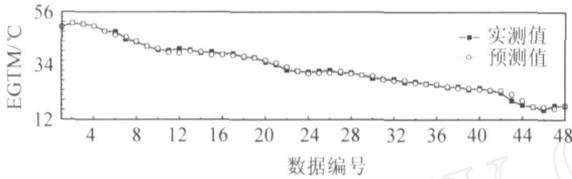


图 1 EGTm 的预测值与实测值的比较

Fig 1 EGTm comparison of forecasted and measured results

需要指出的是,在表 1 和表 2 中,预测的相对误差定义了 2 个,相对误差 1 是指绝对误差与当前时刻的实测值的比较;相对误差 2 是指绝对误差与实测值的变化范围之比,即为实测值的变化范围即为最大值与最小值之差。显然相对误差 2 更能够反映预测的精度。因此本文选择相对误差

2 来进行分析。在下面的计算中,所指的误差均为相对误差 2。

从表 1 可以看出一步预测的精度达到了很高,相对误差 2 基本上均在 10% 以内。从表 2 中可以看出,两步以内其预测精度较好,基本上在 10% 以内,但在两步以后其相对误差 2 则在 10% 以上。精度难于保证。

(2) 巡航状态下 JT9D 发动机 EGT 偏差趋势预测

民航发动机的核心部件是气路系统部件,包括压气机、燃烧室、涡轮。气路部件的一些热力参数可反应发动机性能变化,通过在巡航阶段采集温度(发动机进气温度,发动机排气温度)、压力、转子转速、燃油流量等发动机可测参数。再把这些参数转换成标准状态下的数值。与发动机厂家所给定的该型发动机的标准性能参数进行比较,看偏差的变化情况。通过对偏差的分析以及偏差变化趋势分析,来判断发动机健康状况,实现对发动机的监控,及时发现参数与标准值的偏差异常或参数的变化趋势异常,并分析出产生异常的原因,为预防和排除故障提供依据。

选取西北航空公司 JT9D 发动机的一组 EGT 偏差数据,数据总数为 31,数据时间间隔为 30 个飞行起落,运用前 26 个数据进行建模,后 5 个数据进行外推预测验证。对前 26 个数据建立结构自适应神经网络预测模型,遗传算法参数为:种群数为 30;进化代数为 10;交叉率为 0.5;变异率为 0.05;对输入层节点数 N 、中间隐层节点数

表 1 一步预测精度分析

Table 1 One-step forecasting precision analysis

步 数	数据编号	实测值 EGT _{mC} /	预测值 EGT _{mY} /	绝对误差 EGT _{mC} - EGT _{mY}	相对误差 1/ % EGT _{mC} - EGT _{mY} / EGT _{mC}	相对误差 2/ % EGT _{mC} - EGT _{mY} / EGT _m 变化范围
1	49	17.650	18.688	1.038	5.879	2.924
1	50	14.980	17.708	2.728	18.213	7.690
1	51	13.640	15.704	2.065	15.136	5.819
1	52	10.312	13.686	3.374	32.714	9.508
1	53	9.950	11.742	1.792	18.013	5.052

表 2 多步预测精度分析

Table 2 Multi-steps forecasting precision analysis

步 数	数据编号	实测值 EGT _{mC} /	预测值 EGT _{mY} /	绝对误差 EGT _{mC} - EGT _{mY}	相对误差 1/ % EGT _{mC} - EGT _{mY} / EGT _{mC}	相对误差 2/ % EGT _{mC} - EGT _{mY} / EGT _m 变化范围
1	49	17.650	18.688	1.038	5.879	2.924
2	50	14.980	18.613	3.633	24.249	10.238
3	51	13.640	19.193	5.553	40.714	15.652
4	52	10.312	19.164	8.852	85.833	24.948
5	53	9.950	18.665	8.715	87.581	24.563

M 和 MSE 进行二进制编码,其二进制码长度分别为 3 位、5 位和 3 位;训练样本比例为 0.8;适应度函数为预测误差 ARV 值的倒数。

通过遗传算法优化后得到的神经网络预测模型为:输入层节点数为 11;隐层节点数为 15;训练精度为 0.002。图 2 为应用所建的模型对前 26 个数据进行的一步预测结果。表 3 为运用所得到的模型对后 5 个数据进行一步外推预测的预测结果,不难看出,其预测精度基本上均在 5% 以内。表 4 为对后 5 个数据进行多步预测的结果,从表

中可以看出,对于该数据多步预测精度与一步预测的精度基本相当,仍然在 5% 以内。

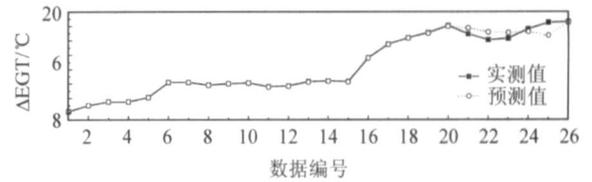


图 2 EGT 的预测值与实测值的比较

Fig. 2 EGT comparison of forecasted and measured results

表 3 一步预测精度分析

Table 3 One-step forecasting precision analysis

步数	数据编号	实测值 /	EGT_C	预测值 /	EGT_Y	绝对误差	相对误差 1/ %	相对误差 2/ %
						$ EGT_C - EGT_Y $	$ EGT_C - EGT_Y / EGT_C$	$ EGT_C - EGT_Y / EGT$ 变化范围
1	27	19.000		18.805		0.195	1.024	0.782
1	28	20.800		19.662		1.138	5.472	4.578
1	29	20.600		20.007		0.593	2.879	2.385
1	30	20.750		20.519 9		0.230	1.109	0.925
1	31	20.667		20.136		0.531	2.569	2.135

表 4 多步预测精度分析

Table 4 Multi-steps forecasting precision analysis

步数	数据编号	实测值 /	EGT_C	预测值 /	EGT_Y	绝对误差	相对误差 1/ %	相对误差 2/ %
						$ EGT_C - EGT_Y $	$ EGT_C - EGT_Y / EGT_C$	$ EGT_C - EGT_Y / EGT$ 变化范围
1	27	19.000		18.805		0.195	1.041 0	0.782
2	28	20.800		19.646		1.154	5.546 0	4.639
3	29	20.600		19.921		0.679	3.296 0	2.731
4	30	20.750		20.450		0.300	1.447 4	1.208
5	31	20.667		20.077		0.590	2.854 9	2.373

(3) 东航江苏公司 AE3007A 发动机巡航状态下 EGT 裕度预测

为了进一步进行性能参数预测分析,选取东航江苏公司 AE3007A 发动机的一组巡航状态下的 EGT 裕度数据来进行预测分析,数据总数为 110,数据时间间隔为 1 个飞行起落,运用前 105 个数据进行建模,后 5 个数据进行外推预测验证。遗传算法参数为:种群数为 30;进化代数为 10;交叉率为 0.5;变异率为 0.05;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,其二进制码长度分别为 3 位、5 位及 3 位;训练样本比例为 0.8;适应度函数为预测误差 ARV 值的倒数。

通过遗传算法优化后得到的神经网络预测模型为:输入层节点数为 8;隐层节点数为 37;

训练精度为 0.000 6。图 3 为利用优化得到的神经网络模型对前 105 个数据进行一步预测的结果。表 5 为运用所得到的最优模型对后 5 个数据进行一步外推预测的结果,不难看出,一步预测的精度基本上均在 4% 以内。表 6 为对后 5 个数据进行多步预测的结果,从表中可以看出,2 步以内的预测精度在 10% 以内,3 步以后精度无法保证。

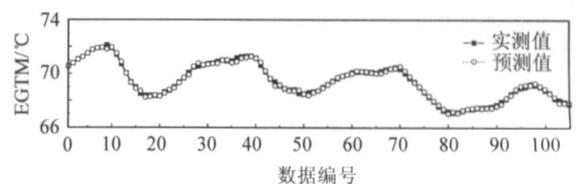


图 3 EGT_M 的预测值与实测值的比较

Fig. 3 EGT_M comparison of forecasted and measured results

表5 一步预测精度分析

Table 5 One-step forecasting precision analysis

步数	数据编号	实测值 EGT _{M_C}	预测值 EGT _{M_Y}	绝对误差	相对误差 1/ %	相对误差 2/ %
		/	/	EGT _{M_C} - EGT _{M_Y}	EGT _{M_C} - EGT _{M_Y} / EGT _{M_C}	EGT _{M_C} - EGT _{M_Y} / EGT _{M_Y} 变化范围
1	106	67.570	67.680	0.170	0.2524	3.398
1	107	67.290	67.463	0.173	0.2577	3.458
1	108	66.996	67.051	0.055	0.0826	1.104
1	109	66.759	66.774	0.015	0.0220	0.297
1	110	66.625	66.536	0.089	0.1342	1.783

表6 多步预测精度分析

Table 6 Multi-steps forecasting precision analysis

步数	数据编号	实测值 EGT _{M_C}	预测值 EGT _{M_Y}	绝对误差	相对误差 1/ %	相对误差 2/ %
		/	/	EGT _{M_C} - EGT _{M_Y}	EGT _{M_C} - EGT _{M_Y} / EGT _{M_C}	EGT _{M_C} - EGT _{M_Y} / EGT _{M_Y} 变化范围
1	106	67.570	67.680	0.170	0.2524	3.398
2	107	67.290	67.749	0.460	0.6829	9.161
3	108	66.996	67.748	0.752	1.1220	14.994
4	109	66.759	67.842	1.083	1.6227	21.597
5	110	66.625	68.012	1.387	2.0820	27.656

4 结论

(1) 针对目前航空发动机性能参数趋势分析缺乏外推能力的缺陷,提出利用结构自适应神经网络预测模型对航空发动机的历史数据建立数学模型,以实现发动机性能的趋势预测。

(2) 用实际的航空发动机性能参数数据,进行了预测分析,充分表明了本文方法的正确有效性。尽管本文仅对发动机 EGT 性能参数进行了预测分析,但是按同样思路,不难对其他参数,如高、低压转子转速和燃油流量等进行预测。另外,本文尽管仅仅讨论了民航发动机的性能趋势预测,对于军用航空发动机,其理论仍然适用,限于篇幅,本文不再详述。

(3) 本文的研究工作对于提前预知航空发动机未来时刻的性能数据,有效地实现发动机状态监测和视情维修具有重要意义。

致谢

感谢中国东方航空股份有限公司、西北航空公司和东航江苏公司为本论文提供的民航发动机性能参数数据。

参考文献

- [1] 陈志英,李其汉. 监视参数预测和故障识别法[J]. 航空动力学报, 1994, 9(4): 419-421.
Chen Z Y, Li Q H. Monitoring parameters forecasting and faults recognition[J]. Journal of Aerospace Power, 1994, 9(4): 419-421. (in Chinese)
- [2] Weigend A S, Huberman B A, Rumelhart D E. Predicting the future: a connectionist approach[J]. International Jour-

nal of Neural System, 1990, (1): 193-209.

- [3] Xu K, Xie M, Tang L C, et al. Application of neural networks in forecasting engine systems reliability[J]. Applied Soft Computing, 2003(2): 255-268.
- [4] 刘豹,胡代平. 神经网络在预测中的一些应用研究[J]. 系统工程学报, 1999, 14(4): 338-344.
Liu B, Hu D P. Some application research of neural networks in forecasting[J]. Journal of System Engineering, 1999, 14(4): 338-344. (in Chinese)
- [5] 杨虞微,陈果. 光谱油样分析监测技术中的神经网络预测法[J]. 光谱学与光谱分析, 2005, 25(8): 1339-1343.
Yang Y W, Chen G. Artificial neural network forecasting method in monitoring technique by spectrometric oil analysis[J]. Spectroscopy and Spectral Analysis, 2005, 25(8): 1339-1343. (in Chinese)
- [6] 陈果. 神经网络模型的预测精度影响因素分析及其优化[J]. 模式识别与人工智能. 2005, 18(5): 528-534.
Chen G. Analysis of influence factors for forecasting precision of artificial neural network model and its optimizing[J]. Pattern Recognition and Artificial Intelligence, 2005, 18(5): 528-534. (in Chinese)
- [7] 徐章遂,房立清,王希武,等. 故障信息诊断原理及应用[M]. 北京:国防工业出版社, 2000: 185-281.
Xu Z S, Fang L Q, Wang X W, et al. Fault information diagnosis principle and application[M]. Beijing: Press of National Defence Industry, 2000: 185-281. (in Chinese)
- [8] Cholewo T, Zurada J M. Sequential network construction for time series prediction[C]. Proceedings of the IEEE International Joint Conference on Neural Networks. Houston, USA: [s. n.], 1997: 2034-2039.

作者简介:



陈果(1972-)男,副教授,博士,主要研究方向:航空发动机智能诊断与专家系统、转子动力学。

E-mail: cgzyx@263.net

Tel: 025-84891850

(责任编辑:刘振国)