

基于 PSO-BP 神经网络的固冲发动机 推力估计器设计

王 昭^{1,2}, 田小涛^{1,2}, 黄 萌^{1,2}, 张 博^{1,2}

- (1. 中国兵器工业集团有限公司 西安现代控制技术研究所, 西安 710065;
2. 中国兵器工业集团有限公司 现代控制技术重点实验室, 西安 710065)

摘 要: 为了对固体火箭冲压发动机的推力进行直接控制,提出了基于 PSO(粒子群优化算法)优化 BP(back propagation)神经网络的固体火箭冲压发动机推力估计方法。采用 SPSO(标准 PSO)和三种不同的 BB-PSO(骨干 PSO)寻优神经网络权值,而后以最优权值进行 BP 网络训练,对其进行精调,如此便可获取推力和燃气流量、飞行马赫数以及飞行高度之间的非线性关系,从而完成推力估计器的设计。利用 240 组训练集数据对网络进行训练,并用 180 组测试集数据对网络进行验证。仿真结果表明:在 SPSO、BBExp(exploiting BB-PSO)、ABPSO(modified adaptive BBPSO)和 SNPSO(simplified pruning strategy based BBPSO)等四种不同的 PSO 中,基于 SNPSO 优化 BP 神经网络实现推力估计器设计是最为便捷有效的方法,不仅形式简单,而且对于测试集数据而言,其能够将推力相对误差控制在 5% 以内。

关 键 词: 固体火箭冲压发动机; 推力估计器; 粒子群优化算法; 神经网络; 非线性关系

中图分类号: V435.5

文献标志码: A

Design of thrust estimator in the solid rocket ramjet based on PSO-BP neural network

WANG Zhao^{1,2}, TIAN Xiaotao^{1,2}, HUANG Meng^{1,2}, ZHANG Bo^{1,2}

- (1. Xi'an Modern Control Technology Research Institute,
China North Industries Group Corporation Limited, Xi'an 710065, China;
2. Key Laboratory for Modern Control Technology,
China North Industries Group Corporation Limited, Xi'an 710065, China)

Abstract: A solid rocket ramjet thrust estimation method based on BP(back propagation) neural network optimized by PSO (particle swarm optimization) was proposed for direct control of the thrust of solid rocket ramjet. In detail, SPSO (standard PSO) and three different BBPSO (bare bones PSO) methods were adopted to optimize the network weights. Then, the optimal weights as the initial value were tuned finely by BP neural network training. Therefore, the non-linear relationship between thrust and gas flow, flight Mach number as well as flight height was obtained such that the design of thrust estimator was completed. 240 sets of training data were used to train the network, and 180 sets of testing data were used to verify the network. The simulation results showed that among four different PSO methods such as SPSO, BBExp (exploiting

收稿日期:2021-06-25

作者简介:王昭(1992—),男,工程师,博士,主要从事人工智能在发动机控制中的应用研究。

引用格式:王昭,田小涛,黄萌,等. 基于 PSO-BP 神经网络的固冲发动机推力估计器设计[J]. 航空动力学报,2022,37(7):1487-1494. WANG Zhao, TIAN Xiaotao, HUANG Meng, et al. Design of thrust estimator in the solid rocket ramjet based on PSO-BP neural network[J]. Journal of Aerospace Power, 2022, 37(7): 1487-1494.

BBPSO), ABPSO* (modified adaptive BBPSO) and SNPSO (simplified pruning strategy based BBPSO), the design of thrust estimator based on BP neural network optimized by SNPSO is the most convenient and effective method not only due to its simple form but also due to its capacity of controlling the relative thrust error within 5% for test set data.

Key words: solid rocket ramjet; thrust estimator; particle swarm optimization; neural network; nonlinear relationship

固体火箭冲压发动机由于将火箭发动机和冲压发动机组合在一起,因而能够充分发挥火箭喷出的高能射流对低能空气流的引射增压作用,在性能上兼备了两种发动机的优点^[1],得以广泛应用于新型战术导弹中。著名的“流星”超视距空空导弹的动力装置便采用了固体火箭冲压发动机。随着战术导弹工作包线的扩大,同时保证发动机能够安全高效地工作,要求固体火箭冲压发动机的推力必须能够进行有效调节^[2]。

由于在飞行过程中,无法实时测量发动机的推力。传统的推力控制方式通常采取控制与飞行条件相关的参数,如压强、温度等间接地控制发动机的推力。牛文玉对比了多个表征发动机状态的参数,提出进气道出口静压作为发动机推力调节的被控参数^[3]。但这种间接控制推力的方式为了保护发动机,通常预留了足够多的安全边界,因此不能充分发挥发动机的潜能^[4]。

为了克服上述缺陷,另一种思路便是通过可测参数实时估计出固体火箭冲压发动机的推力。如此,可通过直接控制推力来充分发挥发动机的潜在性能。一般来说,估计方法主要可分为基于模型的方法和数据驱动的方法^[5]。前一种方法顾名思义,建立发动机性能计算模型,在发动机各项参数确定的条件下,计算不同飞行马赫数、不同飞行高度及不同燃气流量规律下发动机的推力^[6]。后一种方法是要建立不同飞行马赫数、飞行高度及燃气流量和发动机推力之间的非线性对应关系,这就需要海量的数据作为支撑。事实上,最简单的数据驱动方法便是插值^[7]。然而,插值的精度较低,无法准确估计出推力。目前,最有效的数据驱动方法便是将人工智能算法用于发动机性能的估计中,比如遗传算法^[8]、神经网络^[9-10]、粒子群极限学习机^[11]等。

上述算法中,粒子群优化算法 (particle swarm optimization, PSO) 是基于生物群的群集行为的一种群智能优化方法。该算法具有参数较少、收敛迅速、全局搜索能力强等优点,广泛应用

于模式识别、信号处理、智能控制等领域^[12]。在标准 SP SO (standard PSO) 中,每个优化问题的解均为搜索空间中的一个粒子,每个粒子都有其位置、速度及适应度值。BBPSO (bare bones PSO) 则是一种取消了粒子速度属性的 PSO,粒子的位置由服从高斯分布的随机采样直接获得,因而较 SP SO 更加简洁,理论结构更加简单^[13-14]。Kennedy 提出的高斯骨干 PSO^[15]和孙俊提出的量子 PSO^[16]是最为广泛的 BBPSO 形式。需要特别指出的是,早熟问题和“burst”现象是各种 PSO 普遍存在的问题。早熟指粒子收敛于非全局最优解的位置,“burst”现象指粒子群在一段时间内几乎不进行进化,而在一定迭代次数后突然又恢复进化的现象。解决早熟和“burst”问题,须从优化全局搜索能力和局部开发能力两方面着手。张勇等提出了 ABPSO (adaptive BBPSO),根据粒子的聚散程度和种群的多样性自适应地调节高斯采样的标准差 δ ,同时采用变异算子进一步增加群体的多样性^[17],但是并未对高斯分布的均值 μ 做改进。为此王东风等对 μ 进行自适应的调整^[18],获得了更佳的优化结果。而陈健的自学习骨干 PSO 本质上也是一个自适应的高斯分布^[19]。此外,张震提出的 NPSO (基于剪枝策略的骨干 PSO) 对于克服上述两方面的问题也有着很好的效果^[13]。

本文采用不同的 PSO 对训练集数据进行训练来优化神经网络的权值,而后将其用于固体火箭冲压发动机推力估计器的设计,最后通过测试集数据对不同算法的预估性能进行比较。所需数据通过弹道仿真平台获得。

1 基于 PSO-BP 神经网络的推力估计器设计

以固体火箭冲压发动机为研究对象,基于推力的控制器结构如图 1 所示。如前所述,本文的目的是通过 PSO 寻优神经网络权值,而后以最优权值进行 BP (back propagation) 网络训练,进而获取推力和燃气流量、飞行马赫数以及飞行高度之




图 1 直接推力控制结构图

Fig.1 Structure of direct thrust control

间的非线性关系,完成推力估计器的设计。

1.1 BP 神经网络

如图 2 所示,本文所建立的推力预测模型使用的神经网络包含输入层、隐含层和输出层 3 层,其中输入层的神经元个数设置为 3,分别代表燃气流量、飞行马赫数和飞行高度。输出层神经元个数设置为 1,代表推力。隐含层神经元个数根据以下经验公式^[20]设置为 5。

$$q = \sqrt{k+l} + a \quad (1)$$

其中 q 为隐含层神经元个数, k 和 l 分别为输入层和输出层神经元个数, a 为常数, $a \in [1, 10]$ 。




图 2 神经网络结构图

Fig.2 Structure of neural network

由图 2 可见,网络输入为 $O_d^{(1)} = I_d, d=1, 2, 3$ 。而网络隐含层输入、输出分别为

$$n_\lambda^{(2)} = \sum_{d=0}^3 \omega_{\lambda d}^{(2)} O_d^{(1)} \quad (2)$$

$$O_\lambda^{(2)} = f(n_\lambda^{(2)}), \quad \lambda = 1, 2, \dots, 5$$

其中 $f(n_\lambda^{(2)})$ 为隐含层作用函数,取为非负 Sigmoid 函数,亦即: $f(\gamma) = \frac{1}{1 + e^{-\gamma}}$ 。 $\omega_{\lambda d}^{(2)}$ 为隐含层和输入层的连接权值。另外,需要强调的是,为了描述简单,上式将隐含层节点的阈值作为特殊的权值表示,亦即 $\omega_{\lambda d}^{(2)} = -\theta_\lambda^{(2)}, O_d^{(1)} = 1, d=0$ 。

网络输出层输入、输出分别为

$$\begin{cases} v_{i,j}^{(t+1)} = \omega v_{i,j}^{(t)} + c_1 r_1 (p_{i,j}^{(t)} - x_{i,j}^{(t)}) + c_2 r_2 (p_{g,j}^{(t)} - x_{i,j}^{(t)}) \\ x_{i,j}^{(t+1)} = x_{i,j}^{(t)} + v_{i,j}^{(t+1)} \end{cases}, \quad j = 1, 2, \dots, D \quad (6)$$

$$n^{(3)} = \sum_{\lambda=0}^5 \omega_{\lambda}^{(3)} O_\lambda^{(2)} \quad (3)$$

$$O^{(3)} = \varphi(n^{(3)})$$

输出层的输出即为推力,亦即

$$T = O^{(3)} \quad (4)$$

而输出层的作用函数 φ 可取为线性函数,亦即 $\varphi(\gamma) = \gamma$ 。

本文需要对最优权值进行 BP 神经网络训练,训练过程由正向传播和反向传播组成。正向传播中,输入信号从输入层经隐含层传向输出层。若输出层得到了期望的输出或者达到了训练次数,训练结束;否则,转至反向传播来精调网络权值。反向传播的具体过程可参考文献[21]。

1.2 PSO

1.2.1 SPSO

在 SPSO 中,每个优化问题的解均为搜索空间中的一个粒子,每个粒子都有其位置、速度及适应度值。基本的 SPSO 由以下三部分构成。

1) 初始化

假设在 D 维的搜索空间中,种群由 N_s 个粒子构成,第 i 个粒子的位置为 $\mathbf{X}_i = (x_{i,1}, x_{i,2}, \dots, x_{i,D})$, 对应的速度为 $\mathbf{V}_i = (v_{i,1}, v_{i,2}, \dots, v_{i,D})$ 。为了合理限制粒子的运动范围,须设定粒子的速度区间 $[v_{\min}, v_{\max}]$ 和位置区间 $[x_{\min}, x_{\max}]$ 。首先,对于每个粒子而言,在位置区间内取 D 个随机数,将其设为初始位置,而将其初始速度置为 0。需要说明的是,本文生成随机数所采用的种子是计算机系统默认值。

2) 适应度计算

将 BP 神经网络的输出误差作为 PSO 的适应度函数,即

$$F = \sum_{m=1}^{N_p} (\hat{y}_m - y_m)^2 \quad (5)$$

其中 $\hat{y}_m$ 为样本 m 通过训练的实际输出值, y_m 为弹道平台得到的精确值, N_p 为样本总数。

3) 位置和速度更新

在每一次迭代中,粒子通过对比个体历史最优值 P_i 和全局最优值 P_g 来不断更新自己的位置与速度。粒子的个体历史最优值为 $P_i = (p_{i,1}, p_{i,2}, \dots, p_{i,D})$, 全局最优值为 $P_g = (p_{g,1}, p_{g,2}, \dots, p_{g,D})$, 则其迭代公式为^[20]

其中学习因子 c_1 为认知学习系数,影响粒子对自身的认知步伐; c_2 为社会学习系数,影响粒子对社会的认知步伐。本文采用的学习因子表达式为^[22]

$$\begin{cases} c_1 = c_{10} - (c_{10} - c_{11})(1 - t/t_{\max}) \\ c_2 = c_{20} + (c_{21} - c_{20})(1 - t/t_{\max}) \end{cases} \quad (7)$$

其中 c_{10} 和 c_{11} 分别为 c_1 的起始取值和最终取值; c_{20} 和 c_{21} 分别为 c_2 的起始取值和最终取值, t 为迭代次数, $t_{\max}$ 为最大迭代次数。此外,式(7)中 r_1 、 r_2 是介于 $[0, 1]$ 之间的随机数。 ω 为惯性权重,用以平衡算法的局部搜索和全局搜索。本文采用非线性递减的方式来控制惯性权重^[12]。

1.2.2 BBPSO

BBPSO 是在对 SPSO 中粒子的运行轨迹进行分析的基础上提出的,算法取消了速度项,粒子的位置由服从高斯分布的随机采样直接获得,避

免了 SPSO 复杂的参数调节。BBPSO 的一般模型可归纳如下^[13]:

$$x_{i,j}^{(t+1)} = \mu_{i,j}^{(t)} + \alpha \xi_j \delta_{i,j}^{(t)} \quad (8)$$

其中 $x_{i,j}$ 为粒子 i 在维度 j 的进化位置; α 为标量,是唯一的控制参数, α 越大,粒子群越倾向于分散, α 越小,越倾向于聚拢; ξ_j 为标准高斯分布; $\mu_{i,j}$ 和 $\delta_{i,j}^{(t)}$ 分别表示进化中心项和离散控制项, $\mu_{i,j}$ 为粒子的期望位置, $\delta_{i,j}^{(t)}$ 为粒子分布方差的大小,随着迭代的进行, $\delta_{i,j}^{(t)}$ 将减小到零,粒子位置将收敛于 $\mu_{i,j}$ 。

式(9)是 BBPSO 的基本形式,本文所考察的三种 BBPSO 分别为 BBExp^[15]、ABPSO⁺^[17] 和 SNPSO(simplified NPSO)^[13],对应的粒子群进化方程是在式(8)的基础上加以损益,具体形式如表 1 所示。

表 1 三种 BBPSO 的演化方程及其参数值

Table 1 Evolutional equation of three kinds of BBPSO and corresponding parameters

算法	BBExp	ABPSO ⁺	SNPSO
演化方程	$x_{i,j}^{(t+1)} = \begin{cases} (9), & r < 0.5 \\ p_{i,j}^{(t)}, & r > 0.5 \end{cases}$	$x_{i,j}^{(t+1)} = \begin{cases} (9), & r < \Theta \\ x_{i,j}^{(t)}, & r > \Theta \end{cases}$	式(8)
$\mu_{i,j}^{(t)}$	$\frac{p_{i,j}^{(t)} + p_{g,j}^{(t)}}{2}$	$\frac{p_{i,j}^{(t)} + p_{g,j}^{(t)}}{2}$	$\frac{\xi_a p_{i,j}^{(t)} + \xi_b p_{g,j}^{(t)}}{\xi_a + \xi_b}$
α	1	1	0.5
$\delta_{i,j}^{(t)}$	$ p_{i,j}^{(t)} - p_{g,j}^{(t)} $	$ p_{i,j}^{(t)} - p_{g,j}^{(t)} + \Delta$	$\mu_{i,j}^{(t)} - x_{i,j}^{(t)}$

三种算法中,BBExp 和 ABPSO⁺ 的进化中心项 $\mu_{i,j}$ 是一致的,均取为历史最优位置 $p_{i,j}^{(t)}$ 和全局最优位置 $p_{g,j}^{(t)}$ 的中点。而对于离散控制项 $\delta_{i,j}^{(t)}$,后者在前者的基础上加入摄动值 Δ ,表征粒子的聚散程度,其表达式为: $\Delta = r \cdot |p_{k1,j}^{(t)} - p_{k2,j}^{(t)}| \cdot \exp[F(p_{g,j}^{(t)}) - F(x_{i,j}^{(t)})]$ 。与文献[17]不同的是,在本文中 P_{k1} 和 P_{k2} 是在所有粒子中随机选择的两个粒子的历史最优位置。此外,对于 ABPSO⁺ 而言,选择概率 Θ 的取值也是至关重要的,本文取为 0.9。与前两种方法不同,在 SNPSO 中,粒子位置的更新与当前位置是相关的。再者 ξ_a 、 ξ_b 均为标准高斯分布, r 为 $(0, 1)$ 之间均匀分布的随机数。

1.3 推力估计器设计

推力估计器设计的核心是通过 PSO 优化神经网络的权值。首先随机地初始化一个粒子群,每个粒子包含一组神经网络权值的数据,对于本文而言,采用三层网络结构,每个粒子须包含全部的权值和阈值,即输出层与隐含层、隐含层与输入层的连接权值以及输出层和隐含层的阈值。而后,通过计算每个粒子的适应度来获得在当前迭代步下的历史最优值和全局最优值。接下来,通过更新公式不断迭代每个粒子的信息,直至达到最大迭代次数。而后以优化的权值为初值,进行 BP 网络训练,得到最终的训练权值,便获取了神经网络输入层与输出层的映射关系,亦即燃气流量、飞行马赫数和飞行高度和推力之间的表达式。具体的算法见表 2。

表 2 PSO-BP 算法
Table 2 Method of PSO-BP

1	设置粒子群的种群规模 N_s 和迭代次数 $t_{\max}$ 等参数。 初始化所有粒子的信息
2	For $t = 1$ to $t_{\max}$
3	For $i = 1$ to N_s
4	计算每个粒子的适应度
5	获取个体历史最优值
6	End
7	确定本次迭代全局最优值
8	更新每个粒子的信息
9	End
10	将粒子群优化的权值作为初始权值进行 BP 训练
11	达到训练次数时,算法结束

2 预估结果分析

以某型固体火箭冲压发动机模型为研究对象,在标准大气条件下,假定飞行高度(H)、飞行马赫数(Ma)、燃气流量等唯一确定发动机状态,也就同时确定了发动机的推力(T)。本文在全包线内选取 240 组数据(H 、 Ma 、燃气流量和 T)作为训练集,其中飞行马赫数的范围是 2.5~4.0,间隔为 0.5,飞行高度的范围是 2~20 km,间隔为 2 km,燃气流量的范围是 0.4~0.9 kg/s,间隔为 0.1 kg/s。另在三个飞行高度段(2~8 km, 8~14 km, 14~20 km)各随机抽样 20 组数据作为测试集。所需数据通过弹道仿真平台获得。此外,在进行 BP 神经网络训练时,由于各输入输出数据的量纲不同影响网络收敛过程,因此需对数据进行归一化预处理,以提高训练效率和数据的泛化能力^[8,11-12]。

设置种群规模 $N_s=4\ 000$;最大迭代次数 $t_{\max}=800$;粒子位置区间为 $[-10, 10]$,粒子速度取值区间为 $[-1, 1]$;其他变化的参数为: $c_{10}=2.5$, $c_{11}=1.25$, $c_{20}=0.5$, $c_{21}=2.5$ 。网络部分,设置学习率 η 为 0.01。

需要说明的是,对于 BBExp 和 ABPSO* 两种算法而言,其粒子的进化位置不受当前时刻的粒子位置影响,故而容易陷入局部最优^[13]。因此,本文将文献[22]的变异算子引入上述两种算法,以改进优化结果。其中,变异概率由下式决定:

$$p_m(t) = \left[(p_1 + p_0) - (p_1 - p_0) \cos(\pi t / t_{\max}) \right] / 2$$

(9)

式中 p_0 和 p_1 分别为变异概率的起始取值和最终

取值。经过反复数值实验,确定 BBExp 的变异参数取 $p_0=0.02$, $p_1=0.25$ 。ABPSO* 的变异参数取 $p_0=0.05$, $p_1=0.25$ 。需要说明的是,在变异算子中生成随机数时对种子进行了更新,而种子是通过计算机系统时间所确定的。

粒子群的优化过程如图 3 所示。可以看到, ABPSO* 和 SPSO 在优化过程中会出现前文所述的“burst”现象。这是由于 PSO 优化神经网络权值是一个多峰问题,PSO 在优化的过程中,有时会陷入局部优化,在发现更好的粒子后,整个群体便会继续进化。





图 3 PSO 过程
Fig.3 Optimization process of PSO

优化结果如表 3 所示。通过对比可知,对于本文所采用的参数而言,在四种算法中, BBExp 和 ABPSO* 的优化能力相当,而 SPSO 和 SNPSO 在无须引入变异算子的情况下,其优化性能超过前两种算法。


表 3 PSO 结果
Table 3 Results of PSO

算法	适应度/ 10^{-3}
SPSO	5.53
BBExp	57.60
ABPSO*	22.50
SNPSO	5.00


之后,分别将四种算法训练的权值作为初始值进行 BP 训练 1 000 次得到最终优化的权值。而后用于训练集的计算,其结果如图 4 所示。通过相对误差进行对比,显而易见, BBExp 所预估的推力相对误差绝对值最大值高达 42.6%, ABPSO*



(a) 推力拟合情况



(b) 推力局部拟合情况



(c) 推力相对误差

图4 训练集推力估计结果

Fig.4 Results of thrust estimation for training set


的预估结果稍好,推力相对误差绝对值最大值为26.3%。此外,SPSO和SNPSO的预测精度良好。具体而言,SPSO所预估的推力相对误差绝对值最大值仅为10.4%,SNPSO预估的推力相对

误差绝对值最大值为11.9%,对于绝大部分样本,两者预估的推力相对误差在10%以内。


为了进一步对SNPSO和SPSO两种算法的预估能力进行验证,在三个飞行高度段(2~8 km, 8~14 km, 14~20 km)各随机抽样60组数据作为测试集,对相应的推力预测,结果如图5~图7所示。表4所示为不同方法在三组测试集下的相对误差绝对值对比。

经过对比可知,两种算法在低空段(2~8 km)和中空段(8~14 km)的预测能力相当。在高空段(14~20 km),SPSO的预测能力稍优于SNPSO。从最大值来看,两者均能将推力的相对误差控制在5%以内。

综上所述,在SPSO、BBExp、ABPSO*和SNPSO等四种不同的粒子群方法中,基于SPSO和SNPSO优化BP神经网络的算法在无须引入变异算子的前提下便能实现良好的推力预估。



(a) 推力拟合情况



(b) 推力相对误差

图5 第一组测试集推力估计结果

Fig.5 Results of thrust estimation for first test set




图 7 第三组测试集推力估计结果

Fig.7 Results of thrust estimation for third test set

表 4 两种方法在不同测试集下的相对误差绝对值对比

Table 4 Comparison of absolute values of relative error for different test sets under two methods

算法	均值/%			总平均 值/%	最大 值/%
	第一组	第二组	第三组		
SPSO	1.30	1.78	1.15	1.41	3.52
SNPSO	1.32	1.77	1.79	1.63	4.17





图 6 第二组测试集推力估计结果

Fig.6 Results of thrust estimation for second test set

相较于 SPSO,SNPSO 因为取消了速度项而更加简洁明了。总之,在四种 PSO 中,基于 SNPSO 优化 BP 神经网络进行推力估计是最为便捷有效的方法。



3 结 论

本文提出了基于 PSO 优化神经网络的固体火箭冲压发动机推力估计器设计方法。选取燃气流量、飞行马赫数以及飞行高度等三个典型指标,在训练集样本数量为 240 的情况下对不同的 PSO-BP 算法进行仿真实验。而后,将所设计的推力估计器用于随机抽样得到的 180 组测试集样本。结果表明:在 SPSO、BBExp、ABPSO^{*} 和 SNPSO 等四种不同的 PSO 中,基于 SNPSO 优化 BP 神经网络的推力估计是最为便捷有效的。下一步可用 PSO 寻优神经网络隐含层神经元的节点数,从而进一步改善推力估计器的预测能力。

参考文献:

[1] 鲍福廷,黄熙君,张振鹏.固体火箭冲压组合发动机[M].北京:中国宇航出版社,2006.
[2] 牛文玉,刘顶新.固体火箭冲压发动机推力调节和进气道喘振保护的切换控制[J].弹箭制导学报,2015,35(4):93-96.
NIU Wenyu, LIU Dingxin. Switching control of thrust regulation and inlet buzz protection for ducted ramjet[J]. Journal

- of Projectiles, Rockets, Missiles and Guidance, 2015, 35(4): 93-96. (in Chinese)
- [3] 牛文玉. 燃气流量可调的固体火箭冲压发动机控制方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2009.
- NIU Wenyu. Study on control methods for variable flow ducted rockets[D]. Harbin: Harbin Institute of Technology, 2009. (in Chinese)
- [4] 李智强. 基于神经网络的航空发动机推力估计方法研究[D]. 南京: 南京航空航天大学, 2019.
- LI Zhiqiang. Research on aeroengine thrust estimation methods based on neural networks[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2019. (in Chinese)
- [5] HENRIKSSON M, GRONSTEDT T, BREITHOLTZ C. Model-based on-board turbofan thrust estimation[J]. Control Engineering Practice, 2011, 19(6): 602-610.
- [6] 焦继革, 张为华, 夏智勋, 等. 燃气流量可调固体火箭冲压发动机飞行性能分析[J]. 国防科技大学学报, 2011, 33(1): 21-24.
- JIAO Jige, ZHANG Weihua, XIA Zhixun, et al. Flight performance analysis of variable flow ducted rocket[J]. Journal of National University of Defense Technology, 2011, 33(1): 21-24. (in Chinese)
- [7] 王超磊, 刘代军, 崔颖. 固体火箭冲压发动机空空导弹推力控制研究[J]. 计算机仿真, 2015, 32(10): 31-34.
- WANG Chaolei, LIU Daijun, CUI Hao. Thrust control for air-to-air missile with variable flow ducted rockets[J]. Computer Simulation, 2015, 32(10): 31-34. (in Chinese)
- [8] 姚彦龙, 孙健国. 自适应遗传神经网络算法在推力估计器设计中的应用[J]. 航空动力学报, 2007, 22(10): 1749-1755.
- YAO Yanlong, SUN Jianguo. Application of adaptive genetic neural network algorithm in design of thrust estimator[J]. Journal of Aerospace Power, 2007, 22(10): 1749-1755. (in Chinese)
- [9] 姚彦龙, 孙健国. 基于神经网络逆控制的发动机直接推力控制[J]. 推进技术, 2008, 29(2): 249-252.
- YAO Yanlong, SUN Jianguo. Aeroengine direct thrust control based on neural network inverse control[J]. Journal of Propulsion Technology, 2008, 29(2): 249-252. (in Chinese)
- [10] 周宇宸. 燃气流量可调固冲发动机推力控制研究[D]. 长沙: 国防科技大学, 2018.
- ZHOU Yuchen. Research on thrust control of variable flow solid ducted rocket[D]. Changsha: National University of Defense Technology, 2018. (in Chinese)
- [11] 宋汉强, 李本威, 张赞, 等. 基于聚类与粒子群极限学习机的航空发动机推力估计器设计[J]. 推进技术, 2017, 38(6): 185-191.
- SONG Hanqian, LI Benwei, ZHANG Yun, et al. Aero-engine thrust estimator design based on clustering and particle swarm optimization extreme learning machine[J]. Journal of Propulsion Technology, 2017, 38(6): 185-191. (in Chinese)
- [12] 陈昭明, 邹劲松, 王伟, 等. 改进粒子群神经网络融合有限元分析的铸锻双控动态成型多目标优化[EB/OL]. [2021-04-29]. <https://doi.org/10.13229/j.cnki.jdxbgxb20210108>.
- [13] 张震, 潘再平, 潘晓弘. 基于剪枝策略的骨干粒子群算法[J]. 控制与决策, 2015, 30(9): 1591-1596.
- ZHANG Zhen, PAN Zaiping, PAN Xiaohong. Pruning strategy based bare bones particle swarm optimization[J]. Control and Decision, 2015, 30(9): 1591-1596. (in Chinese)
- [14] 张震, 潘再平, 潘晓弘. 骨干粒子群算法两种不同实现的优化特性[J]. 浙江大学学报(工学版), 2015, 49(7): 1350-1357.
- ZHANG Zhen, PAN Zaiping, PAN Xiaohong. Different implementations of bare bones particle swarm optimization[J]. Journal of Zhejiang University (Engineering Science), 2015, 49(7): 1350-1357. (in Chinese)
- [15] KENNEDY J. Bare bones particle swarms[C]//Proceedings of the Swarm Intelligence Symposium. Indianapolis, US: IEEE, 2003: 80-87.
- [16] SUN Jun, FANG Wei, WU Xiaojun, et al. Quantum-behaved particle swarm optimization: analysis of individual particle behavior and parameter selection[J]. Evolutionary Computation, 2012, 20(3): 349-393.
- [17] ZHANG Yong, GONG Dunwei, SUN Xiaoyan, et al. Adaptive bare-bones particle swarm optimization algorithm and its convergence analysis[J]. Soft Computing, 2014, 18(7): 1337-1352.
- [18] 王东风, 孟丽, 赵文杰. 基于自适应搜索中心的骨干粒子群算法[J]. 计算机学报, 2016, 39(12): 2652-2667.
- WANG Dongfeng, MENG Li, ZHAO Wenjie. Improved bare bones particle swarm optimization with adaptive search center[J]. Chinese Journal of Computers, 2016, 39(12): 2652-2667. (in Chinese)
- [19] 陈健. 改进的骨干粒子群优化算法及应用研究[D]. 安徽: 马鞍山: 安徽工业大学, 2017.
- CHEN Jian. Improved bare bones particle swarm optimization algorithm and its application[D]. Ma'an Shan Anhui: Anhui University of Technology, 2017. (in Chinese)
- [20] 龙远, 邓小龙, 杨希祥, 等. 基于 PSO-BP 神经网络的平流层风场短期快速预测[EB/OL]. [2021-04-29]. <https://doi.org/10.13700/j.bh.1001-5965.2021.0068>.
- [21] 徐丽娜. 神经网络控制[M]. 北京: 电子工业出版社, 2009.
- [22] 黄璇, 郭立红, 李姜, 等. 改进粒子群优化 BP 神经网络的目标威胁估计[J]. 吉林大学学报(工学版), 2017, 47(3): 996-1002.
- HUANG Xuan, GUO Lihong, LI Jiang, et al. Target threat assessment based on BP neural network optimized by modified particle swarm optimization[J]. Journal of Jilin University (Engineering and Technology Edition), 2017, 47(3): 996-1002. (in Chinese)

(编辑: 陈 越)