

基于樽海鞘群极限学习机的进/发一体化性能 寻优控制模型研究*

于子洋¹, 王晨¹, 杜宪¹, 聂聆聪², 孙希明¹

(1. 大连理工大学 控制科学与工程学院, 辽宁 大连 116024;

2. 北京动力机械研究所, 北京 100074)

摘要: 为充分发挥航空推进系统的性能, 提高性能寻优控制的实时性, 将樽海鞘群算法 (SSA) 与极限学习机 (ELM) 相结合, 基于进/发一体化部件级模型建立数据集, 提出一种基于 SSA-ELM 的数据驱动模型。将该建模方法与广义回归神经网络 (GRNN)、BP 神经网络 (BPNN) 和极限学习机 (ELM) 比较, 结果表明, 相比于 BPNN, ELM, GRNN, SSA-ELM 用于预测可以使安装推力的均方根误差 (RMSE) 分别降低 7.41%, 17.01%, 72.57%, 安装油耗的 RMSE 分别降低 4.32%, 19.41%, 66.77%, 具有更高的预测精度。将基于 SSA-ELM 的数据驱动模型作为机载模型应用到性能寻优控制, 结果表明, 该机载模型能够维持理想的寻优效果。针对最大安装推力模式开展实时性分析, 该机载模型相比于进/发一体化部件级模型, 平均计算时间由 184.05 ms 缩短至 1.357 ms, 实时性得到显著改善, 大大提高了寻优效率。

关键词: 航空发动机; 进/发一体化; 樽海鞘群优化算法; 极限学习机; 数据驱动模型; 性能寻优控制

中图分类号: V233.7 **文献标识码:** A **文章编号:** 1001-4055 (2024) 05-2302042-14

DOI: 10.13675/j.cnki.tjjs.2302042

1 引言

随着航空航天技术的发展, 飞机和发动机之间的耦合关系变得越来越紧密, 其中进气道与发动机的良好匹配关系, 可以让航空发动机安全、稳定、高效的工作, 对超声速工况下的推进系统整体性能起着重要的影响, 传统的控制系统无法充分发挥其性能潜力^[1-2]。美国国家航空航天局于 20 世纪 90 年代提出了性能寻优控制 (Performance Seeking Control, PSC)^[3-4], 其主要思想就是在不越过发动机运行边界的条件下, 寻找最佳的一组控制变量, 使某种性能达到最优, 主要包括最大推力、最小油耗以及最低涡轮温度三种模式, 进而充分发掘发动机的潜在性能。由于超声速工况下航空推进系统的进发匹配问题更

为显著, 优化潜力更大, 因此对进气道/发动机一体化系统安装性能寻优必要性更强。

航空发动机的性能寻优控制对控制系统的实时性和精度提出较高的要求。实现在线性能寻优控制有两个关键因素: 机载模型和优化算法, 现阶段的研究多集中在优化算法本身, 对 PSC 机载模型的实时性和精度影响研究较少, 性能寻优控制用模型更多地采用了传统部件级模型 (Component-Level Model, CLM)。李岩等^[5]采用自适应循环发动机部件级模型进行性能寻优控制研究, 提出了深度确定性策略梯度算法 (DDPG) 并将其应用于寻找最小耗油率。李勇等^[6]以双转子混合排气加力式涡扇发动机非线性数学模型为研究对象, 提出了一种基于遗传算法与序列二次规划混合优化算法 (GA-SQP), 完成了最小

* 收稿日期: 2023-02-21; 修订日期: 2023-06-21。

基金项目: 国家自然科学基金 (61890921; 61890924); 国家科技重大专项 (J2019-I-0019-0018); 中央高校基本科研业务费 (DUT22QN204)。

作者简介: 于子洋, 硕士生, 研究领域为航空发动机控制。

通讯作者: 杜宪, 博士, 副教授, 研究领域为航空发动机控制系统设计及应用。E-mail: duxian@dlut.edu.cn

引用格式: 于子洋, 王晨, 杜宪, 等. 基于樽海鞘群极限学习机的进/发一体化性能寻优控制模型研究[J]. 推进技术, 2024, 45(5): 2302042. (YU Z Y, WANG C, DU X, et al. An integrated inlet/engine performance seeking control model based on salp swarm algorithm extreme learning machine[J]. Journal of Propulsion Technology, 2024, 45(5): 2302042.)

油耗模式的性能寻优控制研究。然而部件级模型的建立涉及燃烧、热力、控制等众多学科知识,需要深入了解模型机理及其内部交互,建模过程复杂,计算速度较慢,直接将其用作实时优化的机载模型,大部分优化计算时间会消耗在部件级模型反复迭代中。近年来,数据驱动模型(Data-Driven Model, DDM)受到了国内外学者越来越多的关注,它不需要详细的和物理上有意义的数学模型,主要依赖于部件级模型的历史数据。其中,神经网络以其强大的非线性映射关系的能力,成为应用最广泛的方法。Tayarani-Bathaie等^[7]分别使用动态神经网络和时滞神经网络捕捉航空发动机可测变量之间的动态关系,完成了故障检测和隔离任务。Kim等^[8]采用具有径向基函数(RBF)的人工神经网络(ANN)生成数据驱动模型,用于预测航空发动机在过渡运行过程中的性能。Zheng等^[9-10]将深度神经网络模型作为机载模型开展性能寻优控制研究,对比了不同优化算法的寻优效果。

目前基于神经网络的数据驱动模型还存在一些问题。传统的神经网络采用梯度下降的学习方法,训练过程中容易陷入局部极小值,导致精度下降,泛化能力变差。对于深度学习网络,它们更依赖于样本的数量,往往需要大量的样本来提高模型的精度。Huang等^[11-12]开发了一种新型极限学习机(Extreme Learning Machine, ELM),它不仅计算量小,而且比传统的支持向量机和神经网络具有更快的学习速度和更好的泛化性能,对网络的终止条件、学习速度等参数也没有要求。考虑到这些特点,ELM近年来被广泛地用于数据驱动模型的建立^[13-14]。然而,尽管ELM有了许多成功的应用,但由于其输入权重的随机产生机制和隐含层偏差,有时会导致结果不稳定。因此,有必要引入一些有效的技术和工具来提高单一ELM的泛化性能。一种方式是采用改进的ELM, Zhou等^[15]利用选择性更新正则化在线顺序极限学习机(SROS-ELM)建立了在线模型并估计了传感器测量值。Lu等^[16]提出了一种使用稀疏贝叶斯极限学习机(SBELM)进行发动机故障诊断的新型数据驱动的诊断方法。Zhao等^[17]提出了一种鲁棒极限学习机,并将其应用于某小型涡喷发动机的建模,获得了良好的鲁棒性和泛化性能。另一种方式是采用智能优化算法优化ELM参数, Chen等^[18]采用回溯搜索算法(BSA)优化ELM参数,建立了改进的ELM短期洪水预报模型。Wen^[19]提出了一种基于蚁群优化算法(ACO)和极限学习机网络的多变量发电机实际输出

功率预测模型。

Mirjalili等^[20]于2017年提出樽海鞘群算法(Salp Swarm Algorithm, SSA),该算法具有结构简单、参数少和易操作等优势。SSA模拟了樽海鞘链的群体行为,是一种较新颖的群智能优化算法。每次迭代过程中,领导者进行全局探索,以一种链式行为向食物移动,并且指导追随者,追随者则充分进行局部探索,这样一来大大减少了陷入局部最优的情况。由此可见,SSA具有良好的局部搜索能力和全局搜索能力,目前已经广泛应用于各类工程问题。

为了满足在线性能寻优控制用模型的实时性和精度,本研究提出一种SSA-ELM混合方法,并基于此方法建立了数据驱动模型。在提出的SSA-ELM模型中,利用SSA优化ELM控制参数,寻找最小的均方根误差(RMSE),进一步提高了单一ELM的稳健性。将模型得到的安装推力和安装油耗的预测结果与广义回归神经网络(GRNN)、BP神经网络(BPNN)和极限学习机(ELM)三种基准建模方法进行了比较。最后,在性能寻优控制模式下完成了数值仿真验证并与超声速进气道/发动机一体化部件级模型的寻优效果和计算时间做对比,突出所建立模型实时性的优势。

2 基于SSA-ELM的数据驱动模型

2.1 进/发一体化部件级模型

数据驱动模型依赖于进/发一体化部件级模型的历史数据,因此首先要建立部件级模型。部件法建模,即根据部件的特性图和气动热力学关系建立多部件模型。本文建立了超声速状态的进气道/发动机一体化非线性部件级模型,其主要部件包括可变几何进气道、风扇、高压压气机、燃烧室、高压涡轮、低压涡轮、混合室、加力燃烧室和尾喷管。模型计算流程图如图1所示,根据给定的飞行条件(高度 H ,飞行马赫数 Ma),进气道控制参数(进气道相对放气量 α_{t_1} ,第一级斜板角度 δ_1 ,第二级斜板角度 δ_2)以及发动机控制参数(主燃油流量 W_{m_1} ,加力燃油流量 W_{f_1} ,风扇导叶角 α_f ,压气机导叶角 α_c ,尾喷管出口面积 A_8),按照图1中所示的顺序依次进行计算。

为了实现进气道/发动机匹配,以进气流量和风扇流量的残差作为平衡方程,进气道流量系数与总压恢复系数之比(Φ/σ)作为迭代的初始猜测。部件级模型计算达到稳定,需满足式(1)所示的8个平衡方程。

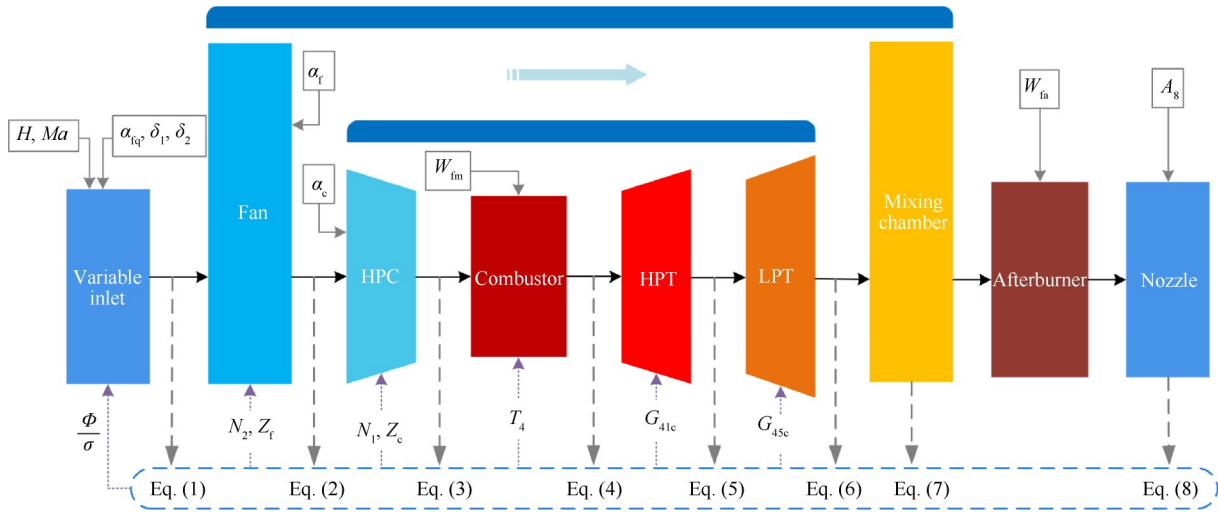


Fig. 1 Calculation flow chart of integrated inlet/engine component-level model

$$\begin{cases}
 f_1(\mathbf{x}) = W_{inlet} - W_{fan,f} = e_1 \\
 f_2(\mathbf{x}) = W_{fan,a} - W_{HPC,f} = e_2 \\
 f_3(\mathbf{x}) = I_H \cdot N_2 \cdot \frac{dN_2}{dt} - L_{HPT} + L_{HPC} - L_{add} = e_3 \\
 f_4(\mathbf{x}) = W_{comb,a} - W_{HPT,f} = e_4 \\
 f_5(\mathbf{x}) = W_{HPT,a} - W_{LPT,f} = e_5 \\
 f_6(\mathbf{x}) = I_L \cdot N_1 \cdot \frac{dN_1}{dt} - L_{LPT} + L_{fan} = e_6 \\
 f_7(\mathbf{x}) = p_6 - p_{16} = e_7 \\
 f_8(\mathbf{x}) = p_8 - p_{nozzle} = e_8
 \end{cases} \quad (1)$$

式(1)中涉及到的变量名称如表 1 所示。 $f_1(\mathbf{x}) \sim f_8(\mathbf{x})$ 分别对应图 1 中的平衡方程 Eq.(1)~Eq.(8)。其中 $\mathbf{x} = [x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8]^T$ 表示迭代过程中需要独立赋值的变量,具体表达如式(2)所示。

$$\mathbf{x} = [x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8]^T = \left[\frac{\Phi}{\sigma}, N_2, Z_f, N_1, Z_c, T_4, G_{41c}, G_{45c} \right]^T \quad (2)$$

式中 Z_f, Z_c 分别表示风扇相对压比系数和压气机相对压比系数, T_4 是燃烧室温度, G_{41c}, G_{45c} 是特性内插的初始猜测。

选定初猜值后进行迭代计算,直至误差 $e_1 \sim e_8$ 小于某一设定数值 ε (ε 通常取 1×10^{-6}),即可认为模型达到收敛状态,计算完毕。

2.2 极限学习机

单隐含层前馈神经网络 (Single-hidden Layer Feedforward Neural Network, SLFN) 以其良好的学习能力在许多领域得到了广泛的应用。传统的学习算法大多采用梯度下降法,该方法具有训练速度慢、易陷入局部极小点、对学习率的选择敏感等缺点。本节将介绍一个针对 SLFN 的新算法——极限学习机,它包括输入层、隐藏层和输出层,结构如图 2 所示。

Table 1 Variables and their names

Variables	Name of variables
W_{inlet}	Inlet outlet flow
$W_{fan,f}, W_{fan,a}$	Fan inlet/outlet flow
$W_{HPC,f}$	Compressor inlet flow
$W_{comb,f}, W_{comb,a}$	Main combustion chamber inlet/outlet flow
$W_{HPT,f}, W_{HPT,a}$	High-pressure turbine inlet/outlet flow
$W_{LPT,f}$	Low-pressure turbine inlet flow
I_H, I_L	Rotational inertia of high/low-pressure rotor
L_{HPT}, L_{LPT}	Power of HPT and LPT
L_{HPC}, L_{fan}	Power of HPC and fan
L_{add}	Additional power of engine starting
N_1, N_2	High/low-pressure rotor speed
p_6, p_{16}	Inner/outer duct outlet static pressure
p_8, p_{nozzle}	Total pressure before/after the nozzle

隐藏层的权重和偏置向量是随机生成的,而且在训练过程中无需调整。因此在训练网络之前设置一个隐藏层神经元的个数,便可以得到唯一的最优解。与传统的训练方法相比,该方法具有学习速度快,泛化性能好等优点。




Fig. 2 Structure of ELM

设具有 Q 个样本的训练集输入矩阵 X 和输出矩阵 Y 分别为

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1Q} \\ x_{21} & x_{22} & \cdots & x_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nQ} \end{bmatrix}_{n \times Q} \quad (3)$$

$$Y = \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1Q} \\ y_{21} & y_{22} & \cdots & y_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ y_{m1} & y_{m2} & \cdots & y_{mQ} \end{bmatrix}_{m \times Q} \quad (4)$$

设隐藏层神经元的激活函数为 $g(x)$, 则由图2可得, 网络的输出 T 为

$$T = [t_1, t_2, \dots, t_Q]_{m \times Q}$$

$$t_j = \begin{bmatrix} t_{1j} \\ t_{2j} \\ \vdots \\ t_{mj} \end{bmatrix}_{m \times 1} = \begin{bmatrix} \sum_{i=1}^l \beta_{i1} g(\omega_i x_j + b_i) \\ \sum_{i=1}^l \beta_{i2} g(\omega_i x_j + b_i) \\ \vdots \\ \sum_{i=1}^l \beta_{im} g(\omega_i x_j + b_i) \end{bmatrix}_{m \times 1} \quad (5)$$

式中 $j=1, 2, \dots, Q$; $x_j = [x_{1j}, x_{2j}, \dots, x_{nj}]^T$; $\omega_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{in}]$ 。

式(5)可以表示为

$$H\beta = T' \quad (6)$$

式中 H 称为神经网络的隐藏层输出矩阵, 具体形式如下, 即

$$H = \begin{bmatrix} g(\omega_1 x_1 + b_1) & \cdots & g(\omega_l x_1 + b_l) \\ g(\omega_1 x_2 + b_1) & \cdots & g(\omega_l x_2 + b_l) \\ \vdots & \ddots & \vdots \\ g(\omega_1 x_Q + b_1) & \cdots & g(\omega_l x_Q + b_l) \end{bmatrix}_{Q \times l} \quad (7)$$

SLFN 的训练误差可以逼近一个任意 $\varepsilon > 0$, 即

$$\sum_{j=1}^Q \|t_j - y_j\| < \varepsilon \quad (8)$$

因此, 当激活函数 $g(x)$ 无限可微时, SLFN 的参数并不需要全部进行调整, ω 和 b 在训练前可以随机选择, 且在训练过程中保持不变。而隐藏层与输出层之间的连接权值 β 可以通过求解以下方程组的最小二乘解获得

$$\min_{\beta} \|H\beta - T'\| \quad (9)$$

其解为

$$\hat{\beta} = H^+ T' \quad (10)$$

式中 H^+ 为隐藏层输出矩阵 H 的 Moore-Penrose 广义逆。

2.3 基于樽海鞘群算法的极限学习机改进

尽管 ELM 近年来有了很广泛的应用, 但也存在

一些不足。由于 ELM 的输入层权值是随机给定的, 有时会导致结果不稳定。增加隐含层的节点数会提高预测精度, 但也会导致网络结构变得复杂, 占用更多的系统资源。为了提高 ELM 的精度稳定性, 本文利用 SSA 优化 ELM 输入层至隐含层的权值和偏置, 形成 SSA-ELM 方法。

樽海鞘, 体透明, 呈桶状, 是一种海洋无脊椎动物, 如图 3(a) 所示。在深海中, 樽海鞘经常形成一个称为樽海鞘链的群体, 如图 3(b) 所示。为了对樽海鞘进行数学建模, 首先将种群分为两个组: 领导者和追随者。领导者是链中处在前面的樽海鞘, 其余为追随者。




Fig. 3 Shape of salps

通过式(11)来更新领导者的位置, 即

$$x_j^1 = \begin{cases} F_j + c_1((u_j - l_j)c_2 + l_j), & c_3 \geq 0 \\ F_j - c_1((u_j - l_j)c_2 + l_j), & c_3 < 0 \end{cases} \quad (11)$$

式中 x_j^1 表示第一个樽海鞘(领导者)在第 j 维的位置, F_j 代表食物源在第 j 维的位置, u_j 和 l_j 分别是第 j 维的上界和下界, c_1, c_2 和 c_3 均为随机数。

式(11)表明领导者仅更新与食物源的相对位置, 系数 c_1 是 SSA 中最重要的参数, 因为它用于平衡探索和利用。

$$c_1 = 2e^{-\left(\frac{4n}{L}\right)^2} \quad (12)$$

式中 n 为当前迭代次数, L 为最大迭代次数。

追随者的位置由式(13)进行更新为

$$x_j^i = \frac{1}{2}at^2 + v_0t \quad (13)$$

式中 $i \geq 2$, x_j^i 表示第 i 个樽海鞘(追随者)在第 j 维上的位置, t 为时间, v_0 为初始速度, a 为加速度。由于在优化中时间就是迭代次数, 所以迭代时间的差就是 1, 考虑到 $v_0=0$, 上式可以表达为

$$x_j^i = \frac{1}{2}(x_j^i + x_j^{i-1}) \quad (14)$$

SSA 流程图如图 4 所示。利用樽海鞘群算法搜

寻到的最佳个体,即输入层至隐含层的权值和偏置,对极限学习机进行优化,实现流程如图 5 所示。该方法主要包括数据预处理,训练优化和预测评估三个阶段,具体步骤如下:

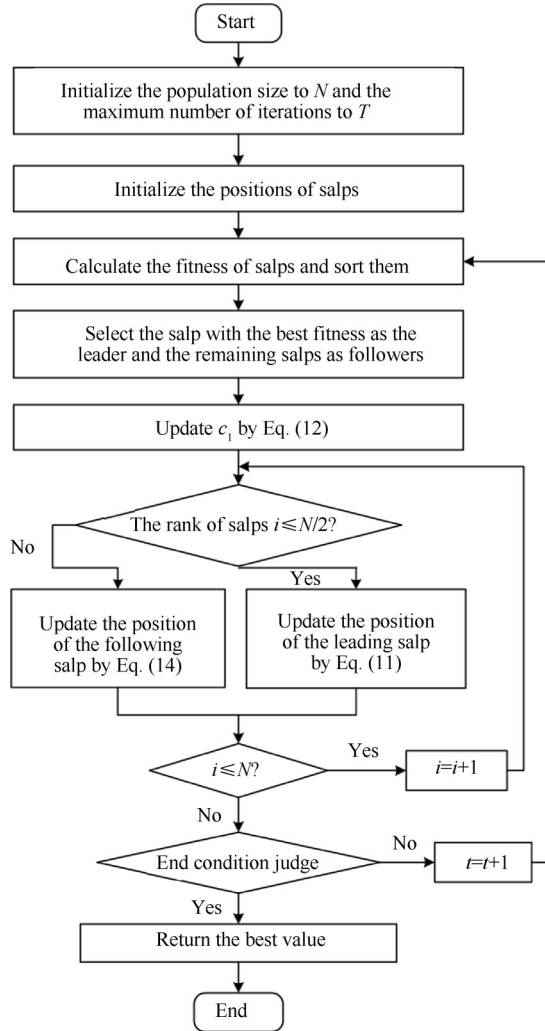


Fig. 4 Flowchart of SSA

(1) 收集进/发一体化部件级模型数据,数据获取方法在 3.1 节中介绍,数据集输入输出变量如式 (15), (16) 所示,即

$$\mathbf{x} = [W_{fm}, W_{fa}, A_8, \alpha_{fq}, \delta_1, \delta_2, \alpha_f, \alpha_c, H, Ma]^T \quad (15)$$

$$\mathbf{y} = [F_{THR,i}, S_{FC,i}]^T \quad (16)$$

式中输入变量 \mathbf{x} 包括主燃油流量 W_{fm} , 加力燃油流量 W_{fa} , 尾喷管出口面积 A_8 , 进气道相对放气量 α_{fq} , 第一级斜板角度 δ_1 , 第二级斜板角度 δ_2 , 风扇导叶角 α_f , 压气机导叶角 α_c , 高度 H , 马赫数 Ma ; 输出变量 \mathbf{y} 包括安装推力 $F_{THR,i}$ 和安装油耗 $S_{FC,i}$ 。

(2) 将收集到的发动机数据分为训练集和测试集两部分,并进行归一化处理。

(3) 初始化 SSA 和 ELM 参数,包括种群数量,最大

迭代次数,ELM 输入层、隐含层、输出层的节点数,种群中的每个个体包括输入层至隐含层的权值和偏置。

(4) 为了使误差最小,采用训练集均方根误差 (RMSE) 作为 SSA 适应度函数。

(5) 初始化种群中的每个樽海鞘个体位置,形成初代种群。

(6) 计算每个个体适应度值并按照从小到大的顺序排序,选取排名前 50% 的个体作为领导者,其余作为追随者。

(7) 根据式 (12) 更新 c_1 , 领导者和追随者的位置分别由式 (11) 和式 (14) 更新。

(8) 根据更新后樽海鞘个体的位置,计算适应度,更新最优个体的位置 $Best_pos$ 和适应度 $Best_score$ 。

(9) 检查是否满足迭代终止条件,即当前迭代次数是否达到最大迭代次数,若满足则进行第 (10) 步,否则转第 (6) 步继续。

(10) 得到的最优樽海鞘个体的位置 $Best_pos$, 即为 ELM 模型最优输入层到隐含层的权值和偏置,将其带入 ELM 模型对输入变量进行预测,得到安装推力和安装油耗预测值,并对得到结果进行反归一化处理。

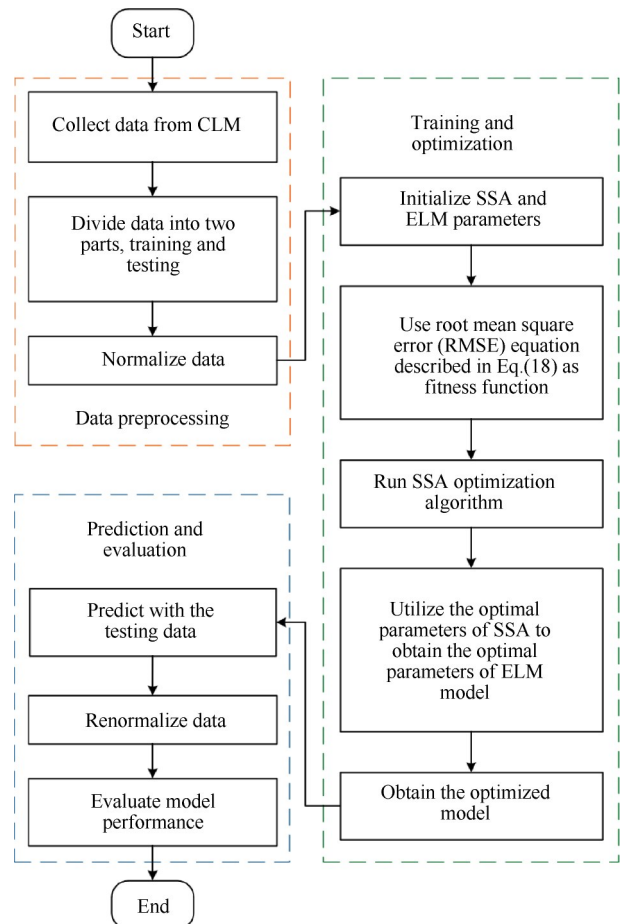


Fig. 5 Flowchart of the hybrid method (SSA-ELM)

(11)为了验证SSA-ELM模型的有效性,将提出的混合模型与GRNN,BPNN和ELM模型进行比较,使用决定系数(R^2)、均方根误差(RMSE)和平均绝对误差(MAE)对上述模型的性能进行评估,并将结果绘制成散点图和柱状图。

2.4 模型评价指标

平均绝对误差(Mean Absolute Error, MAE)即绝对误差的平均值,能更好地反映误差的实际情况。均方根误差(Root Mean Square Error, RMSE)是预测值与真实值偏差的平方和与测试集样本数量 m 比值的平方根,用来衡量预测值和真实值之间的偏差。RMSE相当于L2范数,MAE相当于L1范数,次数越高,计算结果受偏差较大值影响越大,因此RMSE对异常值更加敏感。决定系数(R^2)用来描述预测值和真实值之间的相关性。它们的表达式如(17)~(19)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_{i,\text{real}} - y_{i,\text{sim}})^2}{\sum_{i=1}^m (y_{i,\text{real}} - \bar{y}_{\text{real}})^2} \quad (17)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^m (y_{i,\text{sim}} - y_{i,\text{real}})^2}{m}} \quad (18)$$

$$\text{MAE} = \frac{\sum_{i=1}^m |y_{i,\text{sim}} - y_{i,\text{real}}|}{m} \quad (19)$$

式中 \bar{y}_{real} 为所有测试集样本真实值的平均, $y_{i,\text{real}}, y_{i,\text{sim}}$ 分别代表测试集第 i 个样本真实值和预测值, m 表示测试集样本数量。

3 模型仿真结果与分析

3.1 数据描述

发动机数据是验证数据驱动模型有效性的重要依据。考虑到实际真实发动机的数据获取难度大,成本高,特别是在大的飞行包线内,因此开发了一种发动机数据生成方案来获得足够的发动机数据。本文使用的进/发一体化部件级模型飞行包线如图6所示。

本研究的重点在模型进发匹配的优化问题,因此根据本文建立的进/发一体化部件级模型,选择在典型超声速工况范围内生成发动机数据。在包线范围内设置高度取值为9~13 km,马赫数取值为1.2~2。结合实际需求并提高数据驱动模型的精度,输入变量需要被限制在合理的范围内,取值范围如表2所示。其中 D_1, D_2, D_3, D_4 分别为风扇流量、风扇效率、压气机流量和压气机效率的退化量。在各变量对应的区间范围内随机取值,并带入进/发一体化部件级模




Fig. 6 Flight envelope

Table 2 Input variables and value range

Input variables	Value range
$W_{\text{in}}/(\text{kg/s})$	[1, 1.3]
$W_{\text{in}}/(\text{kg/s})$	[4, 5]
A_8/m^2	[0.55, 0.676]
α_{f_1}	[-0.1, 0.2]
$\delta_1, \delta_2/(\text{°})$	[2, 6]
$\alpha_f, \alpha_r/(\text{°})$	[10, 20]
$D_1, D_2, D_3, D_4/\%$	[0, 5]

型计算安装推力和安装油耗的稳态值,一共产生112572组数据。

3.2 仿真分析

为了证明SSA-ELM的有效性,其他网络如广义回归神经网络(GRNN)、BP神经网络(BPNN)以及极限学习机(ELM)也被采用来做同样的试验,并与SSA-ELM进行比较。

图7和图8分别给出了不同模型在测试数据集中的安装推力 $F_{\text{THR},i}$ 和安装油耗 $S_{\text{FC},i}$ 的预测结果。表3和表4给出了在测试数据集中,不同模型预测 $F_{\text{THR},i}$ 和 $S_{\text{FC},i}$ 的 R^2 ,MAE和RMSE具体数值。从表3和表4来看,对于 $F_{\text{THR},i}$ 和 $S_{\text{FC},i}$ 的 R^2 ,SSA-ELM>BPNN>ELM>GRNN,采用SSA-ELM模型,测试集输出 $F_{\text{THR},i}$ 的 R^2 由低到高分别提高0.08%,0.23%,6.68%,测试集输出 $S_{\text{FC},i}$ 的 R^2 由低到高分别提高0.11%,0.62%,10.11%;对于 $F_{\text{THR},i}$ 和 $S_{\text{FC},i}$ 的MAE和RMSE,SSA-ELM<BPNN<ELM<GRNN,采用SSA-ELM模型,测试集输出 $F_{\text{THR},i}$ 的MAE由低到高分别降低10.24%,20.22%,74.40%,RMSE由低到高分别降低7.41%,17.01%,72.57%;测试集输出 $S_{\text{FC},i}$ 的MAE由低到高分别降低6.39%,21.81%,67.54%,RMSE由低到高分别降低4.32%,19.41%,66.77%。根据计算得到的评价指标可以得出,采用SSA-ELM进行预测, R^2 更接近于1,MAE和RMSE更小,表现出了更为优越的精度。

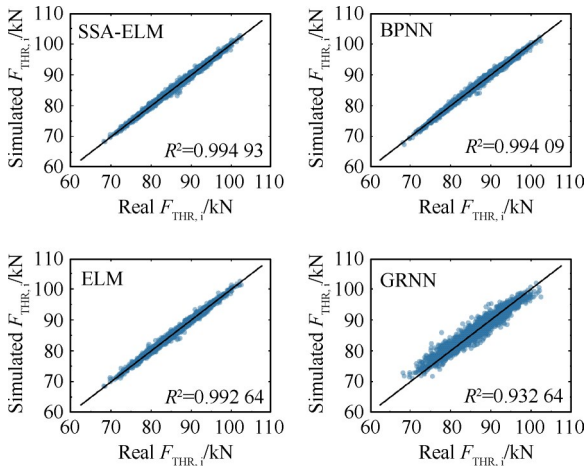


Fig. 7 Scatter plots of real and simulated values of $F_{THR,i}$ for different models




Fig. 8 Scatter plots of real and simulated values of $S_{FC,i}$ for different models

Table 3 Evaluation indicators of $F_{THR,i}$

Item	R^2	MAE/kN	RMSE/kN
BPNN	0.994 09	0.333 96	0.454 75
GRNN	0.932 64	1.170 70	1.535 20
ELM	0.992 64	0.375 70	0.507 35
SSA-ELM	0.994 93	0.299 73	0.421 05

Table 4 Evaluation indicators of $S_{FC,i}$

Item	R^2	MAE/ (kg/(daN·h))	RMSE/ (kg/(daN·h))
BPNN	0.987 69	0.008 674 3	0.011 865
GRNN	0.897 94	0.025 011 0	0.034 164
ELM	0.982 65	0.010 385 0	0.014 087
SSA-ELM	0.988 73	0.008 119 6	0.011 353

3.3 考虑退化因子的仿真分析

随着在役时间的增加,发动机不可避免地会发生性能退化,导致推进系统状态参数与真实发动机

存在偏差量。发动机性能退化通常用效率因子和流量因子来进行表征。以超声速巡航状态下的发动机退化为例进行研究,验证基于 SSA-ELM 的数据驱动模型能否进行退化后性能的预测。

将 D_1, D_2, D_3, D_4 在 0~5% 内随机取值,加入到输入变量中,重复 2.3 节建模步骤。 $F_{THR,i}$ 和 $S_{FC,i}$ 的预测结果如图 9,10 所示。




Fig. 9 Scatter plots of real and simulated values of $F_{THR,i}$ for different models(with degradation)

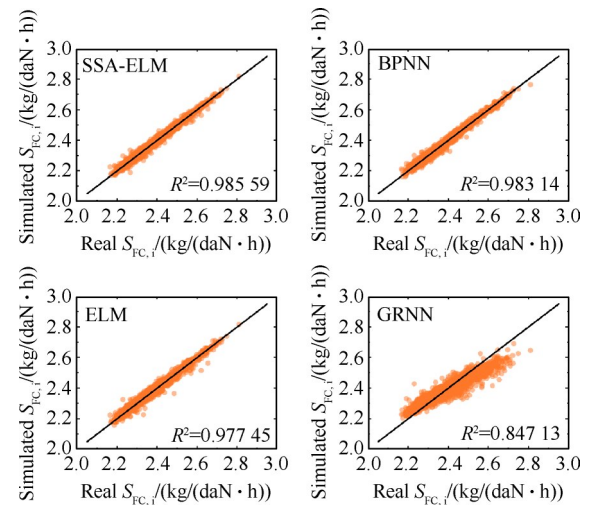


Fig. 10 Scatter plots of real and simulated values of $S_{FC,i}$ for different models(with degradation)

可以看出基于 SSA-ELM 的数据驱动模型在考虑退化因子的情况下预测精度虽然有所下降,但预测 $F_{THR,i}$ 的 R^2 仍大于 0.993,预测 $S_{FC,i}$ 的 R^2 仍大于 0.985。为验证退化因子是否引起该模型的性能下降,引入 $Ma=1.5, H=9.96$ km 和 $Ma=1.2, H=9.91$ km 两个超声速工况,分别验证 $F_{THR,i}$ 和 $S_{FC,i}$ 与 D_1, D_2, D_3, D_4 各自的关系,仿真结果如图 11 所示。图中橙色线代表安装推力的变化,数值由左轴表示;蓝色线代表安装油耗的变化,数值由右轴表示。可以看出,在 D_1, D_2, D_3, D_4 各

自单独作用下,随着退化因子值的升高,安装推力逐渐降低,安装油耗逐渐上升,发动机性能有所下降,进一步验证了该模型的可靠性。

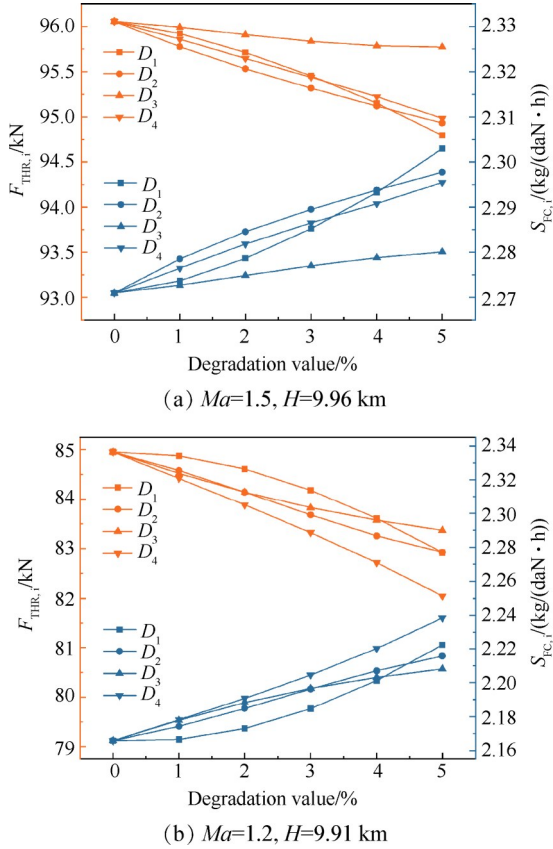


Fig. 11 Effects of degradation factors on SSA-ELM-based model

图 12 给出了在测试数据集中 BPNN, GRNN, ELM 和 SSA-ELM 预测 $F_{THR,i}$ 和 $S_{FC,i}$ 的 MAE 和 RMSE 柱状图,包含考虑退化和未考虑退化两种情况。表 5 和表 6 给出了模型输入变量加入退化因子的情况下,在测试数据集中,不同模型预测 $F_{THR,i}$ 和 $S_{FC,i}$ 的 R^2 , MAE 和 RMSE 具体数值。

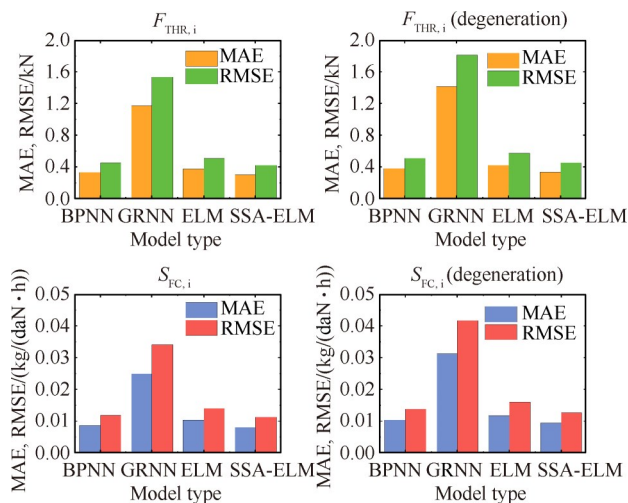


Fig. 12 MAE and RMSE of different models

Table 5 Evaluation indicators of $F_{THR,i}$ with degradation

Item	R^2	MAE/kN	RMSE/kN
BPNN	0.991 98	0.381 05	0.509 64
GRNN	0.898 77	1.416 10	1.810 70
ELM	0.989 79	0.424 29	0.575 06
SSA-ELM	0.993 55	0.335 69	0.457 06

Table 6 Evaluation indicators of $S_{FC,i}$ with degradation

Item	R^2	MAE/(kg/(daN·h))	RMSE/(kg/(daN·h))
BPNN	0.983 14	0.010 47	0.013 87
GRNN	0.847 13	0.031 26	0.041 75
ELM	0.977 45	0.011 83	0.016 04
SSA-ELM	0.985 59	0.009 44	0.012 82

4 性能寻优控制仿真分析

4.1 性能寻优控制原理

PSC 控制结构如图 13 所示。PSC 控制系统主要由发动机控制系统、进气道控制系统、PSC 计算模块和非线性转换模块组成。超声速状态下的性能寻优控制开始时,航空推进系统处于准稳态工作状态。推进系统收到优化指令,此时 PSC 计算模块通过优化算法基于机载模型进行寻优计算,得到优化控制量。为保证推进系统的稳定运行,得到的优化控制量并非直接输入到航空发动机中,而是输入到非线性转换模块。非线性转换模块为相应机载模型,根据优化后的控制量反算出高压转子转速(N_2)以及增压比(η_k),然后将优化前后输出量的变化值作为控制器的校正指令传回发动机闭环系统。进气道和导叶是开环控制,直接输入发动机并不会影响系统的稳定性,控制系统直接根据进气道和导叶优化控制指令增量($\Delta\alpha_{iq}, \Delta\delta_1, \Delta\delta_2, \Delta\alpha_f, \Delta\alpha_c$)通过控制器及执行机构调节进气道和导叶。由此可见,航空推进系统性能寻优控制的最终形式是一个动态的响应过程。在本文的研究中,PSC 计算模块的优化算法采取樽海鞘群算法(SSA),机载模型采用基于 SSA-ELM 方法建立的数据驱动模型(SSA-ELM-DDM),部件级模型(CLM)作为对比算例,优化后的控制量均带入部件级模型进行验证。

本文选用的进/发一体化推进系统优化控制量用 u 表示,如式(20)所示。

$$u = [W_{im}, A_8, \alpha_{iq}, \delta_1, \delta_2, \alpha_f, \alpha_c]^T \quad (20)$$

发动机性能寻优过程中需要保证以下约束条件,即

$$M = \begin{cases} u_{\min} \leq u \leq u_{\max} \\ N_{1,\min} \leq N_1 \leq N_{1,\max} \\ N_{2,\min} \leq N_2 \leq N_{2,\max} \\ s_{mf,\min} \leq s_{mf} \leq s_{mf,\max} \\ s_{mf,\min} \leq s_{mf} \leq s_{mf,\max} \end{cases} \quad (21)$$

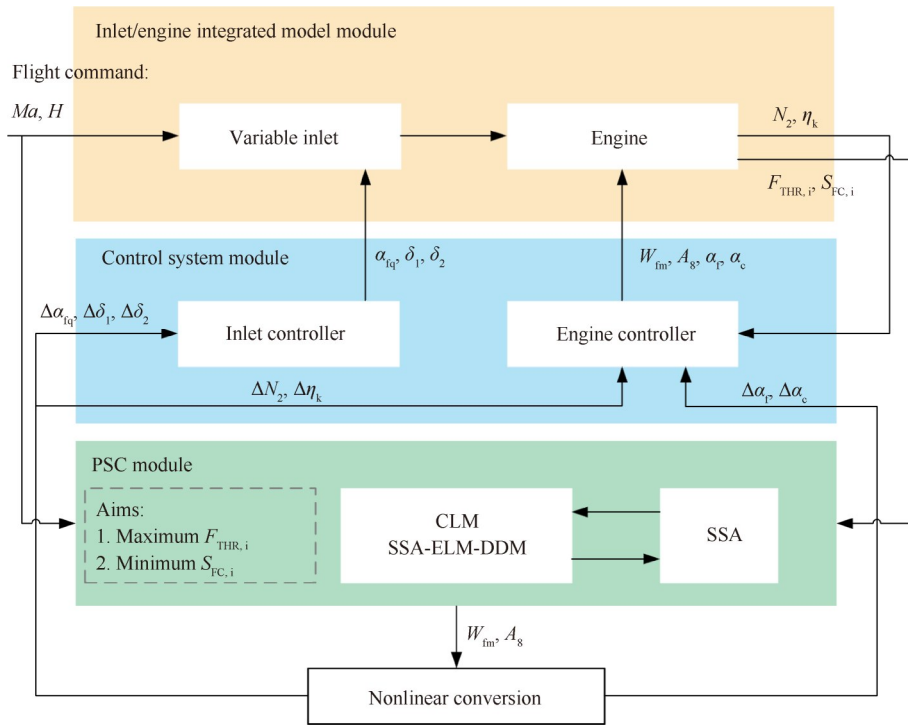


Fig. 13 Structure of PSC

式中 \mathbf{u} 为寻优控制变量, N_1, N_2 分别是低压转子转速和高压转子转速, s_{mf}, s_{mc} 分别是风扇喘振裕度和压气机喘振裕度。

最大安装推力模式是使飞机在超声速巡航状态提供尽可能大的安装推力, 从而保证其机动能力; 或者在加速、爬升条件下, 采用最大安装推力模式, 在保证发动机安全运行的前提下增大安装推力。最大安装推力控制模式的数学表达式如下

$$\begin{cases} \max_{\mathbf{u}} F_{THR,i} \\ \text{s.t. } \mathbf{u} \in M \end{cases} \quad (22)$$

在超声速巡航状态下, 采用最小安装油耗模式, 在给定的推力要求下尽量降低耗油率。其数学表达式如下

$$\begin{cases} \min_{\mathbf{u}} S_{FC,i} \\ \text{s.t. } \mathbf{u} \in M, F_{THR,i} = \text{const} \end{cases} \quad (23)$$

由于实际应用中安装推力不会保持恒定, 因此在本文的研究中波动不超过 1% 即可认为满足安装推力常值要求。

为了探索不同的机载模型在进发匹配综合性能寻优控制中的效果, 选取典型的超声速工况 $Ma=2.0$, $H=12.47 \text{ km}$, 进气道结构参数固定为长度 $L_1=0.9 \text{ m}$, 长度 $L_2=0.9 \text{ m}$, 高度 1.1 m , 宽度 1 m 。在该进气道条件下, 进气道工作在亚临界状态, 此时可以通过放气调节和斜板角度调节提升进气道总压恢复系数并降低溢流阻力, 提高推进系统的性能。下文将针对该

工况, 分别采用 CLM 和 SSA-ELM-DDM 作为机载模型对最大安装推力模式和最小安装油耗模式进行验证, 寻优变量取值范围如表 7 所示。由于安装推力的大小与燃油流量有直接的关系, 为降低燃油流量对安装推力的影响程度, 尽可能调节其余控制变量来获取发动机的最佳性能, 将主燃油流量 W_{im} 取值范围缩小至 $[1, 1.2]$, 其余控制变量取值范围同表 2。

Table 7 Control variables and value range


Input variables	Value range
$W_{im}/(\text{kg/s})$	$[1, 1.2]$
A_8/m^2	$[0.55, 0.676]$
α_{iq}	$[-0.1, 0.2]$
$\delta_1, \delta_2/(\text{°})$	$[2, 6]$
$\alpha_r, \alpha_c/(\text{°})$	$[10, 20]$

4.2 最大安装推力模式


最大安装推力控制模式寻优效果如图 14 和图 15 所示, 其中 (a), (b), (c) 分别表示优化目标变量、控制变量以及约束变量的变化趋势, F_{THR} 表示发动机推力。将 CLM 和 SSA-ELM-DDM 分别作为机载模型进行寻优, 然后将最优控制变量带入部件级模型进行验证。 $t=4 \text{ s}$ 时接入 PSC 模块, 可以看出, 为提升安装推力, 燃油流量增加至上限, 尾喷管出口面积降低。但控制量发生变化时需要保证发动机不超转、不喘振, 因此通过降低风扇和压气机导叶角使得发动机

安全稳定的工作,同时进气道斜板角度降低,提高了进发匹配效果,减小进气道阻力,进而获得更大的安装推力。 $t=7\text{ s}$ 趋于稳定,过渡过程结束。机载模型采用CLM时,安装推力提升了5.63%,推力提升了


5.11%;机载模型采用SSA-ELM-DDM时,安装推力提升了5.63%,推力提升了5.16%,二者结果相近。因此可采用SSA-ELM-DDM作为机载模型对发动机的最大安装推力进行寻优。



(a) Simulation of optimizing goal




(b) Simulation of controlled variables




(c) Simulation of constrained variables


Fig. 14 Maximum installed thrust control mode (Using CLM as on-board model)



(a) Simulation of optimizing goal



(b) Simulation of controlled variables




(c) Simulation of constrained variables

Fig. 15 Maximum installed thrust control mode (Using SSA-ELM-DDM as on-board model)


4.3 最小安装油耗模式

最小安装油耗控制模式寻优效果如图 16 和图 17 所示。其中(a),(b),(c)分别表示优化目标变量、控制变量以及约束变量的变化趋势, F_{THR} 表示发动机推


力, S_{FC} 表示发动机油耗。将 CLM 和 SSA-ELM-DDM 分别作为机载模型进行寻优, 然后将最优控制变量带入部件级模型进行验证。 $t=4$ s 时接入 PSC 模块, 可以看出, 为降低安装油耗, 燃油流量降低。燃油流




(a) Simulation of optimizing goal




(a) Simulation of optimizing goal




(b) Simulation of controlled variables



(b) Simulation of controlled variables



(c) Simulation of constrained variables



(c) Simulation of constrained variables

Fig. 16 Minimum installed fuel consumption control mode (Using CLM as on-board model)

Fig. 17 Minimum installed fuel consumption control mode (Using SSA-ELM-DDM as on-board model)

量的降低会导致安装推力下降,而最小安装油耗控制模式要求发动机的安装推力在小范围内变化并且不超转、不喘振,因此需要调节尾喷管出口面积、导叶角以及进气道斜板角度。斜板角度的调节可以有效改变喉口面积并调节进气溢流阻力,为了获取到最小的安装油耗,两级斜板角度可适当减小以匹配发动机流量需求的降低。图16显示的CLM结果,优化后进气道阻力略大,第一级斜板角从 4° 变化到 4.01° ,基本未变,因此进气道阻力优化效果略差,但其推力波动相对较小。图17采用本文设计的SSA-ELM-DDM方法,两级斜板角度降低幅度更大,优化后进气道阻力($F_{THR}-F_{THR,i}$)更小,安装油耗降低更明显,说明可调进气道较大范围的调节提升了进发匹配的优化效果,但也造成了优化初期推力的小幅度波动。 $t=7$ s趋于稳定,过渡过程结束。机载模型采用CLM时,安装油耗降低了1.48%,油耗降低了1.45%;采用SSA-ELM-DDM时,安装油耗降低了1.63%,油耗降低了1.29%,优化效果基本相近,因此可采用SSA-ELM-DDM作为机载模型对发动机的最小安装油耗进行寻优。

4.4 实时性分析

为充分体现SSA-ELM-DDM作为机载模型发挥实时性的优势,引入3.3节采用的 $Ma=1.5, H=9.96$ km和 $Ma=1.2, H=9.91$ km两个超声速工况,与原工况 $Ma=2.0, H=12.47$ km一起进行性能寻优控制实时性分析。

由于最大安装推力模式和最小安装油耗模式实时性分析方法类似,因此本节的实时性分析针对最大安装推力模式开展。对 $Ma=1.5, H=9.96$ km工况和 $Ma=1.2, H=9.91$ km工况进行与 $Ma=2.0, H=12.47$ km工况相同的操作,并且在每个工况下重复寻优3次,记录模型单次计算时间和程序运行时间,取平均值作为仿真结果,实时性对比如表8所示。仿真结果显示,三种工况下CLM模型平均每次计算时间分别为184.05 ms, 184.46 ms, 194.16 ms, SSA-ELM-DDM为1.357 ms, 1.376 ms, 1.350 ms; CLM程序运行时间分别为286.36 s, 286.62 s, 301.64 s, SSA-ELM-DDM为4.87 s, 4.91 s, 4.86 s。SSA-ELM-DDM作为性能寻优控制用机载模型,模型单次计算时间明显缩短,从而使程序运行时间缩短,可以更快地找到最优点,实时性得到显著改善。

Table 8 Comparison of real-time capability at three conditions

Condition	Average calculating time of model/ms		Program running time/s	
	CLM	SSA-ELM-DDM	CLM	SSA-ELM-DDM
$Ma=2.0$ $H=12.47$ km	184.77	1.358	287.91	4.87
	183.05	1.339	284.36	4.82
	184.34	1.374	286.82	4.91
Average value	184.05	1.357	286.36	4.87
$Ma=1.5$ $H=9.96$ km	184.48	1.364	286.81	4.89
	183.68	1.388	284.97	4.93
	185.22	1.375	288.09	4.92
Average value	184.46	1.376	286.62	4.91
$Ma=1.2$ $H=9.91$ km	194.31	1.351	301.85	4.85
	192.42	1.343	298.84	4.85
	195.75	1.355	304.23	4.88
Average value	194.16	1.350	301.64	4.86

5 结论

为满足在线性能寻优控制用模型的需求,本文提出一种基于樽海鞘群算法的极限学习机的数据驱动模型,并将其用于进/发一体化系统的性能寻优控制,结论如下:

(1) 本文开发了一种新兴的基于樽海鞘群算法的极限学习机方法(SSA-ELM),并依此方法建立了性能寻优控制用数据驱动模型。

(2) 相比于BPNN, ELM, GRNN, SSA-ELM模型预测安装推力的RMSE可以分别降低7.41%, 17.01%, 72.57%, 安装油耗的RMSE分别降低4.32%, 19.41%, 66.77%, 采用SSA-ELM模型决定系数 R^2 更接近于1, 具有更高的预测精度, 且该模型能对退化后的性能进行预测。

(3) 将CLM与SSA-ELM-DDM分别作为机载模型, 选取典型的超声速工况进行性能寻优控制。在 $Ma=2.0, H=12.47$ km工况条件下, 采用CLM安装推力

提高5.63%,安装油耗降低1.48%;采用SSA-ELM-DDM安装推力提高5.63%,安装油耗降低1.63%。SSA-ELM-DDM在最大安装推力和最小安装油耗模式下能够维持理想的寻优效果,且模型单次平均计算时间由184.05 m缩短到1.357 ms,寻优控制程序平均运行时间从286.36 s缩短到4.87 s,实时性得到显著改善。

致谢:感谢国家自然科学基金、国家科技重大专项和中央高校基本科研业务费的资助。

参考文献

- [1] LEE K, LEE B, KANG S, et al. Inlet distortion test with gas turbine engine in the altitude engine test facility[C]. Chicago: 27th AIAA Aerodynamic Measurement Technology and Ground Testing Conference, 2010.
- [2] 陈大光, 张 津. 飞机——发动机性能匹配与优化[M]. 北京: 北京航空航天大学出版社, 1990.
- [3] ORME J S. Performance seeking control(PSC) for the F-15 highly integrated digital electronic control (HIDEC) aircraft[C]. Edwards: An Electronic Workshop on the Performance Seeking Control and Propulsion Controlled Aircraft Results of the F-15 Highly Integrated Digital Electronic Control Flight Research Program, 1995.
- [4] NOBBS S G. PSC algorithm description[C]. Edwards: An Electronic Workshop on the Performance Seeking Control and Propulsion Controlled Aircraft Results of the F-15 Highly Integrated Digital Electronic Control Flight Research Program, 1995.
- [5] 李 岩, 聂聆聪, 牟春晖, 等. 自适应循环发动机性能智能在线寻优算法研究[J]. 推进技术, 2021, 42(8): 1716-1724. (LI Y, NIE L C, MU C H, et al. Online intelligent optimization algorithm for adaptive cycle engine performance[J]. Journal of Propulsion Technology, 2021, 42(8): 1716-1724.)
- [6] 李 勇, 韩非非, 张昕喆, 等. 基于遗传算法-序列二次规划的涡扇发动机最低油耗性能寻优控制[J]. 推进技术, 2020, 41(7): 1638-1648. (LI Y, HAN F F, ZHANG X Z, et al. Performance seeking control of turbofan engine minimum fuel consumption model based on GA-SQP[J]. Journal of Propulsion Technology, 2020, 41(7): 1638-1648.)
- [7] TAYARANI-BATHAIE S S, KHORASANI K. Fault detection and isolation of gas turbine engines using a bank of neural networks[J]. Journal of Process Control, 2015, 36: 22-41.
- [8] KIM S, KIM K, SON C. Transient system simulation for an aircraft engine using a data-driven model[J]. Energy, 2020, 196: 117046.
- [9] ZHENG Q G, CHEN H Y, WANG Y, et al. Research on hybrid optimization and deep learning modeling method in the performance seeking control[J]. Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, 2020, 234(7): 1340-1355.
- [10] ZHENG Q G, FU D W, WANG Y, et al. A study on global optimization and deep neural network modeling method in performance seeking control[J]. Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering, 2020, 234(1): 46-59.
- [11] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1/3): 489-501.
- [12] HUANG G, HUANG G B, SONG S, et al. Trends in extreme learning machines: a review[J]. Neural Networks, 2015, 61: 32-48.
- [13] XU M J, WANG J, LIU J X, et al. An improved hybrid modeling method based on extreme learning machine for gas turbine engine[J]. Aerospace Science and Technology, 2020, 107: 106333.
- [14] XU M J, LIU J X, LI M, et al. Improved hybrid modeling method with input and output self-tuning for gas turbine engine[J]. Energy, 2022, 238: 121672.
- [15] ZHOU J, LIU Y, ZHANG T H. Analytical redundancy design for aeroengine sensor fault diagnostics based on SROS-ELM[J]. Mathematical Problems in Engineering, 2016, 2016(4).
- [16] LU F, JIANG J P, HUANG J Q. Gas turbine engine gas-path fault diagnosis based on improved SBELM architecture[J]. International Journal of Turbo & Jet-Engines, 2018, 35(4): 351-363.
- [17] ZHAO Y P, HU Q K, XU J G, et al. A robust extreme learning machine for modeling a small-scale turbojet engine[J]. Applied Energy, 2018, 218: 22-35.
- [18] CHEN L, SUN N, ZHOU J Z, et al. Flood forecasting based on an improved extreme learning machine model combined with the backtracking search optimization algorithm[J]. Water, 2018, 10(10): 1362.
- [19] WEN X Q. Modeling and performance evaluation of wind turbine based on ant colony optimization-extreme learning machine[J]. Applied Soft Computing, 2020, 94: 106476.
- [20] MIRJALILI S, GANDOMI A H, MIRJALILI S Z, et al. Salp swarm algorithm: a bio-inspired optimizer for engineering design problems[J]. Advances in Engineering Software, 2017, 114: 163-191.

(编辑:白 鹭)

An integrated inlet/engine performance seeking control model based on salp swarm algorithm extreme learning machine

YU Ziyang¹, WANG Chen¹, DU Xian¹, NIE Lingcong², SUN Ximing¹

(1. School of Control Science and Engineering, Dalian University of Technology, Dalian 116024, China;

2. Beijing Power Machinery Institute, Beijing 100074, China)

Abstract: To fully exploit the performance of the aero-propulsion system and improve the real-time performance of performance seeking control, a data-driven model based on SSA-ELM is proposed by combining Salp Swarm Algorithm (SSA) and Extreme Learning Machine (ELM) and establishing data sets based on integrated inlet/engine component-level model. The modeling method was compared with General Regression Neural Network (GRNN), BP Neural Network (BPNN) and Extreme Learning Machine (ELM). The results show that compared with BPNN, ELM and GRNN, SSA-ELM for prediction can reduce the Root Mean Square Error (RMSE) of installed thrust by 7.41%, 17.01%, and 72.57%, respectively, and the RMSE of installed fuel consumption by 4.32%, 19.41%, and 66.77%, respectively, which has higher prediction accuracy. The data-driven model based on SSA-ELM was applied to the performance seeking control as on-board model. The results show that the on-board model can maintain the ideal seeking effect. In the real-time performance analysis of the maximum installed thrust mode, the average computation time of the on-board model is reduced from 184.05 ms to 1.357 ms compared to the integrated inlet/engine component-level model, which significantly improves the real-time performance and greatly enhances the seeking efficiency.

Key words: Aero-engine; Integrated inlet/engine; Salp swarm optimization algorithm; Extreme learning machine; Data-driven model; Performance seeking control

Received: 2023-02-21; **Revised:** 2023-06-21.

DOI: 10.13675/j.cnki. tjjs. 2302042

Foundation items: National Natural Science Foundation of China (61890921; 61890924); National Science and Technology Major Project of China (J2019-I-0019-0018); Fundamental Research Funds for the Central Universities (DUT22QN204).

Corresponding author: DU Xian, E-mail: duxian@dlut.edu.cn