

文章编号: 1000-8055(2003) 05-0676-05

基于遗传算法和 BP 网络的航空发动机 拆换期望值预测

宋金光, 许春生
(中国民用航空学院, 天津 300300)

摘要: 通过使用真实样本实验的方法, 在 BP 神经网络、GA 遗传算法与改进的 GA-BP 复合算法中, 找出能迅速精确地预测航空发动机拆换期望值的最佳方法。试验结果证明, GA-BP 复合算法在用遗传算法对神经网络的权值进行大致搜索以后, 再用神经网络方法进行训练, 能很好地模拟发动机拆换期望值, 并用实例证明该算法是有效的。

关键词: 航空、航天推进系统; BP 网络; 遗传算法; 航空发动机; GA-BP 算法
中图分类号: V 263. 5 **文献标识码:** A

The Estimation of Aeroengine Expectant Cycle Based on Genetic Algorithm and BP Neural Network

SONG Jin-guang, XU Chun-sheng

(Civil Aviation University of China, Tianjin 300300, China)

Abstract: The algorithm described in the paper is one of the important instruments for the establishment of aero-engine expectant cycle to supervise aero-engine scientifically and effectively. By means of experimental method of using real specimens, the optimal algorithm which can estimate aero-engine expectant cycle quickly and precisely among BP neural network, GA (genetic algorithm) and compound GA-BP can be found. It shows that GA-BP algorithm can simulate expectant cycle excellently. First it searches weights of neural network grossly using genetic algorithm, then is trained by using BP network. It has been proved to be effective by real instances. Two softwares have been made.

Key words: aerospace propulsion system; BP network; genetic algorithm; aero-engine; GA-BP algorithm

1 引言

1999年由北方航空公司提出, 由中国民用航空学院负责完成的《基于神经网络方法的航空发动机拆换期望的制定》课题成果^[1]在北方航空公司得到了应用。但是经过一年多的实践检验, 某些航空发动机拆换预测值与实际拆换值还有差别。

其原因是由于:

(1) 在原课题中用神经网络方法输入的影响发动机拆换值的参数仅仅是发动机在大修后测得的试车数据。而实际影响航空发动机拆换值的因素不只是这些大修后数据, 还有发动机实际应用中涉及到的一些其它实时因素, 比如 EGT (Exhaust Gas Temperature) 的实时变化, 低压转

子转速、高压转子转速的变化情况,滑油耗量,以及滑油含量中一些金属含量的实时变化情况,这些都直接影响了发动机的拆换值。

(2) 用于训练的样本数量不够,代表性不足。

(3) 算法上还存在缺陷,神经网络方法只是对样本一个一个地进行训练,只是局部寻优,而没有在训练之前对全部的权值进行全局的寻优,导致收敛速度慢。

由于这些因素造成了预测拆换值与实际拆换值的差异。因此,为了更加精确预测航空发动机的拆换值,有必要提出一种新型的预测航空发动机拆换值的方法,尽可能地把影响发动机拆换值的因素都考虑进去,收集更多的样本,使其具有代表性,为发动机机队管理提供实时的依据,为航空发动机科学管理提供可靠的保障。

本文由北方航空公司提供25组训练样本,其中前22组样本作为训练用,后三组样本作为检验用。分别用BP网络、GA(遗传算法)和GA-BP三种方法进行实验,以确定最佳算法。

2 BP 网络实验

2.1 网络结构及算法

网络结构为一个输入层、一个隐层和一个输出层。输入参数包括影响发动机拆换期望值的25个参数,它们是 $TSFC$ (耗油率)、 $N1$ (发动机低压转子转速)、 $N2$ (发动机高压转子转速)、变化 $N1$ 、变化 $N2$ 、 EGT (排气温度)、 EPR (发动机压比)、 $PS4/PT2$ (高压压气机出口静压与压气机进口总压之比)、 $PS3/PT2$ (低压压气机出口静压与压气机进口总压之比)、 EGT 裕度、变化 EGT 、振动、九种滑油金属含量、 AD 报告、 SB 服务通告;隐层数根据实验确定;输出参数是拆换期望值。

2.2 实验结果

通过选取不同的网络参数来最后确定最佳参数。

2.2.1 样本误差^[2]

单个样本误差:

$$E = \frac{1}{2} (d - o)^2 = \frac{1}{2} \sum_{k=1}^l (d_k - o_k)^2$$

总误差:

$$E_{\text{总}} = \frac{1}{2p} \sum_p \sum_{k=1}^l (d_k - o_k)^2$$

其中: d 为期望输出向量, o 为输出层输出向量, p 为训练样本。其它参数值固定,改变误差精度值,

以确定最佳误差精度值。第一种 $E = 1 * 10^{-4}$, $E_{\text{总}} = 1 * 10^{-4}$, 训练次数 = 277; 第二种 $E = 1 * 10^{-7}$, $E_{\text{总}} = 1 * 10^{-7}$, 训练次数 = 3391。拆换值拟合结果如图1。




图1 拆换拟合值随样本误差不同而变化
Fig. 1 Simulated expectant cycle change with samples error

从图1看出,第二种拆换值拟合精度好。

2.2.2 步长

在公式 $\Delta W(t) = \eta \delta X + \alpha \Delta W(t-1)$ 中, η 的选取对 ΔW (权值的改变) 起到至关重要的作用。其它参数值固定,改变步长值,以上一步得到的最佳误差精度为标准,看步长取多大时收敛的最快,以确定最佳步长值。 $\eta = 0.9$, 训练次数 = 3391; $\eta = 0.8$, 训练次数 = 956; $\eta = 0.7$, 训练次数 = 1174; $\eta = 0.6$, 训练次数 = 1452; $\eta = 0.5$, 训练次数 = 1153; $\eta = 0.4$, 训练次数 = 2146。从以上数据可以看出, $\eta = 0.8$ 时收敛的最快,是最佳步长值。

2.2.3 动量系数

动量项反映了以前积累的调整经验,对于 t 时刻的调整起阻尼作用。 $\alpha = 0.9$, 训练次数 = 648; $\alpha = 0.8$, 训练次数 = 1076; $\alpha = 0.7$, 训练次数 = 1353; $\alpha = 0.6$, 训练次数 = 1080; $\alpha = 0.5$, 训练次数 = 1549; $\alpha = 0.4$, 训练次数 = 1429。从以上数据可以看出, $\alpha = 0.9$ 时收敛的最快,是最佳动量系数值。

2.2.4 隐层节点数

隐层节点数的多少也关系到网络收敛的程度,这里也通过实验法确定最佳隐层节点数的值。隐层节点数 = 26, 训练次数 = 1649; 隐层节点数 = 24, 训练次数 = 648; 隐层节点数 = 22, 训练次数 = 961; 隐层节点数 = 20, 训练次数 = 1058。隐层节点数 = 24 时收敛的最快。

由此得到 BP 网络最佳参数值: $E =$

0. 000001; $E_{总}$ = 0. 0000001; η = 0. 8; α = 0. 9; 隐层 节点数= 24。

表1 世代数、种群数、变异概率改变的实验结果

Table 1 Experiment result change with maxgeneration, popsize and mutation probability

平均误差/ 世代数	1017/ 1	818/ 3	767/ 5	781/ 10	850/ 50
平均误差/ 种群数	959/ 10	748/ 20	781/ 50	768/ 100	1065/ 200
平均误差/ 变异概率	748/ 0. 01	791/ 0. 05	620/ 0. 2	965/ 0. 5	1278/ 1

表2 交叉概率改变的实验结果

Table 2 Experiment result change with crossover probability

	$P_c= 1$	$P_c= 0. 9$	$P_c= 0. 8$	$P_c= 0. 7$	$P_c= 0. 6$	$P_c= 0. 5$	$P_c= 0. 4$	$P_c= 0. 3$
$P_m= 0. 01$	706	778	966	1038	801	841	569	927
$P_m= 0. 2$	841	1015	1145	628	713	1015	1129	1288

3 遗传算法实验

3. 1 遗传操作及算法参数

遗传操作是模拟生物基因遗传的操作^[3]。遗传操作包括三个基本操作: 选择(Selection)、交叉(Crossover)和变异(Mutation)。遗传算法的控制参数主要包括遗传世代数 maxgeneration、种群规模 popsize、交叉概率 P_c 和变异概率 P_m 。

3. 2 遗传算法控制参数对预测值的影响及分析

控制参数选取的不同常常会对算法的性能产生较大的影响。

3. 2. 1 遗传世代数、种群数、变异概率对结果的影响

固定其它几个参数, 分别只改变遗传世代数、种群数、变异概率, 以样本算术平均误差作为评判标准。试验结果见表1。

从表1可以看出, 世代数越多误差反而越来越大, 而世代数太少, 显然得不到最佳结果。因此取世代数为5比较理想; 种群数过大不仅费时, 而且对平均误差结果的减小起不到任何作用, 反而有增大的趋势, 因此种群数选为20足以; 当变异概率增大, 实际上增加了父代解中更多的个体在下一代中对其邻域进行搜索的机会, 使得遗传算法能快速搜索到最优解。但是, 当变异概率太大时, 计算量加大, 遗传算法运行时间加长, 而平均误差也变大。因此, 变异概率并不是越大越好, 当变异概率为0. 2或0. 01时, 效果较为理想, 到底取那一个, 留待下面试验继续探讨。

3. 2. 2 交叉概率对结果的影响

固定其它几个参数不变, 变异概率分别为0. 01和0. 2时, 改变交叉概率的值, 分别取为1. 0, 0. 9, 0. 8, 0. 7, 0. 6, 0. 5, 0. 4进行计算, 平均误差结果见表2。

从表2可以看出, 交叉概率对实验结果影响很大。因为本文采用的是实数编码方案, 交叉操作采用的是随机交叉两个权值, 产生后代, 从实验结果得出, 变异概率等于0. 01以及交叉概率等于0. 4时, 误差最小。然而我们应该看到, 即使是最后选定的参数, 其平均误差仍然很大, 说明遗传算法在本实例中, 对神经网络的权值调整没有达到十分精确的地步, 只能对神经网络权值起到大致的搜索。因此, 遗传算法必须同神经网络结合起来, 先用遗传算法对神经网络的初始权值做一个大致的搜索, 然后再用神经网络的误差反传算法, 最后得到精确的权值。

4 GA-BP 算法实验

4. 1 GA-BP 算法思想

由于BP网络的初始权值是随机给定的^[4], 因而每次训练的次数和最终的权值会略有不同, 这就是说, 网络的寻优不具有唯一性, 会出现局部极小; 另一方面, 初始权值给定的“盲目”性也导致了训练次数的较多, 收敛速度慢到有时让人难以忍受。

有鉴于此, 如果在BP网络算法之前, 能用一种有效的方法大致搜索出一定的权值范围, 此时

的权值作为 BP 算法的初始权值,则可以解决 BP 算法的易陷入局部极小、收敛速度慢和引起震荡效应等缺点。本文将神经网络与遗传算法结合起来,形成一种杂交算法 GA-BP 算法,达到优化网络的目的,训练时先由遗传算法进行全局寻优,将搜索范围缩小后,再利用 BP 网络误差反传算法来训练,得到精确的权值最后利用网络的泛化能力对输入的样本进行预测。

4.2 GA-BP 算法实验

通过选取不同的网络参数,已达到给定精度时的网络误差反传次数(括号内为单独使用 BP 法训练次数),来最后确定最佳参数。

4.2.1 样本误差

第一种 $E=1 \times 10^{-4}$, $E_{总}=1 \times 10^{-4}$, 训练次数=23(277); $E=1 \times 10^{-7}$, $E_{总}=1 \times 10^{-7}$, 训练次数=562(3391)。第二种拆换值拟合精度好。

4.2.2 步 长

$\eta=0.9$, 训练次数=520(3991); $\eta=0.8$, 训练次数=526(956); $\eta=0.7$, 训练次数=528(1174); $\eta=0.6$, 训练次数=525(1452); $\eta=0.5$ 训练次数=527(1153); $\eta=0.4$, 训练次数=739(2146)。从以上数据可以看出, $\eta=0.9$ 时收敛的最快, 是最佳步长值。

4.2.3 动量系数

$\alpha=0.9$ 训练次数=520(648); $\alpha=0.8$, 训练次数=966(1076); $\alpha=0.7$, 训练次数=847(1353); $\alpha=0.6$, 训练次数=962(1080); $\alpha=0.5$, 训练次数=940(1549); $\alpha=0.4$, 训练次数=1347(1429)。从以上数据可以看出, $\alpha=0.9$ 时收敛的最快, 是最佳动量系数值。

4.2.4 隐层节点数

隐层节点数=24, 训练次数=520(648); 隐层节点数=22, 训练次数=957(961); 隐层节点数=20, 训练次数=842(1058)。

由此得到网络最佳参数值: $E=0.00000001$, $E_{总}=0.0000001$, $\eta=0.9$, $\alpha=0.9$, 输入层节点数=24, 隐层节点数=22, 输出层节点数=1。

5 三种算法的比较

本文利用 BP 算法、GA 法和 GA-BP 复合算法三种算法对航空发动机拆换期望值做了拟合实验。图2是三种算法拟合值与真实值比较图。

从图2可以看到, 单独使用 GA 法, 拟合结果

与真实值相差较大, 而 BP 法与改进的 GA-BP 复合算法都能很好的拟合真实值, 在拟合精度上两种算法都是有效的。然而在拟合速度上却有着很大的差别。在 GA-BP 复合算法实验中, 对每一个




图2 三种算法拟合值比较
Fig. 2 Comparison of three algorithms simulated data

网络参数的实验, 都给出了两种算法的误差反传次数对比。可以看出, 在 GA-BP 复合算法中, 经过 GA 法对初始权值进行全局寻优后, 再利用 BP 网络的误差反传, 可以使达到精度时的收敛速度大大缩短, 从而弥补了 BP 法由于初始权值随意性造成的收敛速度慢、易陷入局部极值的严重缺陷。

6 实例验证及软件设计

用 GA-BP 复合算法对25组样本中后三组样本进行实例验证, 验证结果如表3。

表3 实例验证结果 Table 3 Validated result with real data			
真实值	6700	7997	9404
测试值	6677	8117	9436

从表3可以看出, 最大误差度 $(8117-7997)/8117=0.014$, 达到了令人满意的程度。

为了实际使用的方便, 设计两套程序: 网络训练软件(图3), 换发期望预测软件(图4)。

此软件通过北方航空公司实际参数检验效果良好, 能很好地预测拆换时间, 使用方便可靠, 为航空公司制订发动机预计下发时间排队报告, 科学高效地管理发动机提供了有利的依据。

7 结 论

(1) 在航空发动机拆换期望值预测的实例中, 我们得出, 对于这种输入与输出存在非线性关



图3 网络训练软件

Fig.3 Software of network training



图4 换发期望预测软件

Fig.4 Software of expectant cycle

系的模型,通过设计合理的神经网络对系统输入输出样本对进行自我学习,能够以任意精度逼近复杂的非线性映射,但其缺点也是显而易见,就是

训练时间长,收敛速度慢。

(2) 遗传算法单独使用在本例中,还达不到给定的精度,只能对神经网络的权值进行大致的搜索,但对优化神经网络的权值起到了一定的作用。

(3) 将 GA 与 BP 网络算法相结合,进行神经网络学习是解决非线性复杂问题的行之有效的方法,该算法不仅具有全局搜索能力并提高了局部搜索能力,从而增强了在搜索过程中自动获取和积累搜索空间的知识及自适应地控制搜索过程的能力,使解的性质得以极大的改善。GA-BP 算法在用遗传算法对神经网络的权值进行大致搜索以后,再用神经网络方法进行训练,虽然对精度提高不大,但是大大减小了网络的训练时间,训练次数大大缩短。

(4) 通过实例证明,GA-BP 算法在航空发动机拆换期望值的预测中得到了成功的应用,能够对发动机拆换期望值做出真实的预测。

参考文献:

[1] 李书明,许春生,李光辉.基于神经网络方法的航空发动机拆换期望的制定[J].振动工程学报,2000,10:362-365.

[2] 韩力群.人工神经网络理论、设计及应用[M].北京:化学工业出版社,2002.

[3] 王小平,曹立明.遗传算法-理论、应用与软件实现[M].西安:西安交通大学出版社,2002.

[4] 王志亮,李筱艳,殷宗泽.遗传算法和改进的BP网络杂交法在岩土工程中的应用[J].地下空间,2001,21(3):178-182.