

文章编号:1000-8055(2012)07-1464-08

连分式扩充的粒子群神经网络压气机特性重构方法

王星博, 李本威, 王永华, 杨欣毅

(海军航空工程学院 飞行器工程系, 山东 烟台 264001)

摘 要: 对航空发动机压气机原始二维等转速线的数据点进行连分式扩充, 通过两次网络训练, 增加转速特性数据, 在三维空间中进行 BP(back propagation)网络模型重构. 根据压气机特性数据空间分布的特点, 引入压力比函数, 调整计算区域, 定义网络的输入输出数据, 利用试探法确定隐含层维数. 采用基于趋利避害原则的粒子群算法对网络的初始权值和阈值进行优化, 建立了压气机压比和效率特性的整体代理模型. 最后以某型发动机的低压压气机为例进行了压气机特性模型的重构. 通过模型的校核与验证表明: 采用这种方法建立的模型精度较高, 优于普遍采用的传统二维插值方法和普通 BP 神经网络模型. 最终建立的重构模型对于采用选配法、坐标法和部件法等以压气机通用特性曲线为基础的发动机模型的求解, 可提高计算精度和迭代速度, 具有一定的工程应用价值.

关 键 词: 航空发动机; 压气机特性; 连分式; 粒子群优化; 趋利避害; BP 神经网络; 重构模型

中图分类号: V231.3

文献标志码: A

Neural network reconstruction method of compressor characteristics with continued fraction expanded data

WANG Xing-bo, LI Ben-wei, WANG Yong-hua, YANG Xin-yi

(Department of Aircraft Engineering,

Naval Aeronautical and Astronautical University, Yantai Shandong 264001, China)

Abstract: Original two-dimensional constant rotating speed curve data points of aero-engine compressor were expanded using continued fraction interpolation. Rotating speed characteristic data through twice network training was increased and BP (back propagation) neural network model reconstruction in three-dimensional space was performed. According to the space distribution of compressor characteristics data, pressure ratio function was introduced, computational domain was adjusted, input and output data were defined and dimension of hidden layer was determined by cut-and-try method. Particle swarm optimizing algorithm based on seek advantage and avoid disadvantage principle was used to optimize the initial weight and threshold of neural network, and to establish the integral surrogate model of compressors was taken pressure ratio and efficiency characteristics. In the end, some aero-engine low pressure compressor for example to conduct the model reconstruction method. The check and verification results indicate the surrogate model established by the method proposed is more accurate than traditional two-dimensional interpolation and common BP neural network model. The reconstruction model can increase computational accuracy and

收稿日期: 2011-08-20

网络出版地址: http://www.cnki.net/kcms/detail/11.2297.V.20120801.1438.201207.1464_004.html

作者简介: 王星博(1982—), 男, 山东莱州人, 博士生, 主要研究方向为航空发动机检测与控制.

boost iteration speed when used in solving aero-engine mathematic model based on general characteristic curve of compressor such as trial and error procedure, coordinate method and components method, therefore it is of engineering value.

Key words: aero-engine; compressor characteristics; continued fraction; particle swarm optimization; seek advantage and avoid disadvantage; BP neural network; reconstruction model

根据航空发动机建模的过程和原理,对部件原始特性数据插值计算的精度很大程度上决定了发动机部件级模型的精度^[1].尤其是压气机部件特性相对复杂,流量和效率的确定都是通过二维插值计算获得,其插值计算对发动机模型精度影响很大^[2].由于航空发动机试车、试验费用昂贵,具有一定的危险性,通常在已知的压气机原始特性数据样本点较少.并且考虑原始流量特性和效率特性曲面本身的非线性特点,直接使用数据点很少的数据表进行特性二维插值计算的精度不高,随着模型求解的迭代过程,可能产生较大的累积误差^[3].

本文利用 BP(back propagation)神经网络对压气机未知转速下的特性进行模型重构,代替普遍采用的线性插值方法,同时引入多种数据处理手段和网络训练方法以提高重构模型精度.

1 连分式函数的构造和计算

提高插值计算精度的传统方法是利用多项式插值增加原始特性数据样本点.当插值节点较多时,要相应提高插值多项式的次数.但在实际应用中,过分地提高插值多项式的次数固然能使插值多项式 $P_n(x)$ 在更多的点上与被插值函数 $f(x)$ 相等,但是,在两个插值结点之间,插值多项式 $P_n(x)$ 并不一定能很好地逼近被插值函数 $f(x)$,有时差异很大^[4].在某些场合下,用多项式作为工具就不一定合适.例如,某个函数在 $x = \alpha$ 附近无界(不考虑喘振限制线时的压气机压比在高换算流量区域是无界的),或者当 $x \rightarrow \infty$ 时趋于某个定值,此时如果用多项式来逼近这个函数,其效果很不理想.但有理分式 $\frac{Ax+B}{x-\alpha}$ 却能很好地反映函数在 $x = \alpha$ 附近无界,并且也保证了当 $x \rightarrow \infty$ 时趋于某个定值 A .而且,用有理分式逼近一个函数,或者用有理分式作为工具构造算法,其效果(如精度与计算工作量)比用多项式好^[5].

利用上述有理分式进行函数逼近的方法就是连分式插值与逼近.尽管连分式是一个相对古老

的概念,但是连分式插值与逼近却是一种新的非线性数值计算工具,并已经在许多工程技术领域得到广泛应用^[6].

假设已知函数 $f(x)$ 在 $n+1$ 个互异结点处的函数值

$$y_k = f(x_k), k = 0, 1, \dots, n$$

现要构造一个 n 项截断函数连分式

$$\begin{aligned} \varphi(x) &= b_0 + \frac{x - x_0}{b_1 + \frac{x - x_1}{b_2 + \dots + \frac{x - x_{n-1}}{b_n}}} = \\ &= b_0 + \frac{x - x_0}{b_1} + \frac{x - x_1}{b_2} + \dots + \\ &\quad \frac{x - x_{n-1}}{b_n} = \frac{P_n(x)}{Q_n(x)} \end{aligned} \quad (1)$$

使满足

$$\varphi(x_k) = f(x_k), \quad k = 0, 1, \dots, n$$

为了确定连分式插值函数(1)中的各参数 $b_0, b_1, b_2, \dots, b_n$, 进行逐级分解,即令

$$\begin{aligned} \varphi_k(x) &= b_k + \frac{x - x_k}{\varphi_{k+1}(x)}, \\ k &= 0, 1, \dots, n-1 \end{aligned} \quad (2)$$

及

$$\varphi_n(x_n) = b_n \quad (3)$$

由式(2)与式(3),可以得到

$$\begin{aligned} b_j &= \varphi_j(x_j), \\ j &= 0, 1, \dots, n \end{aligned} \quad (4)$$

其中 $b_0 = \varphi_0(x_0) = f(x_0)$, 以及

$$\begin{aligned} \varphi_{k+1}(x) &= \frac{x - x_k}{\varphi_k(x) - b_k}, \\ k &= 0, 1, \dots, n-1 \end{aligned} \quad (5)$$

由式(5)可以得到计算 $b_j = \varphi_j(x_j)$ ($j = 0, 1, \dots, n$) 的递推公式如下:

$$b_j = \varphi_0(x_0) = f(x_0) \quad (6)$$

$$\begin{cases} \varphi_0(x_j) = f(x_j) \\ \varphi_{k+1}(x_j) = \frac{x_j - x_k}{\varphi_k(x_j) - b_k}, \\ b_j = \varphi_j(x_j) \end{cases} \quad k = 0, 1, \dots, j-1 \quad (7)$$

2 压气机特性曲线数据的预处理

压气机特性是指压气机的主要性能参数与压气机工作条件之间的关系. 由于压气机原始数据点在等换算转速线上的分布十分不均匀, 拟合结果的误差会大大增加, 严重影响曲面拟合的精度. 为使数据点分布尽量均匀, 同时便于压气机计算, 采用压力比函数进行数据的预处理.

设压气机某一等换算转速线上增压比最大点的增压比为 $\pi_{c\max}$, 增压比最小点的增压比为 $\pi_{c\min}$, 则这一等换算转速线上任一点增压比 π_{c0} 的压力比函数 Z 的值为

$$Z = \frac{\pi_{c0} - \pi_{c\min}}{\pi_{c\max} - \pi_{c\min}} \quad (8)$$

压气机特性曲线可以采用以下函数关系表示:

$$\begin{cases} \pi_c = f_1(n_{cor}, Z) \\ W_{acor} = f_2(n_{cor}, Z) \\ \eta_c = f_3(n_{cor}, Z) \end{cases} \quad (9)$$

以压力比函数表示的某型航空发动机低压压气机通用特性曲线如图 1 和图 2 所示.




图 1 低压压气机换算流量 W_{acor} 曲线
Fig. 1 Pressure ratio function Z to converted flow rate W_{acor} curve




图 2 低压压气机效率 η_c 曲线
Fig. 2 Pressure ratio function Z to efficiency η_c curve

在原有的等转速数据点上, 利用上节中的插值函数构造和求解方法进行二维连分式内插, 在

每条等换算转速线上, 对 Z 等间距增加数据点, 按升序与原始数据合并, 方便下一步的特性曲面重构. 对换算流量 W_{acor} 曲线和效率 η_c 曲线分别进行连分式内插扩充 40 个数据点, 结果如图 3 和图 4 所示.




图 3 扩充数据点后的 W_{acor} 曲线空间特性图
Fig. 3 W_{acor} space characteristic curve with expanded data




图 4 扩充数据点后的 η_c 曲线空间特性图
Fig. 4 η_c space characteristic curve with expanded data

以换算流量 W_{acor} 和换算转速 n_{cor} 为坐标的计算区域内的数据点如图 5 所示. 在坐标系中, 这些数据点分布非常不均匀, 主要集中在对角线附近, 这将会对神经网络的训练效果产生极大影响. 为使数据点分布尽量均匀, 需要对实际的分布域进




图 5 计算区域调整前的换算流量 W_{acor} 数据点分布图

Fig. 5 Data points scattergram of converted flow rate W_{acor} before computational domain adjusted

行调整. 其中横坐标对应的换算转速是固定的离散值, 不需要调整, 只需要对纵坐标按照式(10)进行转换^[7].

$$W'_{acor} = \frac{\arctan \frac{W_{acor}}{n_{cor}} - \min \left\{ \arctan \frac{W_{acor}}{n_{cor}} \right\}}{\max \left\{ \arctan \frac{W_{acor}}{n_{cor}} \right\} - \min \left\{ \arctan \frac{W_{acor}}{n_{cor}} \right\}} \quad (10)$$

图 6 和图 7 为转换后的节点在计算区域的分布图. 同转换前的计算区域相比, 转换后的节点在域内分布更加均匀. 求取压气机特性就转化为在调整后的计算区域内利用扩充后的节点对增压比和效率特性曲面的重构过程, 最后对变换区域进行反调整, 还原数据.




图 6 计算区域调整后的相对换算流量 W'_{acor} 数据点分布图

Fig. 6 Data points scattergram of relative converted flow rate W'_{acor} after computational domain adjusted




图 7 计算区域调整后的相对换算流量 W'_{acor} 三维曲面图

Fig. 7 Three-dimensional surface of relative converted flow rate W'_{acor} after computational domain adjusted

3 基于趋利避害原则的粒子群算法

近几年来粒子群算法 (particle swarm optimization, 简称 PSO) 在函数优化、神经网络训练、

模糊系统控制以及遗传算法的应用领域都有比较好的表现, 并在工程实践中表现出巨大的潜力^[8]. 但与其它全局优化算法一样, 标准粒子群算法会出现早熟收敛现象^[9-10]. 本文把生物行为中昆虫的趋利避害原则引入到粒子群优化算法中, 改变传统 PSO 只存在趋利操作而没有避害操作的单向性, 提出一种保持和增加种群多样性的改进算法, 增强全局寻优性能^[11-14].

假设一个由 M 个粒子组成的群体在 D 维搜索空间以一定的速度飞行. 粒子 i 在 t 时刻的状态属性如下

1) 粒子位置

$$X_i(t) = (x_{i1}(t), x_{i2}(t), \dots, x_{iD}(t)) \quad (11)$$

其中 $x_{iD}(t) \in [L_D, U_D]$, L_D, U_D 分别为搜索空间的下限和上限;

2) 粒子速度

$$V_i(t) = (v_{i1}(t), v_{i2}(t), \dots, v_{iD}(t)) \quad (12)$$

其中 $v_{iD}(t) \in [v_{\min}, v_{\max}]$, $v_{\min}, v_{\max}$ 分别为粒子的最小和最大速度;

3) 个体最优位置

$$P_{\text{best}_i}(t) = (p_{\text{best}_i1}, p_{\text{best}_i2}, \dots, p_{\text{best}_iD}) \quad (13)$$

4) 全局最优位置

$$G_{\text{best}}(t) = (g_{\text{best}_1}, g_{\text{best}_2}, \dots, g_{\text{best}_D}) \quad (14)$$

其中 $1 \leq i \leq M$.

则趋利操作每次迭代中, 粒子根据以下公式更新速度和位置

$$V_i(t+1) = \omega V_i(t) + c_1 r_1 [P_{\text{best}_i}(t) - X_i(t)] + c_2 r_2 (G_{\text{best}}(t) - X_i(t)) \quad (15)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (16)$$

其中 ω 为惯性权重, 其大小决定了粒子对当前速度继承的多少; r_1, r_2 为均匀分布在 $(0, 1)$ 区间的随机数; c_1, c_2 为学习因子, 通常取 $c_1 = c_2 = 2$.

当粒子执行避害操作时, 跟趋利操作相仿, 每个位置更新过程中, 记录粒子个体最差位置和全局最差位置

$$P_{\text{worst}_i}(t) = (p_{\text{worst}_i1}, p_{\text{worst}_i2}, \dots, p_{\text{worst}_iD}) \quad (17)$$

$$G_{\text{worst}}(t) = (g_{\text{worst}_1}, g_{\text{worst}_2}, \dots, g_{\text{worst}_D}) \quad (18)$$

算法执行过程中, 粒子避开以上两个位置, 速度更新按下式进行

$$V_i(t+1) = \omega V_i(t) - c_3 r_1 (P_{\text{worst}_i}(t) - X_i(t)) - c_4 r_2 (G_{\text{worst}}(t) - X_i(t)) \quad (19)$$

其中 c_3, c_4 称为避害学习因子。

粒子的避害运动没有目标趋向性, 仅仅是增加粒子向较好区域飞行的可能性, 有助于发现更为优秀的位置。因此, 寻优算法应以趋利操作为主, 同时将避害操作的强度控制在适当的范围, 否则容易造成粒子寻优运动的混乱, 反而使寻优效率变差。避害操作的强度大小可以通过避害学习因子 c_3, c_4 的大小进行调节。

仿照标准 PSO 算法的线性惯性权重策略, 使 c_3, c_4 随着进化代数而线性递增, 一般取

$$c_3 = c_4 = c_{\text{start}} + \frac{c_{\text{end}} - c_{\text{start}}}{T} \times t \quad (20)$$

式中 c_{start} 为避害学习因子的初始值, 也是最小值; c_{end} 为迭代结束时的学习因子值, 也是最大值。 T 为最大迭代次数; t 为当前迭代次数这种强度分配方法保证了算法初期在趋利操作的作用下快速收敛, 后期粒子加强避害特性避免落入局部极小值点, 过程中依据粒子群多样性度量值依切换趋利操作与排斥操作, 将这种改进的 PSO 算法记为 PSO-T。采用 Riget J 提出的多样性度量方法, 多样性度量公式表示如下:

$$f_{\text{div}}(t) = \frac{1}{M \cdot |L|} \cdot \sum_{i=1}^M \sqrt{\sum_{j=1}^D [x_{ij}(t) - \bar{x}_j(t)]^2} \quad (21)$$

式中 M 为种群大小, $|L|$ 为搜索空间最长对角线的长度, D 为粒子维数, $x_{ij}(t)$ 是 t 次迭代时第 i 个粒子位置的第 j 个分量, $\bar{x}_j(t)$ 是第 j 个分量的平均值。

定义两个阈值 d_{low} 和 d_{high} , 当种群多样性小于 d_{low} 时, 粒子由趋利操作转入避害以增加种群的多样性。当种群多样性大于 d_{high} , 算法重新转入趋利操作, 如此周而复始直到预设的迭代次数或收敛精度。

4 粒子群算法优化的 BP 神经网络

BP 神经网络模型思路清晰、结构严谨、工作状态稳定、可操作性强, 是人工神经网络模型中应用最广泛的一种。已经证明含有足够多隐含层节点的 3 层 BP 网络能够以任意精度逼近一个非线性函数^[15]。针对 BP 神经网络由于初始权值选取不当容易陷入局部极小点的问题, 本文将善于处理多峰函数的 PSO-T 算法引入到网络初始权值和阈值的确定中, 以提高学习精度, 增强网络的泛化能力。同时采用以下方法增强网络训练效果和泛化能力:

1) 采用最大最小法对输入数据进行归一化处理。把所有输入输出数据都转化为 $[0, 1]$ 之间的数, 消除压力比函数和换算转速间数量级的差别, 避免因为输入输出数据数量级差别较大而造成网络预测误差增大。函数形式如下:

$$x_k = (x_k - x_{\min}) / (x_{\max} - x_{\min}) \quad (22)$$

其中 $x_{\min}$ 为数据序列中的最小数; $x_{\max}$ 为序列中的最大数。

2) 确定压气机的喘振边界。利用压气机喘振边界点的实验数据拟合出一条边界线, 并以此作为网络泛化后各等转速线的上界。

3) 模仿小样本数据分析中的自助法, 进行 2 次网络训练。利用连分式扩充后的等转速线数据作为网络训练数据进行一次训练。利用网络预测间距较大的等转速线间的特性数据, 将小样本转化为大样本, 跟原有数据合并作为第二次网络训练的输入数据, 完成最终的网络训练。

4) 采用正则化方法提高网络的泛化能力。一般的目标函数为网络误差的平方和的均值。

$$E_{\text{mse}} = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (23)$$

其中 e_i 为各维的误差, y_i 为网络的期望输出, $\hat{y}_i$ 表示实际输出。为了提高泛化能力, 在目标函数里加上由网络权值和偏置值的平方和的均值组成的一项。

$$E_{\text{msereg}} = \gamma E_{\text{mse}} + (1 - \gamma) E_{\text{msw}} \quad (24)$$

γ 为一个比率数, 加的一项 E_{msw} 为

$$E_{\text{msw}} = \frac{1}{n} \sum_{j=1}^n w_j^2 \quad (25)$$

式中 w_j 为网络节点与上次训练值的偏差。用上面的目标函数可以使得网络有更小的权值和偏置值, 从而使得网络的响应更加平滑, 减小过拟合的可能性。比率 γ 的设定采用贝叶斯的统计方法来自动决定正则化参数。

5 压气机特性曲面重构模型的建立

PSO-T 优化 BP 神经网络分为 BP 神经网络结构确定、PSO-T 算法优化和 BP 神经网络预测 3 个部分。其中 BP 神经网络结构确定部分根据拟合函数输入输出参数个数确定神经网络结构, 进而确定遗传算法个体的长度。PSO-T 算法优化使用粒子群算法优化 BP 神经网络的权值和阈值, 种群中的每个个体都包含了一个网络所有权值和阈值, 个体通过适应度函数计算个体适应度。

PSO-T 通过趋利避害操作找到最优适应度值对应个体. BP 神经网络预测用 PSO-T 算法得到最优个体对网络初始权值和阈值赋值, 网络经训练后预测函数输出.

BP 神经网络隐含层单元数的选择是一个十分复杂的问题, 目前并没有很好的解析式表示, 它与问题的要求及输入输出的单元的多少都有直接的关系. 本文采用试探法, 从 5 至 20 逐一增加隐层神经元的个数对网络进行训练和测试, 经过多次仿真试验对比, 确定取隐含层单元数为 9 时网络能较好地重构测试样本. 将基于趋利避害原则的粒子群算法学习因子 c_1 和 c_2 都设置为 2; 将多样性控制参数 d_{low} 和 d_{high} 分别设置为 1×10^{-5} , 0.2, 种群的大小设置为 30.

将已有的压气机通用特性图离散化后得到原始特性数据, 定义以下形式的矩阵

换算转速矩阵为

$$n_{\text{cor}}|_{m \times n} = [n_{\text{cor}}^1, n_{\text{cor}}^2, \dots, n_{\text{cor}}^i, \dots, n_{\text{cor}}^p, \dots, n_{\text{cor}}^q, \dots, n_{\text{cor}}^r, \dots, n_{\text{cor}}^m]^T$$

其中, $n_{\text{cor}}^i|_{n \times 1} = [n_{\text{cor}}^i, n_{\text{cor}}^i, \dots, n_{\text{cor}}^i]^T$.

增压比为

$$\pi_c|_{m \times n} = [\pi_c^{ij}]$$

$$(i = 1, 2, \dots, m, j = 1, 2, \dots, n)$$

换算流量为

$$W_{\text{acor}}|_{m \times n} = [W_{\text{acor}}^{ij}]$$

$$(i = 1, 2, \dots, m, j = 1, 2, \dots, n)$$

压气机效率为

$$\eta_c|_{m \times n} = [\eta_c^{ij}]$$

$$(i = 1, 2, \dots, m, j = 1, 2, \dots, n)$$

按上述方法引入压力比函数 Z , 在每个等转速线进行连分式插值扩充 d 个数据点, 对换算流量计算区域进行调整得到相对换算流量 W'_{acor} .

压力比函数为

$$Z|_{m \times (n+d)} = [\pi_c^{ij}]$$

$$(i = 1, 2, \dots, m, j = 1, 2, \dots, n+d)$$

相对换算流量为

$$W'_{\text{acor}}|_{m \times (n+d)} = [W'_{\text{acor}}^{ij}]$$

$$(i = 1, 2, \dots, m, j = 1, 2, \dots, n+d)$$

抽取低中高速三个等转速线 $n_{\text{cor}}^p, n_{\text{cor}}^q, n_{\text{cor}}^r$ 作为模型验证数据

$$n_{\text{cor_test}} = [n_{\text{cor}}^p, n_{\text{cor}}^q, n_{\text{cor}}^r]$$

相应的压比函数和相对换算流量测试数据为

$$Z|_{3 \times (n+d)} = [\pi_c^{ij}]$$

$$(i = p, q, r, j = 1, 2, \dots, n+d)$$

$$W'_{\text{acor}}|_{3 \times (n+d)} = [W'_{\text{acor}}^{ij}]$$

$$(i = p, q, r, j = 1, 2, \dots, n+d)$$

将剩余的转速线数据点作为网络训练数据, 上述特性数据按矩阵中的位置一一对应, 即给定一对换算转速值和压比函数值对应一个相对换算流量值和效率值, BP 网络的输入和输出训练数据为

$$I_{\text{train}} = (n_{\text{cor}}, Z),$$

$$O_{\text{train}} = (W'_{\text{acor}}, \eta_c)$$

利用上述数据样本, 预留第 2, 6, 14 条等转速线, 进行一次网络训练, 泛化得到未知区域的等转速线, 如图 8 和图 9 所示.




图 8 BP 网络第一次训练泛化得到的相对换算流量曲线

Fig. 8 Relative converted flow rate curve obtained by BP neural network generalization after the first net training




图 9 BP 网络第一次训练泛化得到的相对效率曲线

Fig. 9 Relative efficiency curve obtained by BP neural network generalization after the first net training

将上一步训练出的数据连同原有数据一起作为新的学习样本, 进行第二次网络训练, 确定各节点权值和阈值. 训练好的 BP 神经网络就是最终的压气机特性重构模型.

6 模型的校核与验证

采用平均绝对误差(mean absolute error,简称 MAE)作为重构模型精度的评价指标

$$e_{\text{mae}} = \sum_{i=1}^n |y_i - \hat{y}_i| / n \quad (26)$$

其中 n 是验证点的数量; $\hat{y}_i$ 是观测值 y_i 的预测值. e_{mae} 的值越低,则模型的精确性越高.

将压气机预留的高、中、低 3 组换算转速特性数据的压比函数和相对换算流量测试数据作为输入,代入训练好的 BP 网络代理模型,计算出流量和效率的估计值,与预留的真实值比较并计算出评价指标 e_{mae} . 压比特性和效率特性的估计结果如图 10 和图 11 所示. 可以看出,使用重构模型预报所得的 3 组换算转速和压比下的流量值与原始数据的曲线走势非常吻合.




图 10 压气机压比特性网络模型校验结果

Fig. 10 Check result of neural network model of compressor's pressure ratio characteristic




图 11 压气机效率特性网络模型校验结果

Fig. 11 Check result of neural network model of compressor's efficiency characteristic

同时给出由常用的二维线性插值法和普通 BP 神经网络一次训练模型计算所得的特性结果作为对比,压比和效率特性的精度评价指标 e_{mae} 的计算结果如图 12 和图 13 所示.

通过对比可以看出,本文提出的方法所建重




图 12 压比特性模型 e_{mae} 对比

Fig. 12 e_{mae} histogram of pressure ratio characteristic model




图 13 效率特性模型 e_{mae} 对比

Fig. 13 e_{mae} histogram of pressure ratio characteristic model

构模型具有较好的精度. 这正是因为模型的建立和训练过程考虑了不同固定换算转速下,压气机特性整体空间位置的相关性. 并且用单个神经网络来同时表达压气机压比特性和效率特性的整体重构模型更加简便,免去了在发动机型仿真过程中需要对压气机特性分别进行二维插值的麻烦,减少了许多计算量.

7 结 论

以某型涡扇发动机低压压气机特性为例,通过建模和校验结果表明:使用较少的压气机原始样本数据,通过连分式扩容的改进粒子群神经网络对低压压气机特性进行模型重构,体现了压气机特性参数间的隐含耦合关系,预测结果的趋势和符合度都较好,具有更高的精度. 如果不预留检测数据,将所有原始数据作为模型的训练样本,压气机特性模型重构的精度必将进一步提高.

高压压气机的特性与低压压气机类似,也可采用本文的方法进行建模. 将重构后扩展的压气机特性数据用于选配法、坐标法和部件法等以压气机通用特性曲线为基础的发动机模型的求解将在一定程度上提高模型计算的速度和精度.

参考文献:

- [1] 陈玉春,徐思远,屠秋野,等. 求解航空发动机非线性方程组的变步长牛顿法[J]. 航空计算技术, 2009, 39(1): 39-44.
CHEN Yuchun, XU Siyuan, TU Qiuye, et al. Variable step newton method for solving the nonlinear equations of aero turbine engines[J]. Aeronautical Computing Technique, 2009, 39(1): 39-44. (in Chinese)
- [2] 王鑫. 航空发动机数学模型与控制规律研究[D]. 西安: 西北工业大学, 2007.
WANG Xin. Research on aero-engine mathematical model and control strategy[D]. Xi'an: Northwestern Polytechnical University, 2007. (in Chinese)
- [3] Tirnovan R, Giurgea S, Miraoui A, et al. Surrogate modeling of compressor characteristics for fuel-cell applications[J]. Applied Energy, 2008, 85(5): 394-403.
- [4] Hu M, Tan J Q. Adaptive osculatory rational interpolation for image processing[J]. J Comp Appl Math, 2006, 195(1/2): 46-53.
- [5] Hu M, Tan J Q, Xue F. A new approach to the image resizing using interpolating rational linear splines by continued fractions[J]. Journal of Information & Computational Science, 2005, 2(4): 681-685.
- [6] Zhao Q J, Tan J Q. Block based thiele-like blending rational interpolation[J]. J. Comp. Appl. Math., 2006, 195(1/2): 312-325.
- [7] 杨欣毅. 弹用涡喷发动机气动过程数值仿真与试验研究[D]. 山东烟台: 海军航空工程学院, 2009.
YANG Xinyi. Numerical simulation and experimental study on the missile turbojet engine start process[D]. Yantai Shandong: Naval Aeronautical Engineering University, 2009. (in Chinese)
- [8] 张强, 李本威, 马力. 粒子群算法在航空发动机部件模型求解中的应[J]. 系统仿真学报, 2009, 21(12): 3584-3587.
ZHANG Qiang, LI Benwei, MA Li. Application of particle swarm optimization in solution to aeroengine component-level model[J]. Journal of System Simulation, 2009, 21(12): 3584-3587. (in Chinese)
- [9] Kennedy J, Mendes R. Population structure and particle swarm performance[C]// Proceedings of the IEEE Congress on Evolutionary Computation, Hawaii; IEEE Press, 2002: 1671-1675.
- [10] Liang J J, Suganthan P N. Dynamic multiswarm particle swarm optimizer[C]// Proceedings of the IEEE Swarm Intelligence symposium. Piscataway: IEEE Press, 2005: 124-129.
- [11] Li L L, Wang L, Liu L. An effective hybrid PSOSA strategy for optimization and its application to parameter estimation[J]. Applied Mathematics and Computation, 2006: 179(1): 135-146.
- [12] He S, Wu Q H, Wen J Y, et al. A particle swarm optimizer with passive congregation[J]. Biosystems, 2004, 78(1/2/3): 135-147.
- [13] Mendes R, Kennedy J. The full informed particle swarm: Simpler, maybe better[J]. IEEE Transaction on Evolutionary Computation, 2004, 8(3): 204-210.
- [14] 纪震, 廖惠连, 吴青华. 粒子群算法及应用[M]. 北京: 科学出版社, 2009.
- [15] 宋金光. 人工神经网络在航空发动机中的应用[J]. 中国民航学院学报, 2002, 20(3): 46-50.
SONG Jinguang. Application of artificial neural network in aeroengine[J]. Journal of Civil Aviation University of China, 2002, 20(3): 46-50. (in Chinese)