

文章编号: 1000-8055(2007)10-1748-06

自适应遗传神经网络算法在推力估计器设计中的应用

姚彦龙, 孙健国

(南京航空航天大学 能源与动力学院, 南京 210016)

摘 要: 为了在全包线内能够准确方便估计出航空发动机推力, 提出了一种自适应遗传神经网络算法: 将遗传算法和神经网络技术相结合充分发挥遗传算法和神经网络各自的全局收敛性和局部搜索快速性的优点, 其中通过自适应概率遗传操作及局部寻优算子直接优化出神经网络拓扑结构及权值(包括阈值), 克服了神经网络隐层节点需凭经验尝试的缺点和神经网络对初始权值(包括阈值)敏感的缺点, 再应用神经网络对上述优化的权值(包括阈值)进行“精调”, 最后设计出全包线推力估计器。经验证, 此推力估计器具有较高估计精度和良好泛化能力。

关 键 词: 航空、航天推进系统; 航空发动机; 推力估计器; 自适应; 遗传算法; 神经网络

中图分类号: V233 7

文献标识码: A

Application of adaptive genetic neural network algorithm in design of thrust estimator

YAO Yanlong, SUN Jianguo

(College of Energy and Power Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: An adaptive genetic neural network algorithm (AGNNA) was proposed for estimating aeroengine thrust accurately and easily in a full flight envelope. It is based on the combination of genetic algorithm and neural network technology which could make full use of the global convergence property and rapid local searching capability separately. The topology structure and weights (including threshold) of neural network could be directly optimized through adaptive probability genetic operator and local optimizing operator, thereby overcoming the disadvantage of hidden layer nodes of neural network requiring empirical effort and the sensitivity of neural network to its initial weights (including threshold). Then, neural network was applied to “fine tune” the above specified weights (including threshold). Finally, the thrust estimator for the full flight envelope was designed with the algorithm. The experimental results show that the thrust estimator has good estimation accuracy and generalization ability.

Key words: aerospace propulsion system; aeroengine; thrust estimator; adaptive; genetic algorithm; neural network

收稿日期: 2006-10-12; 修订日期: 2006-12-19

基金项目: 国家自然科学基金资助项目(50576033); 航空科学基金资助项目(04C52019)

作者简介: 姚彦龙(1981-), 男, 黑龙江龙江人, 硕士生, 主要研究航空发动机控制与仿真, E-mail: yaoyanlongyyl@nuaa.edu.cn

航空发动机最主要的作用是为飞行器提供推力, 所以如何实现推力的有效控制是最重要的问题. 但是目前发动机推力控制基本上是基于传感器的间接推力控制(如图 1), 通过转速、压比等参数来间接控制推力, 不可能准确控制推力值, 为保护发动机, 在发动机设计时通常要保留很大的裕度, 且控制性能不高. 而进行直接推力控制(如图 2)可以准确控制推力值, 降低设计裕度, 提高发动机性能^[1-3]. 随着计算机技术和非线性估计理论的发展, 准确地估计推力得到实现, 才能使直接推力控制的实现成为可能.




图 1 基于传感器控制的结构图

Fig. 1 Block diagram based on sensor control




图 2 直接推力控制结构图

Fig. 2 Block diagram based on direct thrust control

近些年, 神经网络和遗传算法^[4-5]作为在非线性控制领域的智能算法引起业内广泛关注. 神经网络具有非线性映射特性和学习能力, 为解决复杂的非线性、不确定系统的辨识和估计问题开辟了一条有效的途径. 但是神经网络在具备诸多优点的同时也存在一些先天不足, 比如, 神经网络对初始值敏感; 隐层节点数不易确定, 要根据经验多

次尝试; 学习速度慢, 训练时间长; 易陷于局部极小等等. 遗传算法是一种启发式算法, 它不需求导或其他辅助知识, 而只需要影响搜索方向的适应度函数. 遗传算法强调概率转换规则, 而不是确定的转换规则. 同时遗传算法具有极强的鲁棒性, 可以并行计算、全局寻优. 但是遗传算法的缺陷就是局部寻优效果不够显著. 为了克服要根据经验, 多次才能大致选出较好的神经网络拓扑结构和遗传算法局部寻优效果不佳的缺陷, 本文提出自适应遗传神经网络算法(AGNNA), 该算法具有以下几方面优点:

(1) 采用了遗传算法直接优化出神经网络的拓扑结构和权值(包括阈值), 有效克服了神经网络难以确定隐含层节点个数, 需凭借经验反复试验的缺点;

(2) 提出局部寻优算子, 进一步优化权值(包括阈值), 克服了遗传算法的局部优化效果不佳和神经网络对初始值较敏感的缺点;

(3) 采用随着进化代数的变化, 自适应减小遗传操作概率的方法, 使处于进化后期的群体中个体不发生较大的变化, 以免破坏了个体的优良性能结构;

(4) 采用遗传算法(GA)和神经网络(NN)的相结合技术, GA 对于全局搜索有较强的鲁棒性和较高的效率, 但局部搜索效率不高, 不适合权值(包括阈值)的“精调”, 故又用 NN 对权值(包括阈值)“精调”, 以提高神经网络的映射精度, 从而充分发挥 GA 和 NN 各自的全局收敛性和局部搜索的快速性.

1 自适应遗传神经网络算法 (AGNNA) 设计

1.1 假设条件

对于神经网络的拓扑结构和权值同时进行优化的 AGNNA 算法, 首先给出几点假设:

假设 1: 神经网络是严格分层全连接的, 即仅在两个相邻层的节点间才有连接;

假设 2: 神经网络采用三层网络结构(*r-h-o*), 只对隐层节点数进行优化, 而输入层节点数和输出层节点数由设计者根据具体问题确定, 其中 r , h 和 o 分别为输入节点数、隐层节点数和输出节点数;

假设 3: 给定训练集(样本数为 p 个), 其输入样本为 $\{X^1, X^2, \dots, X^p\}$, 目标输出向量为 $\{T^1, T^2,$

..., T^p }. 如果输出向量 $T^j (j \in \{1, 2, \dots, Y^p\})$ 是 o 维的, 则根据实际输出向量 $\{Y^1, Y^2, \dots, Y^p\}$ 和目标向量 $\{T^1, T^2, \dots, T^p\}$ 之间的误差定义网络的性能误差函数如下:

$$E(\text{net}) = \sqrt{\sum_{j=1}^p \sum_{i=1}^o (y_i^j - t_i^j)^2} \quad (1)$$

式中 y_i^j, t_i^j 分别表示向量 Y^j 和 T^j 的第 i 个分量。

1.2 编码方式

采用二进制和十进制混合编码方式进行等长染色体编码。即拓扑结构采取二进制进行编码, 二进制 1 代表节点存在并连入网络, 0 代表节点不存在并未连入网络, 而网络权值采取十进制进行编码。网络的结构码串和权值码串构成一个完整的染色体。网络隐层最大节点数由设计者设定, 隐层最终节点数在此范围内寻优确定。

1.3 种群初始化

随机生成初代个体, 每个个体中结构码串初始化为随机二进制数, 权值码串初始化为某一范围内的随机浮点数, 种群规模设置为某一整数。

1.4 选择策略

采用轮盘赌选择策略。在此设 $E(\text{net}_i, t)$ 是第 t 代进化群体中第 i 个个体所具有的网络的性能误差函数, 故适应度函数可定义为

$$f(\text{net}, t) = \frac{1}{0.000001 + E(\text{net}, t)} \quad (2)$$

由轮盘赌选择策略可知, 网络 net_i 被选择到下一代的概率为

$$p_s = \frac{f(\text{net}_i, t)}{\sum_{j=1}^n f(\text{net}_j, t)} \quad (3)$$

式中 n 表示群体的规模。

为了保证每一代中的优良个体不被破坏, 采用最优个体保存方法, 使其直接被复制到下一代群体中。

1.5 交叉操作

采用均匀交叉策略。从选择出的新种群中依概率选择两个个体作为父代, 根据随机二进制掩码进行交叉操作, 交叉方式说明: 掩码为 1 时, 将父代个体一给予子代个体一, 将父代个体二给予子代个体二; 掩码为 0 时, 将父代个体二给予子代个体一, 将父代个体一给予子代个体二。

1.6 变异操作

从交叉操作生成的种群中依概率选择若干个

个体分别作为父代变异个体, 再针对每个父代变异个体采用结构码串和权值码串分别变异的策略生成子代变异个体, 之后再用于子代变异个体代替父代变异个体, 形成变异后的种群。其中结构码串部分按通常规则依概率取反变异, 权值码串部分变异时, 依概率选择若干个变异位置, 将相应位置重新在初始空间内随机赋新值即可。

1.7 局部寻优算子

针对遗传算法的局部优化效果不够显著和神经网络对初始值较敏感的特点, 本文提出的自适应遗传神经网络算法中, 在遗传优化结束后, 再针对最优个体中的权值部分进行局部优化, 以增强遗传算法的局部寻优能力和降低神经网络对初始值的敏感性。此操作命名为局部寻优算子, 其具体操作步骤

1) 运用(2)式计算出最优个体的适应度值, 记为 $Fitness_A$;

2) 对 1) 中最优个体权值部分码串进行如下变异操作

$$w' = w \left(1 - r \left(\frac{g_l}{g_{l_{\max}}} \right)^T \right) \quad (4)$$

其中 w 表示依概率选择的权值, w' 表示相应的变异后的权值, r 表示 $(-1, 1)$ 范围内的随机数, $g_{l_{\max}}$ 表示局部寻优算子进化总代数, g_l 表示当前局部寻优算子进化到的代数, T 表示需设定常数, 经调试取 $T = 2$;

3) 运用(2)式计算 2) 中权值变异后个体的适应度, 记为 $Fitness_B$;

4) 如果 $Fitness_B$ 大于 $Fitness_A$, 则用变异后的权值码串取代此次变异前的权值码串;

5) 检验退出局部寻优算子准则是否满足? 如果满足, 则转到步骤 6), 否则转到步骤 2);

6) 退出局部寻优算子。

此算子的实质是对最优个体附近的一个小空间进行局部再搜索, 以达到局部深度寻优, 进一步提高适应度。

1.8 自适应操作

交叉概率(p_c)和变异概率(p_m)对遗传算法的性能有较大影响, 为了加强遗传算法在运行后期的局部搜索能力, 提高学习精度, 本文采取 p_c 和 p_m 随进化代数的变化而变化的方式进行自适应操作, 具体变化规律如下:

$$p_c = \begin{cases} p_{c0} \\ p_{c0} - (p_{c0} - p_{c1}) \left(\frac{g}{g_{\max}} \right)^{T_1} \end{cases} \quad (5)$$

$$p^m = \begin{cases} p_{m0} \\ p_{m0} + (p_{m1} - p_{m0}) \left(\frac{g}{g_{max}} \right)^{T_2} \end{cases} \quad (6)$$

上式中 p_{c0} 表示初代交叉概率, p_{c1} 表示末代交叉概率, p_{m0} 表示初代变异概率, p_{m1} 表示末代变异概率, g_{max} 表示进化总代数, g 表示当前进化到的代数, T_1, T_2 均表示需设定常数, 经调试取 $T_1 = T_2 = 4$.

1.9 神经网络“精调”处理

虽然遗传算法对于全局搜索有较强的鲁棒性和较高的效率, 但不适合候选解的“精调”, 因此采用神经网络对候选解(权值)进行“精调”处理, 从而充分发挥遗传算法和神经网络各自的全局收敛性和局部搜索的快速性.

2 基于 AGNNA 的全包线推力估计器设计

2.1 训练集数据采集与处理

以某型混合排气涡扇发动机模型为对象, 在标准大气条件下, 其高度(H)、马赫数(Ma)、燃油量(W_b)和尾喷口面积(A_8)等唯一确定航空发动机状态, 也就同时确定了发动机的推力(F). 本文在全包线内选择 H, Ma, W_b 和 A_8 等四个变量作为输入数据和一个 F 变量作为教师信号. 从模型中在全包线内选取 88 个点, 并采集每个点的不同

油门杆位置的稳态值总共 880 组数据作为训练集. 为了检验神经网络的泛化能力, 在包线内另外选择 70 个点采集 700 组数据作为测试集. 为避免对神经网络估计精度的影响和网络学习失衡, 首先对采集的数据进行归一化变换^[6].

2.2 AGNNA 算法参数设置、计算结果及估计精度验证

AGNNA 算法参数设置如表 1 所示, 其中除了输入、输出节点数外, 其余参数由经验及调试决定. AGANN 算法流程如图 3 所示, 通过 AGNNA 计算优化出 13 个隐层节点, 得到适应度变化情况如图 4 所示. 图 5 表示局部寻优算子寻优时适应度变化情况, 可见此局部寻优算子不但可以有效提高适应度, 而且可以克服神经网络对初始权值敏感的缺点, 可以减小神经网络陷入局部极小值的概率, 缩短了神经网络的学习时间.

表 1 AGNNA 参数设置
Table 1 Setting of AGNNA parameters

参数	数值	参数	数值
网络输入节点数	4	网络隐层最大节点数	30
网络输出节点数	1	群体规模	50
遗传最大迭代代数	50	权值初始化空间	- 5~ 5
初代交叉概率	0.95	初代变异概率	0.001
末代交叉概率	0.80	末代变异概率	0.01
局部寻优算子及神经网络“精调”参数设置如下			
最大寻优代数	100	初代变异概率	0.05
末代变异概率	0.80	“精调”学习次数	1 000




图 3 带局部优化算子的 AGNNA 算法流程图

Fig. 3 Flow chart of AGNNA with local optimization operator




图 4 遗传算法优化时适应度变化情况

Fig. 4 Fitness change when run genetic algorithm




图 5 局部优化时适应度变化情况

Fig. 5 Fitness change when run local optimization operator

通过 AGNNA 算法优化得到神经网络, 构成了推力估计器, 图 6 为训练集用该推力估计器的推力估计结果. 本文用测试集数据对网络的泛化能力进行了检验, 图 7 为测试集推力估计结果. 并将推力估计结果统计信息列于表 2 中, 分别为估计值的相对误差最大值(MAX)、中间值(MEDIAN)、平均值(MEAN)、标准偏差(STD) 和方差

表 2 推力估计结果信息统计

Table 2 Information statistics of thrust estimation results

	MAX	MEDIAN	MEAN	STD	COV
训练集	$-2.345\ 1\times 10^{-3}$	$+7.931\ 2\times 10^{-7}$	$+3.842\ 1\times 10^{-6}$	$+6.796\ 6\times 10^{-4}$	$+4.619\ 4\times 10^{-7}$
测试集	$-2.810\ 8\times 10^{-3}$	$-4.609\ 0\times 10^{-5}$	$-8.298\ 2\times 10^{-5}$	$+7.871\ 9\times 10^{-4}$	$+6.196\ 7\times 10^{-7}$

3 结束语

本文提出了一种自适应遗传神经网络算法 (AGNNA), 此算法综合考虑了遗传算法和神经网络的优点, 并运用 AGNNA 对发动机推力估计器进行设计和验证, 仿真结果表明此方法设计出

(COV). 从表 2 可以看出估计值的相对误差各种统计指标均在 10^{-3} 量级以下, 具有较高的映射精度和泛化能力, 满足精度要求.





图 6 训练集推力估计结果

Fig. 6 Thrust estimation result of training set





图 7 测试集推力估计结果

Fig. 7 Thrust estimation result of testing set

的推力估计器具有较高的估计精度, 训练集估计值的相对误差最大值为 , 并在包线内具有良好的泛化能力, 测试集估计值的相对误差最大值为 $-2.810\ 8\times 10^{-3}$. 相信 AGNNA 在其他类似优化计算中具有良好应用前景.

参考文献:

- [1] SUN Jianguo, Vasilyev V, Hyasov B, et al. Advanced multivariable control systems of aeroengines[M]. Beijing: Beijing University of Aeronautics and Astronautics Press, 2005, 10: 160-169.
- [2] Maggiore M, Ordonez R, Passino K, et al. Estimator design in jet engine applications [C] // Proceedings of the 38th Conference on Decision and Control, Phoenix, Arizona USA: [s. n] 1999.
- [3] 陈恬, 孙健国. 基于相关性分析和神经网络的直接推力控制[J]. 南京航空航天大学学报, 2005, 37(2): 183-187.
CHEN Tian, SUN Jianguo. Direct control of aeroengine thrust based on correlation analysis and neural networks [J]. Journal of Nanjing Univ. of Aero. and Astro, 2005, 37(2): 183-187.
- [4] 张志涌. 精通 MATLAB 6.5 版[M]. 北京: 北京航空航天大学出版社, 2003.
ZHANG Zhiyong. Mastering MATLAB 6.5 [M]. Beijing: Beijing Univ. of Aero. and Astro Press, 2003.
- [5] 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.
WANG Xiaoping, CAO Liming. Genetic algorithm theory, application and software realization [M]. Xi'an: Xi'an Jiaotong University Press, 2001.
- [6] 张平. 基于机电 BIT 的发动智能容错技术研究[D]. 南京: 南京航空航天大学, 2005. 3: 15-21
ZHANG Ping. Aeroengine intelligent fault tolerance technology based on mechanism and electricity BIT [D]. Nanjing: Nanjing Univ. of Aero. and Astro, 2005, 3: 15-2.