

一种双回路 VCE 加速控制计划优化方法研究

赵兴宇, 李秋红, 庞淑伟, 顾子渝, 刘鑫洋

(南京航空航天大学 能源与动力学院 江苏省航空动力系统重点实验室, 南京 210016)

摘要: 为提高变循环发动机加速性能, 提升推力的响应速度, 提出了内外回路耦合的加速控制计划优化方法; 内回路采用模型预测控制, 以增加乘法层的神经网络结构在线构建线性化预测模型, 采用交替方向乘法对约束条件下的闭环控制变量进行优化; 在外回路, 采用樽海鞘群智能算法, 以推力响应最快为目标, 优化由贝塞尔曲线构造的开环控制规律; 内回路的优化基于外回路开环几何机构的调节规律展开, 外回路的优化以内回路的推力响应为评价, 形成内、外回路耦合优化结构; 以最优个体对应的发动机输入输出构造基于换算油气比的加速控制计划以及开环几何机构控制计划, 开展加速过程的仿真实验; 结果表明, 在线学习预测模型 5 步预测最大动态误差低于 0.8%; 相比原有控制计划, 优化后的控制计划充分利用了开、闭环控制变量的有利耦合, 加速过程中, 转速的响应时间缩短 14.6% 以上, 推力响应时间缩短 15% 以上, 验证了所提出的控制计划优化方法的有效性。

关键词: 变循环发动机; 加速控制计划; 神经网络状态空间模型; 贝塞尔曲线; 模型预测控制

Research on Acceleration Control Schedule Optimization Based on Dual-loop VCE

ZHAO Xingyu, LI Qihong, PANG Shuwei, GU Ziyu, LIU Xinyang

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

Abstract: To improve the acceleration performance of variable cycle engines (VCEs), and enhance the response speed of thrust, an acceleration control schedule optimization method based on coupled internal and external loops is proposed. In the inner loop, the neural network state space model with an additional multiplication layer was used to construct the prediction model online, and the alternating direction multiplier method was used to optimize the closed-loop control variables under constraint conditions. In the external loop, by using the salp swarm algorithm, the open-loop control law constructed by the Bessel curve was optimized with the goal of thrust response speed. The inner loop was optimized by the regulation law of the open-loop geometric mechanism and the external loop was optimized by the thrust response of the inner loop, which formed a coupled optimization structure. The control schedules for the corrected fuel-air ratio acceleration and open-loop geometric mechanism are constructed through the input and output of the engine corresponding to the optimal individual, achieving the simulation of acceleration process experiments. The results show that the maximum 5-step output prediction error of the on-line learning prediction model is below 2%. Compared with the original control schedule, the optimized acceleration control schedule makes full use of the favorable coupling of the open and closed loop control variables, and in acceleration process, the response time of rotational speed is shortened by over 14.6, and the response time of thrust by over 15%, which verifies the effectiveness of the proposed control schedule optimization method.

Keywords: VEC; accelerated control schedule; neural network state space model; Bessel curve; model predictive control (MPC)

0 引言

于传统的涡扇和涡喷发动机具有更宽的飞行包线和更多的工作状态, 且其参数变化范围大, 可调机构多^[1-2]。加速控制规律的设计是发动机控制技术中的关键部分,

变循环发动机 (VCE, variable cycle engine) 相较

收稿日期: 2024-01-14; 修回日期: 2024-02-27。

基金项目: 中国航发产学研合作项目 (HFZL2021CX007); 航空发动机及燃气轮机基础科学中心项目 (P2022-B-V-002-001)。

作者简介: 赵兴宇 (1999-), 男, 硕士研究生。

通讯作者: 李秋红 (1972-), 女, 副教授。

引用格式: 赵兴宇, 李秋红, 庞淑伟, 等. 一种双回路 VCE 加速控制计划优化方法研究. 计算机测量与控制, 2025, 33(3): 113-123.

一个合理的加速控制规律,是为了在加速过程中确保发动机安全性能的前提下,快速响应^[3]。而在加速控制规律的设计中,加速控制计划直接影响了航空发动机的响应性能和安全性^[4-5],因此优化技术被广泛用于制定发动机的加速控制计划。

目前常采用基于经典非线性优化和基于现代人工智能的方法对发动机的加减速控制计划进行优化。如文献[6]根据动态稳定法的思想,采用非线性最小二乘方法优化辅助向量,建立了涡扇发动机的过渡态控制规律。文献[7]针对涡扇发动机的整个加速度过程建立一个优化问题,采用序列二次规划方法对控制量的贝塞尔曲线进行优化,进而构建加速控制计划。文献[8]采用基因表达混乱遗传算法,对燃气轮机性能指标(响应时间和油耗)和惩罚项(波动、跟踪误差)构成的目标函数进行优化,提取加速控制计划。文献[9]将遗传算法和序列二次规划算法相结合,对发动机推力在最短的时间内达到最大的加速过程进行寻优求解。文献[10]提出了一种航空发动机瞬态控制时序设计问题的数学优化公式,采用集成径向基函数模型辅助求解优化问题。文献[11-12]则将对控制计划的优化扩展到全包线,制定了基于等温度线的换算油气比控制计划和基于等高度线的 $N\text{-dot}$ 控制计划。这些控制计划制定过程中,采取针对单一工作点的评价指标或者基于整个加速过程的评价方式,前者忽略了加速过程的整体性,后者则增加了加速优化过程的难度和计算工作量。

考虑到发动机加速控制计划优化本质上是一个带约束的非线性最优化问题,可以直接将约束带入到问题求解过程中^[13-14],如文献[15]提出了一种基于模型预测控制(MPC, model predictive control)局部优化思想,开展了涡扇发动机加速控制计划优化研究,利用模型预测控制显式处理约束的能力,把加速过程中的约束条件转换成模型预测控制的约束,采用在有限时域滚动优化的策略,实现加速过程中的局部最优化设计。

在变循环发动机的加减速控制计划优化研究方面,主要采用全局优化和局部优化两种方式。如文献[16-17]基于发动机原理和灵敏度分析,分别以恒定低压转速和恒定进气流量为条件,建立了自适应循环发动机在亚声速和超声速巡航工作点节流状态的控制计划,提高了发动机节流状态工作性能。文献[18-19]借助多学科优化设计 ISIGHT 平台开展变循环发动机过渡态控制计划设计,其中文献[18]提出性能系数矩阵的概念,以高压转子最大剩余功率为目标,采用改进的序列二次规划 NLPQL 优化算法优化变循环发动机的加速控制计划,但仅对燃油流量进行了优化,没有充分利用多变量的优势。文献[19]通过相关分析用可变几何参数取代发动机模型中的状态因子,建立了双外涵 VCE 的动态

逆模型并采用 Hooke _ Jeeves 方法来优化 VCE 加减速过程中的高、低压转子的剩余功率组合,但是动态逆方法几何参数变化受到状态量的变化轨迹的约束,需要考虑状态量和几何参数之间的相关性以及动态模型求解需求,难以兼顾所有的限制参数。同时这两种优化方法都属于逐工作点优化的局部优化求解方法,所获得几何参数在当前状态获得的指标是最优的,对加速过程的全局性考虑不够充分。而对于全局优化的研究,文献[20]将灰狼优化算法应用于 VCE 低压涡轮出口温度优化控制模式,通过对转子部件导叶角角度的几何机构设计,结合惩罚函数求出推力不变情况下的低压涡轮出口温度的最优控制变量序列,并且采用一种基于自抗扰控制的闭环控制器来实现多变量解耦控制,结合平滑切换公式,实现了传统工作模式到最低涡轮出口温度模式的平滑切换。这种优化方法用在加减过程中需要多次调用模型,大大增加了迭代计算的负担,对参与开环和闭环控制的几何机构也没有进行区分。

考虑到变循环发动机加速过程的全局性和几何机构过渡的平稳性,本文提出一种全局优化和局部优化相结合的加速控制计划综合优化办法,以推力的快速响应为目标,对参与开环控制的几何机构通过贝塞尔曲线进行全局优化,确保几何机构在加速过程的平稳性,对参与闭环控制的几何机构采用模型预测进行局部滚动优化,以获得最优的动态响应特性。所提出的方法内回路的优化以外回路为基础,外回路以内回路的加速响应时间为评价指标,实现加速控制计划的开/闭环几何机构的耦合优化。

1 加速控制计划优化系统结构

本文基于某型双/三外涵变循环发动机开展研究,与传统双轴涡扇发动机相比,结构更为复杂,包括:前风扇(FFAN)、后风扇(RFAN)、模式转换阀门(MSV)、核心机驱动风扇(CDFS)、前涵道引射器(FVABI)、压气机(COM)、燃烧室、高压涡轮(HT)、低压涡轮(LT)、后涵道引射器(RVABI)、掺混室、加力燃烧室和尾喷管,具体构型如图1所示。其中高压涡轮,压气机与核心机驱动风扇三者同轴,低压涡轮与前后风扇同轴。

在内回路采用控制量为主燃油流量 W_{fm} 和尾喷口喉部面积 A_8 的双变量闭环控制方式,被控制量选择低压转速 N_L 、推力 F 。

为了提升发动机的加速性能,基于变循环发动机的部件级数学模型(CLM, component level mathematical model),对三个开环几何机构输入面积前涵道引射器面积 A_{FVABI} 、后涵道引射器面积 A_{RVABI} 和低压涡轮导向器面积 A_{LT} 进行优化(压缩部件的导叶角随换算转速变




图 1 变循环发动机结构示意图

化, 高压涡轮导向器面积 A_{HT} 在 VCE 两种模式下均为定值, 这里不进行优化), 设计了加速控制计划优化系统结构如图 2 所示的。外回路采用新兴的樽海鞘链群智能优化算法^[21-22] (SSA, salp swarm algorithm) 对 A_{FAVBI} 、 A_{RAVBI} 、 A_{LT} 进行优化, SSA 算法被证明在大多数测试函数上均优于其他算法, 且算法优化标准差小, 性能稳定, 为此本文选用此算法进行开环几何机构的优化。内回路以 CLM 为被控对象, 采用模型预测控制优化当前 A_{FAVBI} 、 A_{RAVBI} 、 A_{LT} 输入下对应的 W_{fm} 和 A_8 , 以充分发挥发动机在满足约束条件下的加速性能。此外, 利用海鞘链群智能来优化贝塞尔曲线的控制点, 通过贝塞尔曲线来构造加速过程中 A_{FAVBI} 、 A_{RAVBI} 、 A_{LT} 的输入变化, 并通过推力的 F 的响应时间 t_{ac} 来评价个体的适应度。

为了使得预测模型能够表征不同输入组合下的发动机动态特性, 基于部件级模型输出, 采用在线学习的极限学习机 (OS-ELM, online sequential extreme learning machine) 来建立状态变量模型, 进而构造预测模型, 并采用交替方向乘法^[23] (ADMM, alternating directions method of multipliers) 实现滚动优化。

2 在线学习预测模型

本文的加速控制计划采用离线优化的方法, 为了提高优化效率, 采用线性优化 ADMM 方法, 建立基于状态空间模型的线性预测模型。对于航空发动机来说, 状态空间模型通常采用曲线拟合法或者偏导数法建立, 且只能在有限的稳态工作点和工作状态通过小扰动法建立, 计算过程耗时较多, 大多离线进行。而不同的 A_{FAVBI} 、 A_{RAVBI} 、 A_{LT} 组合也对应不同的动态过程, 因此基于稳态工作点建立的模型不能准确反应其特性。为此, 本文采用一种在线学习的线性变参数建模方法, 基于 OS-ELM 神经网络的状态空间模型 (NN-SSM, neural network-state space model), 改进神经网络结构, 使得神经网络输出具有状态变量模型的表达形式, 大大提高了线性化建模精度。

2.1 神经网络状态空间模型

用于模型预测控制的变循环发动机状态空间模型 (SSM) 的表达形式如下:

$$\begin{cases} x_{k+1} = \mathbf{A}_k(\alpha_k)x_k + \mathbf{B}_k(\alpha_k)u_k \\ y_k = \mathbf{C}_k(\alpha_k)x_k + \mathbf{D}_k(\alpha_k)u_k \\ y_{c,k} = \mathbf{C}_{c,k}(\alpha_k)x_k + \mathbf{D}_{c,k}(\alpha_k)u_k \end{cases} \quad (1)$$

其中: $\mathbf{x} = [x_1, x_2]^T = [N_L, N_H]^T$ 为系统状态量, 分别代表低、高压转速, $\mathbf{u} = [u_1, u_2]^T = [W_{fm}, A_8]^T$ 为闭环系统控制量, $\mathbf{y} = [y_1, y_2, \dots]^T = [N_L, F]^T$ 为系统输出量, $\mathbf{y}_c = [y_{c1}, y_{c2}, y_{c3}, y_{c4}, y_{c5}, y_{c6}]^T = [SMF, SMR, SMC, SMH, P_3, T_5]^T$ 为输出限制量, 具体表示为前、后风扇、CDFS 和压气机的喘振裕度、压气机出口压力和低压涡轮出口温度。其中, SSM 的调度参数 (即神经网络的输入) α 选择为 N_L , \mathbf{A} , \mathbf{B} , \mathbf{C} , \mathbf{D} , \mathbf{C}_c , \mathbf{D}_c 分别表示适维矩阵。

为了使神经网络的输出满足 SSM 的表达形式, 采

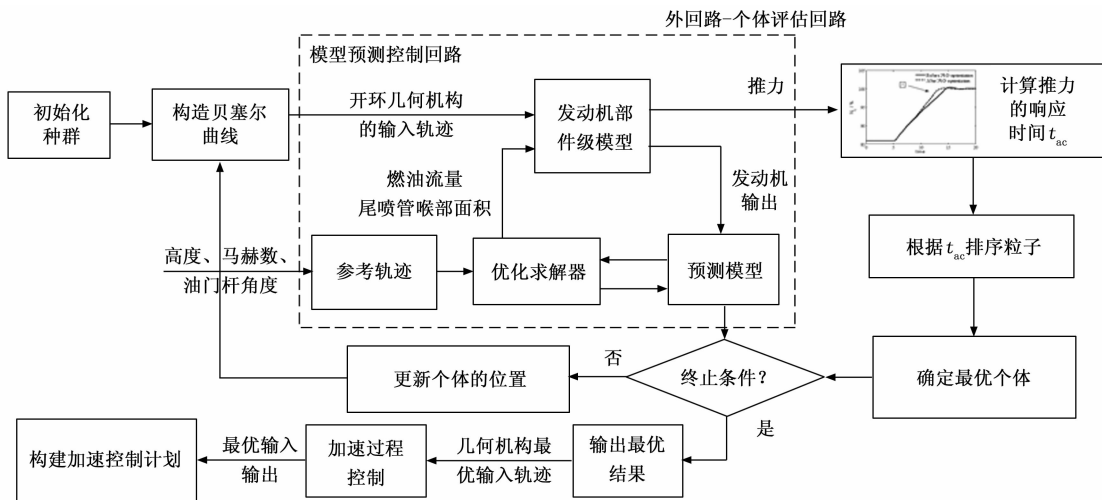


图 2 加速控制计划优化系统结构

用了改进的神经网络结构如图 3 所示。




图 3 NN-SSM 网络结构

由于采用在线学习算法，选用的神经网络为 ELM。ELM 网络的学习速率是 BP 神经网络的十倍以上，学习误差相近^[24]。由图 3 可知，改进的神经网络根据状态量和控制量的维数将隐含层分为 $n+p$ 组， n 代表状态变量的维数， p 代表输入变量的维数，每组含 j 个隐含层节点，然后在 ELM 网络的隐含层和输出层之间增加一层乘法层，乘法层以状态量和控制量作为激励函数，每组输出在乘法层分别与状态变量 x 和输入变量 u 相乘，乘法层到输出层之间的连接权根据递推最小二乘法^[25]计算。

NN-SSM 的第 m 个输出可由乘法层激励函数 k 时刻的状态变量 $N_{L,k}$ 、 $N_{H,k}$ 和控制量 $W_{fm,k}$ 、 $A_{\delta,k}$ 表示为：

$$\hat{Y}_{NN,m,k} = \sum_{i=1}^j \beta_{m,k} h_{i,k} x_{1,k} + \sum_{i=j+1}^{2j} \beta_{m,k} h_{i,k} x_{2,k} + \sum_{i=2j+1}^{3j} \beta_{m,k} h_{i,k} u_{1,k} + \sum_{i=3j+1}^{4j} \beta_{m,k} h_{i,k} u_{2,k} \quad (2)$$

$m = 1, 2, \dots, 10$

其中：神经网络的输入为调度参数 α ， W 和 b 表示隐含层的权值和偏置， β 表示乘法层与输出层之间的权值， $h_{i,k} = f(W_i \alpha_k + b_i)$ 为第 i 个隐含层节点的输出。

因此，NN-SSM 网络的 10 个输出分别对应状态空间模型的输出 $\hat{Y}_{NN,k} = [x_{1,k+1}, x_{2,k+1}, y_{1,k}, y_{2,k}, y_{c1,k}, y_{c2,k}, y_{c3,k}, y_{c4,k}, y_{c5,k}, y_{c6,k}]^T$ 。此时，式 (1) 中的 SSM 则可以写成：

$$A_k(\alpha_k) = \left\{ \left[\sum_{i=1}^j \beta_{il,k} h_{i,k} \quad \sum_{i=j+1}^{2j} \beta_{il,k} h_{i,k} \right] \right\}, l = 1, 2$$

$$B_k(\alpha_k) = \left\{ \left[\sum_{i=2j+1}^{3j} \beta_{il,k} h_{i,k} \quad \sum_{i=3j+1}^{4j} \beta_{il,k} h_{i,k} \right] \right\}$$

$$C_k(\alpha_k) = \begin{bmatrix} 1 & 0 \\ \sum_{i=1}^j \beta_{i3,k} h_{i,k} & \sum_{i=j+1}^{2j} \beta_{i3,k} h_{i,k} \end{bmatrix}^T$$

$$D_k(\alpha_k) = \begin{bmatrix} 0 & 0 \\ \sum_{i=2j+1}^{3j} \beta_{i3,k} h_{i,k} & \sum_{i=3j+1}^{4j} \beta_{i3,k} h_{i,k} \end{bmatrix}$$

$$C_{cs,k}(\alpha_k) = \left\{ \left[\sum_{i=1}^j \beta_{i(4+s),k} h_{i,k} \quad \sum_{i=j+1}^{2j} \beta_{i(4+s),k} h_{i,k} \right] \right\}$$

$$D_{cs,k}(\alpha_k) = \left\{ \left[\sum_{i=2j+1}^{3j} \beta_{i(4+s),k} h_{i,k} \quad \sum_{i=3j+1}^{4j} \beta_{i(4+s),k} h_{i,k} \right] \right\}$$

$s = 1, 2, \dots, 6$ (3)

其中：下标 l 表示与第 l 个状态量相关的参数，下标 s 表示与第 s 个约束量相关的参数。由于 N_L 既是 SSM 模型的输出量又是状态量，所以 C 、 D 矩阵第一行元素可以给出。

由式 (3) 可知，SSM 各参数可由神经网络的参数表示，采用在线学习方法，SSM 参数随着网络参数的更新而更新。为了动态计算和计算实时性的需求。神经网络采用带有遗忘因子的 OS-ELM 算法^[26]进行训练，此处不再赘述。

2.2 预测模型

模型预测控制，以预测模型为基础，采用在线滚动优化和反馈校正策略，以实现对被控对象的跟踪控制，使系统有良好的鲁棒性和稳定性^[27-28]。预测模型是滚动优化的依据，在模型预测控制中关系到了控制的精度和实时性。

以神经网络在线空间模型构建预测模型，根据未来输入的控制序列 $U = [u_k^T, u_{k+1}^T, \dots, u_{k+m-1}^T]^T$ ，计算得到未来的输出序列 $Y = [y_{k+1}, y_{k+2}, \dots, y_{k+ny}]^T$ 和约束预测序列 $Y_C = [y_{c,k+1}, y_{c,k+2}, y_{c,k+3}, \dots, y_{c,k+ny}]^T$ ， n_u 和 n_y 分别表示控制时域和预测时域。

在已知 k 时刻状态量 x_k 和 NN-SSM 模型参数矩阵 A_k 、 B_k 、 C_k 、 D_k 、 $C_{c,k}$ 和 $D_{c,k}$ 的情况下，未来 n_y 步的状态量的表达式如下所示：

$$\begin{cases} x_{k+1} = A_k x_k + B_k u_k \\ x_{k+2} = A_k^2 x_k + A_k B_k u_k + B_k u_{k+1} \\ \vdots \\ x_{k+n_y+1} = A_k^{n_y+1} x_k + A_k^{n_y} B_k u_k + \dots + (A_k B_k + B_k) u_{k+n_y-1} \\ \vdots \\ x_{k+n_y} = A_k^n x_k + A_k^{n-1} B_k u_k + \dots + (A_k^{n-n} B_k + \dots + B_k) u_{k+n_y-1} \end{cases} \quad (4)$$

同理对于未来 n_y 步的输出变量和约束变量如式 (5) 和式 (6) 所示：

$$\begin{cases} y_{k+1} = C_k A_k x_k + C_k B_k u_k + D_k u_{k+1} \\ y_{k+2} = C_k A_k^2 x_k + C_k A_k B_k u_k + C_k B_k u_{k+1} + D_k u_{k+2} \\ \vdots \\ y_{k+n_y} = C_k A_k^n x_k + C_k A_k^{n-1} B_k u_k + \dots + C_k A_k^{n-n_y} B_k u_{k+n_y-1} \end{cases} \quad (5)$$

$$\begin{cases} y_{c,k+1} = C_{c,k}A_kx_k + C_{c,k}B_ku_k + D_{c,k}u_{k+1} \\ y_{c,k+2} = C_{c,k}A_k^2x_k + C_{c,k}A_kB_ku_k + C_{c,k}B_ku_{k+1} + D_{c,k}u_{k+2} \\ \vdots \\ y_{c,k+n_y} = C_{c,k}A_k^{n_y}x_k + C_{c,k}A_k^{n_y-1}B_ku_k + \dots + \\ C_{c,k}A_k^{n_y-n_u}B_ku_{k+n_y-1} \end{cases} \quad (6)$$

整理上式, 将未来 n_y 步的输出量和约束量表示为如下形式:

$$Y = Px_k + HU \quad (7)$$

$$Y_C = P_Cx_k + H_CU \quad (8)$$

其中: 式 (7)、式 (8) 中的输出量的 P 、 H 矩阵和约束量的 P_C 、 H_C 矩阵分别为:

$$P = \begin{bmatrix} C_kA_k \\ C_kA_k^2 \\ \vdots \\ C_kA_k^{n_y} \end{bmatrix}$$

$$H = \begin{bmatrix} C_kB_k & D_k & \dots & 0 \\ C_kA_kB_k & C_kB_k & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ C_kA_k^{n_y-1}B_k & C_kA_k^{n_y-2}B_k & \dots & C_kA_k^{n_y-n_u}B_k \end{bmatrix} \quad (9)$$

$$P_C = \begin{bmatrix} C_{c,k}A_k \\ C_{c,k}A_k^2 \\ \vdots \\ C_{c,k}A_k^{n_y} \end{bmatrix}$$

$$H_C = \begin{bmatrix} C_{c,k}B_k & D_{c,k} & \dots & 0 \\ C_{c,k}A_kB_k & C_{c,k}B_k & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ C_{c,k}A_k^{n_y-1}B_k & C_{c,k}A_k^{n_y-2}B_k & \dots & C_{c,k}A_k^{n_y-n_u}B_k \end{bmatrix} \quad (10)$$

3 内回路优化

在加速控制计划优化过程中, 外回路通过樽海鞘链群智能算法生成不同的 A_{FAVBI} 、 A_{RAVBI} 、 A_{LT} 加速过程变化曲线, 与之相应的内回路采用 ADMM 算法对 W_{fm} 和 A_8 进行优化, 以获得最优的加速性能。

基于上述的在线预测模型, 构造出如下的带约束的二次规划问题:

$$\begin{cases} \min J_1 = E^TE \\ \text{s. t. } MU \leq L \end{cases} \quad (11)$$

式中, $E=R-Y$, 表示参考轨迹 R 和预测输出 Y 的差值, 其中 $R = [r_{k+1}, r_{k+2}, \dots, r_{k+n_y}]^T$, $M = [H_C^T, -H_C^T, I, -I, H_u^T, -H_u^T]^T$, $L = [Y_{C,\max}^T, Y_{C,\min}^T, U_{\max}^T, -U_{\min}^T, \Delta U^T, \Delta U^T]^T$, M 和 L 中元素的具体含义如下。

$Y_{C,\max}$ 和 $Y_{C,\min}$ 定义为约束极限, 分别满足:

$$\begin{cases} H_CU \leq Y_{C,\max} \\ -H_CU \leq Y_{C,\min} \end{cases} \quad (12)$$

$$Y_{c,\max} = \begin{bmatrix} I \\ I \\ \vdots \\ I \end{bmatrix} y_{c,\max} - P_Cx(k) \quad (13)$$

$$Y_{c,\min} = - \begin{bmatrix} I \\ I \\ \vdots \\ I \end{bmatrix} y_{c,\min} + P_Cx(k)$$

U_{\max} 和 U_{\min} 定义为输入量极限, 满足下式:

$$U_{\max} = \begin{bmatrix} I \\ I \\ \vdots \\ I \end{bmatrix} u_{\max}, U_{\min} = \begin{bmatrix} I \\ I \\ \vdots \\ I \end{bmatrix} u_{\min} \quad (14)$$

$$\begin{cases} U \leq U_{\max} \\ -U \leq -U_{\min} \end{cases} \quad (15)$$

ΔU 为执行机构单步最大变化量, 则执行机构的变化极限 ΔU 可表示为:

$$\Delta U = \begin{bmatrix} I \\ I \\ \vdots \\ I \end{bmatrix} \Delta u_{\max} \quad (16)$$

考虑到执行机构的限制约束, 矩阵 H_u 需满足的表达式如下:

$$H_u = \begin{bmatrix} I \\ -I & I \\ & -I & I \\ & & \vdots \\ & & & -I & I \end{bmatrix} \quad (17)$$

$$H_uU \leq \Delta U \quad (18)$$

因此, 最终构造出的矩阵满足 $MU \leq L$ 。

为了获得当前 A_{FAVBI} 、 A_{RAVBI} 、 A_{LT} 下的发动机最优输入、输出序列。本文采用 ADMM 在线滚动优化和反馈校正策略, 对式 (11) 所描述的二次规划问题进行求解。

4 外回路优化

贝塞尔曲线^[29]是一种应用于二维图形应用程序的数学曲线。

对于外回路开环几何机构输入轨迹的优化, 通过构造 A_{RAVBI} 、 A_{FAVBI} 或 A_{LT} 加速过程输入轨迹的贝塞尔曲线, 采用新兴的樽海鞘链群智能优化算法, 以加速过程推力响应时间最短为优化目标, 对表征几何参数变化的贝塞尔曲线控制点进行优化。

一个包含 $n_p + 1$ 个控制点 P_i ($i = 0, 1, \dots, n_p$)

的贝塞尔曲线方程表达式如下：

$$\mathbf{B}(t) = \sum_{i=0}^{n_p} (C_{n_p}^i P_i (1-t)^{n_p-i} t^i), t \in [0, 1] \quad (19)$$

式中， \mathbf{B} 表示为 n 阶伯恩斯坦多项式的线性组合， P_i 为控制点参数， t 为比例参数， $C_{n_p}^i$ 为组合数公式。当 t 从 0 到 1 改变时，贝塞尔曲线上的点从起点移动到终点。

考虑到开环几何机构的输入轨迹由贝塞尔曲线的控制点参数决定。本文采用樽海鞘链群智能算法 (SSA) 对控制点参数进行优化，开环几何机构的输入轨迹均用 5 个控制点描述，对应低压转速的 [76%，82%，88%，94%，102%]，双外涵时优化 A_{RAVBI} 和 A_{LT} (此状态本方案中 A_{FAVBI} 不可调)，三外涵时优化 A_{RAVBI} 、 A_{FAVBI} (此状态本方案中 A_{LT} 不可调)，每种模式优化 2 个开环控制几何机构的 10 个控制点。

与其他群智能算法类似，SSA 也从随机初始化种群开始，樽海鞘链中的领导者按下式更新其位置：

$$x_j^i = \begin{cases} F_j + c_1 [(ub_j - lb_j)c_2 + lb_j], c_3 \geq 0.5 \\ F_j - c_1 [(ub_j - lb_j)c_2 + lb_j], c_3 < 0 \end{cases} \quad (20)$$

式中， F_j ， $j=1, 2, \dots, 10$ ，表示食物源位置的第 j 个维度， ub_j 和 lb_j 为第 j 维的上、下边界前迭代次数， c_2 和 c_3 是 [0, 1] 之间的随机数。 c_1 控制着领导者在食物源附近的搜索区间，其在前期较大，扩大搜索范围，后期较小，进行最优位置附近的精细化搜索。

$$c_1 = 2e^{-(4g/G)^2} \quad (21)$$

式中， g 、 G 分别表示当前迭代次数和最大允许迭代次数。

樽海鞘链中除领导者外的其他跟随者 x^i 按下式更新其第 j 个维度的位置：

$$x_j^i = 0.5(x_j^i + x_j^{i-1}), i \geq 2 \quad (22)$$

个体适应度以内外回路共同作用下的加速时间 t_{ac} 来判断，表达式如下：

$$\min t_{ac} = t_2 - t_1 \quad (23)$$

式中， t_1 为加速开始时间， t_2 为推力到达目标值 99% 的时间。

通过樽海鞘链优化获得不同的 A_{FAVBI} 、 A_{RAVBI} 和 A_{LT} 变化曲线，以 A_{LT} 为例，最优个体对应的曲线如图 4 所示。

由图 4 可见，贝塞尔曲线的 5 个控制点并不单调，但是构造出来的 A_{LT} 随低压转速变化曲线光滑，且随转速增加而单调增大。因此，开环几个机构的输入曲线可由低压转速调度。

在内外回路的综合优化下，以推力响应时间最短个体构造开环几何机构的贝塞尔曲线，得到加速过程的最优开、闭环输入、输出序列，最终得到换算油气比加速控制计划为：

$$\left(\frac{W_{fm}}{P_3}\right) = f(N_{H,cor}) \quad (24)$$




图 4 A_{LT} 五阶贝塞尔曲线

其中： $N_{H,cor}$ 为高压转子换算转速。

5 仿真验证

5.1 预测模型精度验证

对于内回路的模型预测控制，其预测模型的准确性对控制性能至关重要。本文采用在线训练的 NN-SSM 构建预测模型时，在发动机沿不同曲线进行加速时，相比离线算法，NN-SSM 模型通过在线更新能够准确描述发动机的不同动态过程。NN-SSM 模型隐含层分为 $n + p$ 组，每组含 j 个隐含层节点，对于变循环发动机状态变量的维数 $n=2$ ，输入的维数 $p=2$ ，当 $j=2$ 乘法层节点数为 8 时，模型规模较小而精度较高，用于本文预测模型的建立。为避免数据淹没，输入/输出神经网络训练的数据均经过归一化/反归一化处理。下面在变循环发动机的双外涵和三外涵两种模式下，开展预测模型的精度验证。

1) 双外涵模式仿真：

双外涵模式下，变循环发动机在高空点 ($H=11 \text{ km}$, $Ma=1.4$)，当控制时域 $n_u=2$ 时，油门杆变化范围为 30° 到 65° ，分别进行预测时域为 $n_y=3, 4, 5$ 的预测模型精度对比仿真验证。在稳态下，预测模型与 CLM 相比各输出参数的稳态误差均小于 0.02%；在动态时，各输出量的最大预测误差见表 1。

表 1 不同预测时域的最大动态预测误差

输出参数	最大误差/%		
	$n_y=3$	$n_y=4$	$n_y=5$
低压转速	0.12	0.15	0.2
高压转速	0.013	0.016	0.02
推力	0.52	0.58	0.76
压气机出口压力	0.4	0.45	0.6
低压涡轮出口温度	0.3	0.5	0.8

由表 1 可见，在动态过程中，3 种不同预测时域低压转速 N_L 的误差均小于 0.2%，高压转速 N_H 的误差均

小于 0.02%，推力 F 的最大误差为 0.86%，压气机出口压力 P_3 最大误差为 0.6%，低压涡轮出口温度 T_5 最大误差小于 0.8%，各输出量的预测误差随着预测时域 n_y 的增加而增大。仿真结果表明，在双外涵模式下， $n_y = 4$ 时，预测模型精度与 $n_y = 3$ 接近，而优于 $n_y = 5$ ，因此可以选择 $n_y = 4$ 时作为预测时域。

2) 三外涵模式仿真:

三外涵模式下，变循环发动机在地面点 ($H = 0$ km, $Ma = 0$) 进行仿真验证，发现预测时域 $n_y = 5$ 步时精度与 $n_y = 3$ 和 $n_y = 4$ 相近，为了能够更好地表征局部优化特性，采用 $n_y = 5$ 的预测控制。 $n_y = 5$ 时预测模型的预测输出如图 5 所示 (双外涵仿真验证时的油门杆角度变化与图 5 (a) 相同)，图中“模型输出”表示发动机部件级模型 CLM 的输出，“预测输出”表示预测模型 NN-SSM 的五步预测输出。可见预测模型输出可以准确地匹配 CLM 的输出结果。在稳态下，预测模型的五步预测误差较小，各输出量的稳态误差均在 0.02% 以内。在动态下， N_L 的最大误差小于 0.15%， N_H 的最大误差小于 0.02%， F 的最大误差为 0.5%， P_3 和 T_5 最大误差分别小于 0.4% 和 0.2%。仿真结果表明，

在三涵模式下，预测模型具有较高的预测精度，适用于模型预测控制中的预测模型。在包线内其他工作点的验证结果类似，这里不再一一给出。

5.2 加速控制计划优化验证

变循环发动机在两种模式下采用同样的加速控制计划优化方法，分别得到基于最优输入序列构建的基于换算油气比的加速控制计划，开展加速过程控制计划的仿真验证。

1) 双外涵模式仿真:

变循环发动机分别在典型状态点 ($H = 0$ km, $Ma = 0$) 和 ($H = 11$ km, $Ma = 1.4$) 进行加速过程控制计划优化，获得最优换算油气比 (FAR) 和最优 A_{RAVBI} 和 A_{LT} 的变化规律 (A_{FAVBI} 为定值)。超声速巡航工作点的加速过程仿真结果见图 6。图中“优化前”表示的几何机构按原有开环控制计划进行调节，“优化后”表示采用内外回路控制变量耦合优化的仿真结果；前、后风扇、CDF5 风扇和压气机的喘振裕度最小限制值均为 10%，压气机出口压力、低压涡轮出口温度最大限制值为设为 100%。

由图 6 可知，换算油气比加速控制计划在前期优化

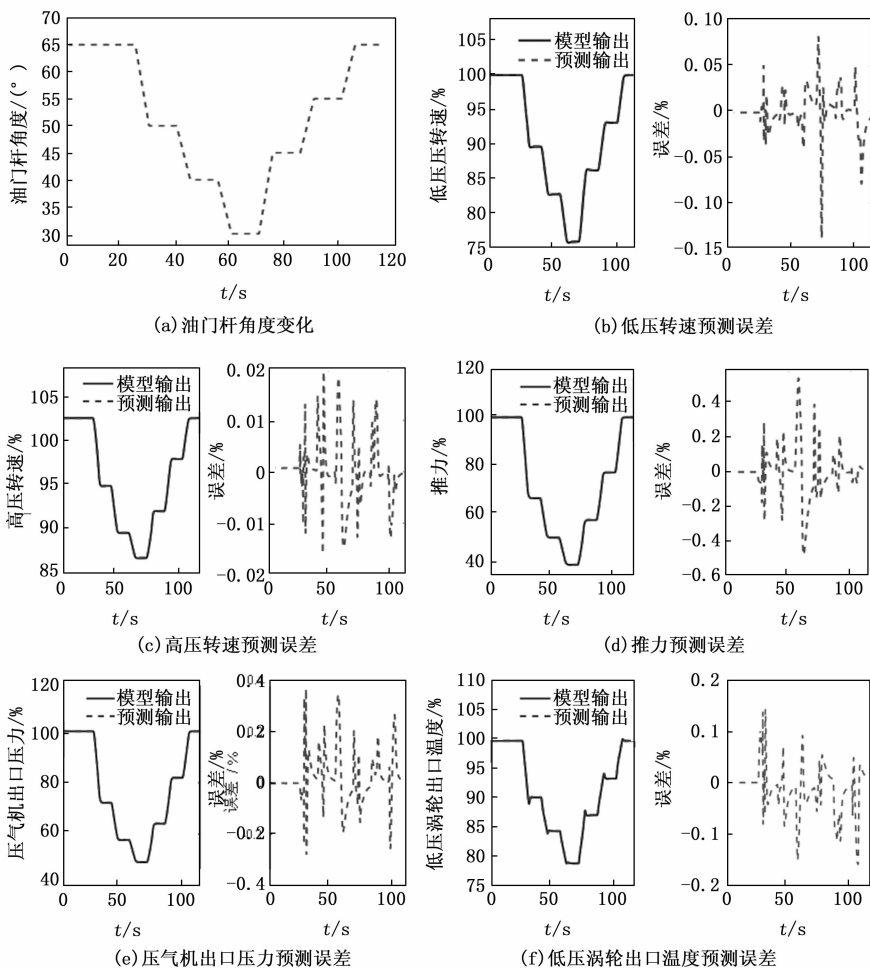


图 5 三外涵模式下预测模型的仿真结果

前后基本一致,优化后的中期油气比增大,允许更大的供油流量,后期减小,更快回到平衡工作点。在加速初期,燃油流量迅速增大,此时燃油流量主要受执行机构单步最大约束量限制,发动机输出参数距离约束边界较远;随着燃油流量的不断增加,发动机的工作点逐渐向约束边界靠近;在加速后期,压气机出口压力和涡轮进口温度逐渐接近约束边界,转子的加速过程放缓,发动机的工作点开始远离风扇和压气机的喘振边界;当低压转速和推力达到 99% 时加速过程结束。图 6 (f) 和 6 (h) 可知,外环输入轨迹经过 SSA 优化后, N_L 达到 99% 的响应时间从 2.275 秒加快到 1.925 秒,时间缩短 15.4% 推力 F 达到 99% 的响应时间从 1.852 秒加快到 1.575 秒,时间缩短了 15.0%,且涡轮后温度和压气机出口压力均略低于未优化情况,喘振裕度 SMF、SMR、

SMC 和 SMH 虽有下降,但仍然远离喘振边界。因此,由图 6 仿真结果可知,采用内、外回路综合优化后的加速控制计划可以安全、快速的实现加速过程控制。

在双外涵模式下,采用同种内、外回路综合优化方法对地面点 ($H=0$ km, $Ma=0$) 的加速控制计划进行了优化验证。在各压缩部件喘振裕度、温度和压力不超限的情况下, N_L 达到 99% 响应时间从 2.23 秒加快到 1.75 秒,时间缩短 21.5%, F 达到 99% 的响应时间从 1.65 秒加快到 1.375 秒,时间缩短了 16.7%,大大提高了发动机的加速性能,验证了双外涵模式下控制计划制定方法的有效性。

2) 三外涵模式仿真:

三外涵模式下,变循环发动机分别在地面点 ($H=0$ km, $Ma=0$) 和亚声速巡航工作点 ($H=8$ km, Ma

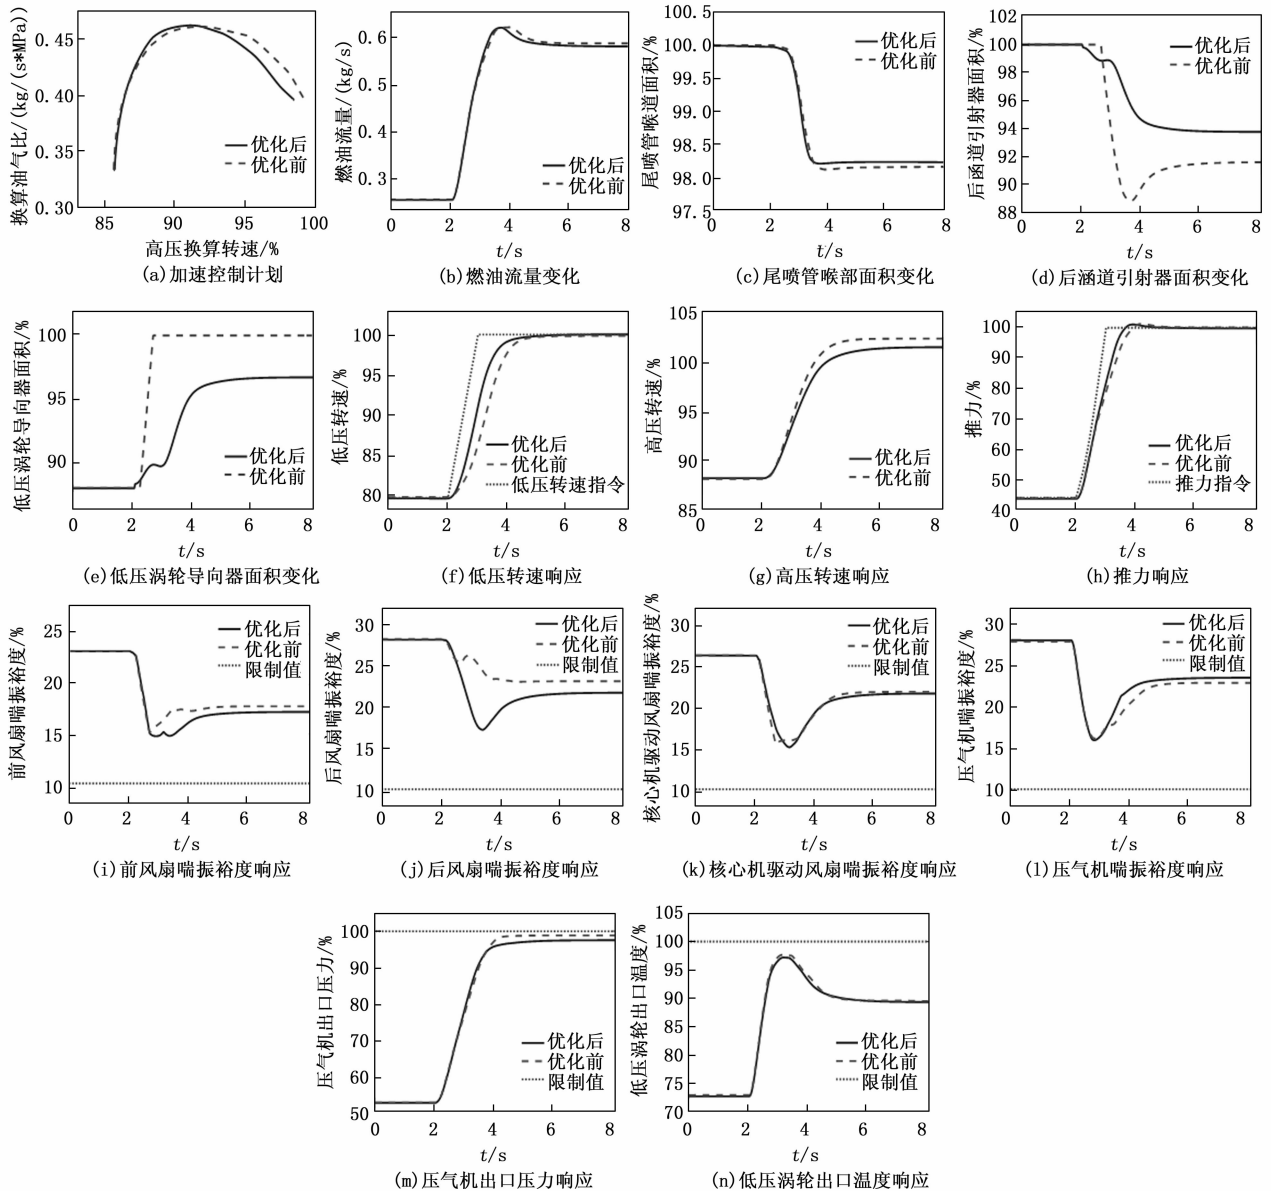


图 6 双外涵模式加速过程仿真结果 ($H=11$ km, $Ma=1.4$)

=0.9), 开展加速过程控制计划优化, 结果如图 7 和图 8。

由图 7 可知, 换算油气比加速控制计划在优化前后基本一致, 也就是允许的加速供油流量基本一致, 加速性能的提升由其他机构结构决定, 实际上优化前后的燃油流量也基本一致。在加速初期, 燃油流量只受执行机构的约束, 燃油的增速较快且各输出量远离约束边界; 在加速后期由于 P3 和 T5 的约束, 燃油的增加速率稍有降低, 转子转速继续上升, 当低压转速和推力达到 99% 时加速过程结束。相比优化前, 外环输入轨迹经过 SSA 优化后, N_L 达到 99% 的响应时间从 2.25 秒加快到 1.825 秒, 时间缩短 18.9%, F 达到 99% 的响应时间从 2.2 秒加快到 1.85 秒, 时间缩短了

15.9%, 且涡轮后温度略低于未优化情况。经过仿真验证, 单外涵模式下的加速控制计划优化也取得较好的加速效果。

图 8 在亚声速巡航工作点 $H=8\text{ km}$, $Ma=0.9$ 开展的仿真验证, 仿真结果与图 7 类似, 在加速后期换算油气比加速控制计划优化比优化前有明显降低, 其在加速中、后期的实际燃油高于优化前是由于其 P_3 较大, 因此换算回来的燃油较大, 同时几何机构在加速过程中也明显不同。相比优化前, 优化后 N_L 达到 99% 的响应时间从 3.075 秒加快到 2.625 秒, 时间缩短 14.6%, F 达到 99% 的响应时间从 2.524 秒加快到 2.125, 时间缩短 15.8%。验证了所设计的加速控制计划的优越性。

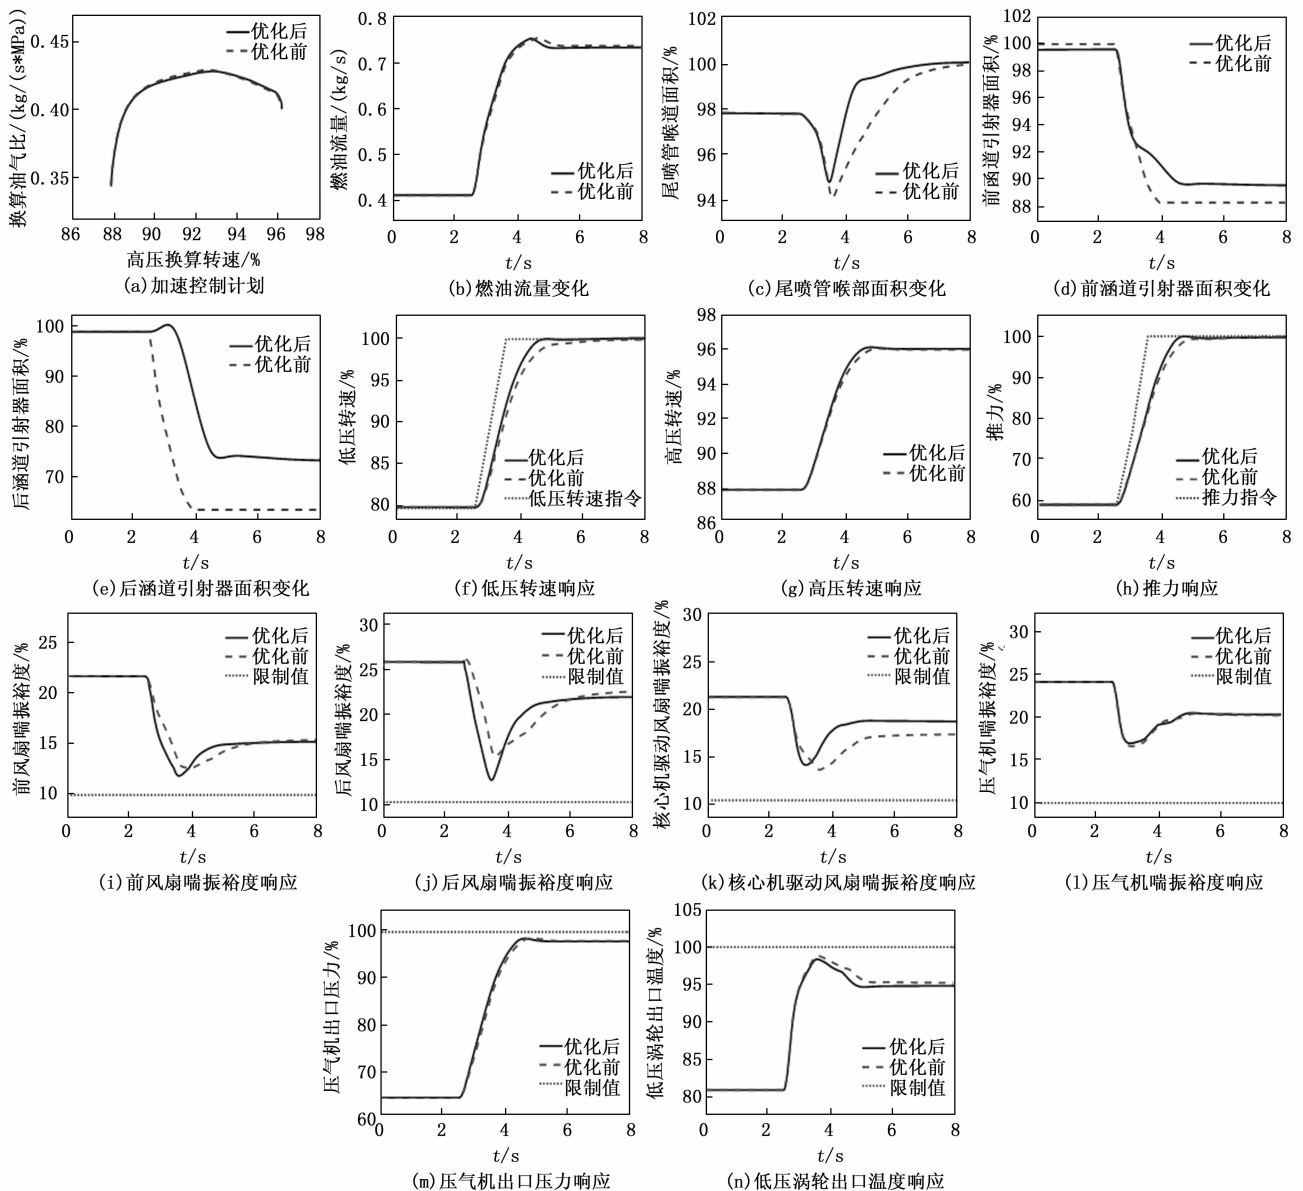


图 7 三外涵模式加速过程仿真结果 ($H=0\text{ km}$, $Ma=0$)

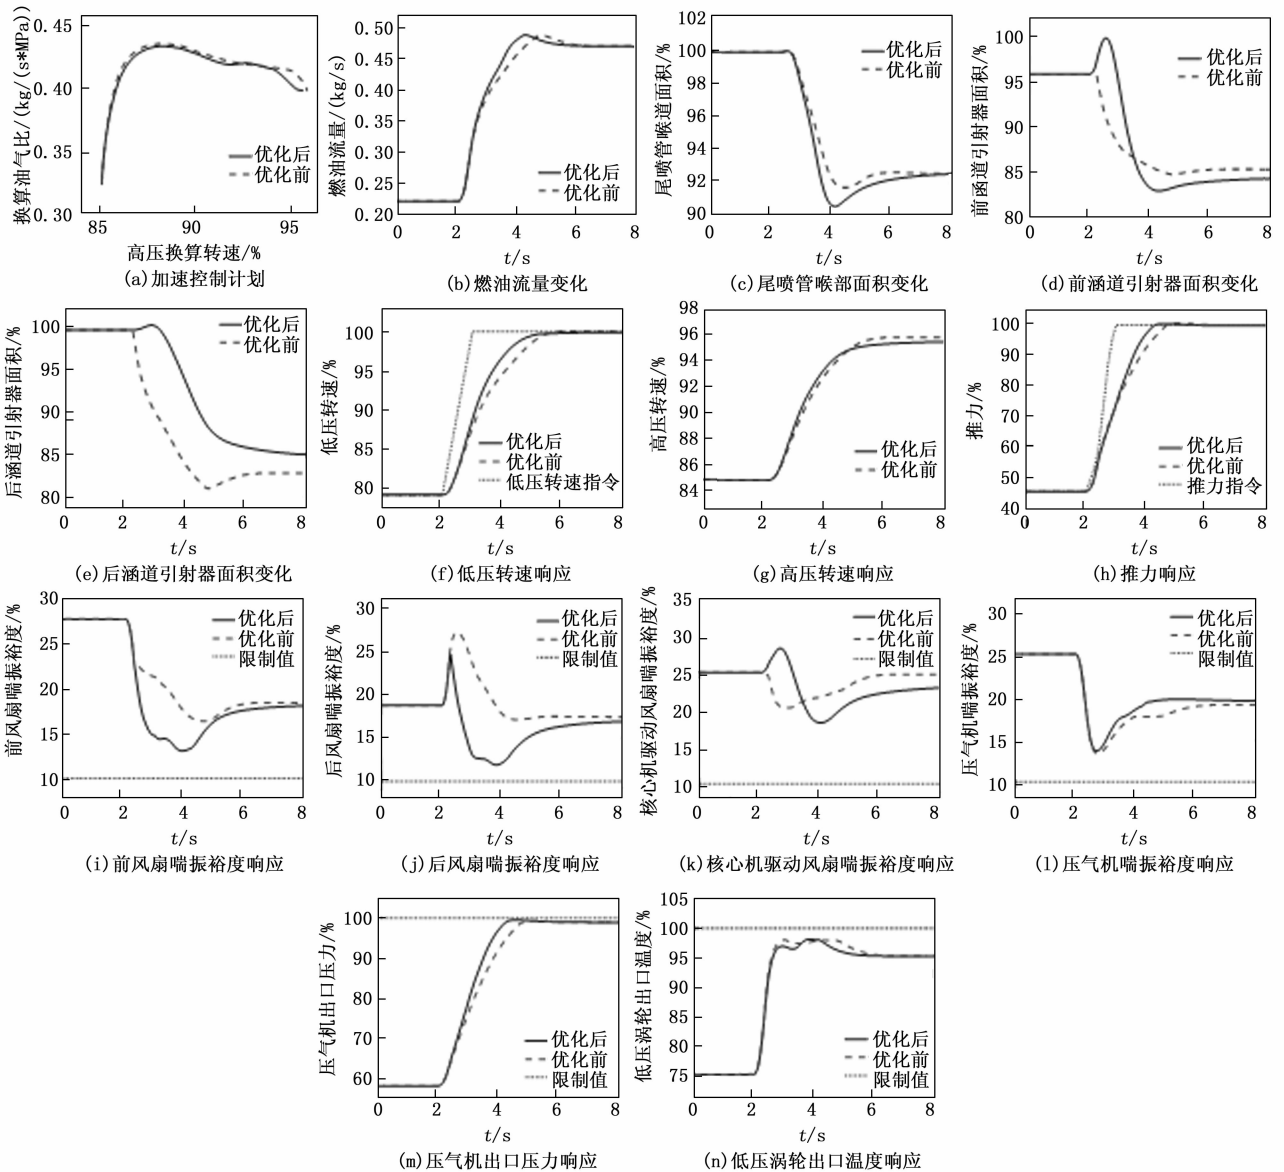


图 8 三外涵模式加速过程仿真结果 ($H=8\text{ km}$, $Ma=0.9$)

6 结束语

本文以三外涵变循环发动机数学模型为基础,开展了基于模型的变循环发动机加速控制计划优化方法研究,提出了一种开环控制变量和闭环控制变量耦合优化方法,采用了增加乘法层的神经网络状态空间模型建模方法,构建了在线学习的预测模型;基于贝塞尔曲线构建开环几何机构控制计划,可以保证几何机构变化兼顾加速过程的总体性能;构建双回路控制计划优化系统,充分利用了多变量控制的优势,外回路采用樽海鞘链群智能算法对 A_{RAVBI} 、 A_{FAVBI} 或 A_{LT} 进行优化,内回路采用模型预测控制优化当前 A_{FAVBI} 、 A_{RAVBI} 、 A_{LT} 情况下的 W_{fm} 和 A_s , 获得满足约束条件下的最优加速性能。相比采用原定开环几何机构调节计划,优化后的随低压转速

开环调节的几何机构,能够大大提高发动机的加速性能。后期将进一步研究 A_{FAVBI} 、 A_{RAVBI} 、 A_{LT} 随高压转速变化的控制计划,以及控制计划在包线及寿命周期内的控制规律,全面提高发动机的加速性能。

参考文献:

[1] 方昌德. 变循环发动机 [J]. 燃气涡轮试验与研究, 2004 (3): 1-5.
 [2] 陈尚晰, 李秋红, 周婷, 等. 基于数据驱动的变循环发动机多变量自适应控制算法研究 [J]. 推进技术, 2022, 43 (8): 371-382.
 [3] 王荣, 周文祥, 黄金泉等. 涡扇发动机加减速控制规律设计的定状态法 [J]. 航空动力学报, 2022, 37 (12): 2896-2904.

- [4] YINFENG L I U, JAFARI S, NIKOLAIDIS T. Advanced optimization of gas turbine aero-engine transient performance using linkage-learning genetic algorithm; Part II, optimization in flight mission and controller gains correlation development [J]. Chinese Journal of Aeronautics, 2021, 34 (4): 568-588.
- [5] GAO WENBO, ZHOU XIN, PAN MUXUAN, et al. Acceleration control strategy for aero-engines based on model-free deep reinforcement learning method [J]. Aerospace Science and Technology, 2022, 120: 107248.
- [6] 陆军, 郭迎清, 王磊. 航空发动机过渡态最优控制规律设计的新方法 [J]. 航空动力学报, 2012, 27 (8): 1914-1920.
- [7] ZHENG Q, ZHANG H. A global optimization control for turbo-fan engine acceleration schedule design [J]. Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, 2018, 232 (2): 308-316.
- [8] YINFENG L I U, JAFARI S, NIKOLAIDIS T. Advanced optimization of gas turbine aero-engine transient performance using linkage-learning genetic algorithm; Part I, building blocks detection and optimization in runway [J]. Chinese Journal of Aeronautics, 2021, 34 (4): 526-539.
- [9] 时培燕, 蔡林峰, 郭江维, 等. 基于 GA-SQP 的航空发动机加速寻优控制 [J]. 计算机与现代化, 2014, 0 (1): 62-66.
- [10] YE Y, WANG Z, ZHANG X. Cascade ensemble-RBF-based optimization algorithm for aero-engine transient control schedule design optimization [J]. Aerospace Science and Technology, 2021, 115: 106779.
- [11] 刘子赫, 郑前钢, 刘明磊, 等. 涡扇发动机全包线加速控制计划改进方法研究 [J]. 推进技术, 2022, 43 (1): 346-353.
- [12] 李宇琛, 李秋红, 张新晟, 等. 基于主动切换逻辑的涡扇发动机 $N\text{-dot}$ 控制方法 [J]. 北京航空航天大学学报, 2023, 49 (11): 3156-3166.
- [13] ACHGILL D M, ZAGARANSKI R D. Adaptive fuel control testing [C] // American Helicopter Society 41th Annual Forum Proceedings. Fort Worth, US: American Helicopter Society, 1985: 197-211.
- [14] 时瑞军, 樊思齐. 基于遗传算法的涡扇发动机多变量加速寻优控制 [J]. 推进技术, 2003 (4): 357-360.
- [15] GU Z, PANG S, LI Y, et al. Turbo-fan engine acceleration control schedule optimization based on DNN-LPV model [J]. Aerospace Science and Technology, 2022, 128: 107797.
- [16] CHEN M, ZHANG J, TANG H. Performance analysis of a three-stream adaptive cycle engine during throttling [J]. International Journal of Aerospace Engineering, 2018 (4): 1-16.
- [17] LYU Y, TANG H, CHEN M. A study on combined variable geometries regulation of adaptive cycle engine during throttling [J]. Applied Sciences, 2016, 6 (12): 374-374.
- [18] 朱白彬. 三外涵变循环发动机控制计划及控制算法设计 [D]. 南京: 南京航空航天大学, 2020.
- [19] LINYUAN JIA, YUCHUN C, CHENG R, et al. Designing method of acceleration and deceleration control schedule for variable cycle engine [J]. Chinese Journal of Aeronautics, 2021, 34 (5): 27-38.
- [20] ZHAO F J, DU X, MA Y H, et al. Optimization and Control for Variable Cycle Engine Based on Grey Wolf Algorithm [J]. IFAC-PapersOnLine, 2021, 54 (10): 465-470.
- [21] 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.
- [22] YASEEN Z M, FARIS H, AL-ANSARI N. Hybridized extreme learning machine model with salp swarm algorithm: a novel predictive model for hydrological application [J]. Complexity, 2020: 1-14.
- [23] 李玉, 江雨燕, 赵双双, 等. 一种基于交替方向乘子法改进的模型预测控制方法 [J]. 数值计算与计算机应用, 2019, 40 (1): 11-20.
- [24] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks [C] // 2004 IEEE international joint conference on neural networks (IEEE Cat. No. 04CH37541). Ieee, 2004, 2: 985-990.
- [25] 强明辉, 张京娥. 基于 MATLAB 的递推最小二乘法辨识与仿真 [J]. 自动化与仪器仪表, 2008 (6): 4-5.
- [26] LIANG N Y, HUANG G B, SARATCHANDRAN P, et al. A fast and accurate online sequential learning algorithm for feedforward networks [J]. IEEE Transactions on neural networks, 2006, 17 (6): 1411-1423.
- [27] 柯宏威. 预测控制在发动机过渡态控制中的应用研究 [D]. 南京: 南京航空航天大学, 2020: 25-48.
- [28] 单睿斌, 李秋红, 何凤林, 等. 基于 ADMM 算法的航空发动机模型预测控制 [J]. 北京航空航天大学学报, 2019, 45 (6): 1240-1247.
- [29] 姚玮, 罗建军, 谢剑锋, 等. 连续推力机轨道优化设计的贝塞尔曲线法 [J]. 宇航学报, 2019, 40 (11): 1274-1285.