

基于 SSA-NARX 的航空发动机动态特性参数辨识方法

陈子桥¹, 洪军², 肖刚², 温新¹

(1. 上海交通大学 机械与动力工程学院, 上海 200240; 2. 上海交通大学 航空航天学院, 上海 200240)

摘要: 针对航空发动机动态特性的建模问题, 提出一种基于麻雀搜索算法 (SSA) 优化 NARX 神经网络的动态特性参数辨识方法。利用 SSA 对 NARX 网络的权值与偏置进行迭代寻优, 使网络具备更高的准确度与泛化能力; 利用优化后的 NARX 网络进行动态参数辨识; 使用航空发动机飞行测试数据集进行了仿真测试。结果表明: SSA-NARX 方法明显优于 NARX 和 PSO-NARX 方法。SSA-NARX 方法的输出参数 N_1, N_2 和排气温度 (EGT) 与真实值的最大相对误差绝对值 δ_{\max} 分别降低至 3.81%, 1.24% 和 3.47%; 动态特性指标 T_i 与 T_t 与真实值的相对误差均小于 5%; 经 10 次交叉试验, 参数 N_1, N_2 和 EGT 的测试结果均方根误差均值 $RMSE_m$ 分别为 0.29, 0.18 和 1.50。模型的准确性、实时性与稳健性均满足了仿真需求。

关键词: 航空发动机; 数据驱动; 麻雀搜索算法; 非线性自回归神经网络; 动态模型辨识

中图分类号: TK231 **文献标识码:** A **DOI:** 10.16146/j.cnki.rndlgc.2024.01.023

[引用本文格式] 陈子桥, 洪军, 肖刚, 等. 基于 SSA-NARX 的航空发动机动态特性参数辨识方法 [J]. 热能动力工程, 2024, 39(1): 205-215. CHEN Zi-qiao, HONG Jun, XIAO Gang, et al. A methodology for aero-engine dynamic characteristic parameter identification based on SSA-NARX [J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(1): 205-215.

A Methodology for Aero-engine Dynamic Characteristic Parameter Identification based on SSA-NARX

CHEN Zi-qiao¹, HONG Jun², XIAO Gang², WEN Xin¹

(1. School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai, China, Post Code: 200240;

2. School of Aeronautics and Astronautics, Shanghai Jiao Tong University, Shanghai, China, Post Code: 200240)

Abstract: A dynamic characteristic parameter identification method based on the sparrow search algorithm (SSA) and nonlinear autoregressive exogenous (NARX) neural network was proposed for the aero-engine dynamic characteristics modeling. SSA was used to optimize the weights and biases of the NARX network iteratively to enhance its accuracy and generalization capability; the optimized NARX network was used for identifying dynamic characteristic parameters; simulation tests were conducted using flight test dataset. The results show that SSA-NARX method is better than the NARX and PSO-NARX methods obviously. By the SSA-NARX method, the maximum relative error absolute values δ_{\max} between the output parameters N_1, N_2 and exhaust gas temperature (EGT) and actual values are reduced to 3.81%, 1.24% and 3.47% respectively; the relative errors between the dynamic characteristic indicators T_i and T_t and actual values are less than 5%; through ten cross tests, the mean values of root mean square errors ($RMSE_m$) of validation results corresponding to parameters N_1, N_2 and EGT are 0.29, 0.18 and 1.50 respectively. The accuracy, real-time performance and robustness of the model meet the requirements for simulation.

Key words: aero-engine, data driven, sparrow search algorithm (SSA), nonlinear autoregressive exogenous (NARX) neural network, dynamic model identification

引言

航空发动机直接影响了飞行器的整体性能、可靠性和经济性,其仿真建模技术对飞行器的全生命周期具有重大意义^[1]。精准的仿真模型在研制过程中可提高研发效率、减少实物试验、降低开发成本^[2],在使用过程中可协助预测系统响应、检测健康状况、评估使用寿命等^[3]。

航空发动机是一种复杂的非线性时变系统,当前对其建模的方法主要分为两大类^[4]:基于组成部件解析的理论建模方法、基于数据驱动的系统辨识方法。半个世纪以来,随着发动机制造工艺逐渐复杂,依据物理机理建立准确的数学解析模型更加困难^[5]。近年来,随着机器学习算法和储存、计算资源的快速发展,使用数据驱动的系统辨识方法从飞行测试数据中建立满足系统容差需求的发动机模型^[6]成为该领域的研究热点。学者尝试使用该方法进行航空发动机动态特性的模型辨识,并取得了良好的拟合效果。如 Wang 等人^[7]利用稀疏最小支撑向量机(Support Vector Machine, SVM)建立发动机动态过程模型; Chati 等人^[8]通过飞行轨迹数据对进近阶段的燃料流量进行高斯过程回归预测; 郑斐华等人^[9]基于约束卡尔曼滤波算法建立了航空发动机状态变量模型。但以上系统辨识方法均不包含反馈单元,缺少对时序系统过往时刻状态的记忆功能,普遍存在对动态特性映射能力差的问题。

针对动态系统仿真准确度提高的需求,在神经网络输入层中加入时延与历史输出数据,构成了具有外部输入非线性自回归神经网络(Nonlinear Autoregressive Exogenous, NARX),使其对时序系统有较好的非线性映射能力^[10]。国内外研究人员对该网络结构和算法进行了大量研究和建模应用,验证了 NARX 在发动机时序动态建模的有效性。耿宏等人^[11]利用 NARX 建立了发动机参数动态辨识模型,并应用于机务维修训练器仿真系统; Giorgi 等人^[12]通过循环神经网络对瞬态操作引起的发动机排气温度动态变化进行有效预测; Asgari 等人^[13]使用 NARX 建立了某型单轴燃气涡轮起动阶段参数模型,并对模型进行了仿真试验。然而, NARX 网络权值及偏置的初值均为随机函数生成,增大了辨识结

果的不稳定性,影响了模型准确性与稳健性。

使用优化算法对 NARX 网络初值参数进行寻优,可提升动态辨识模型的准确性与稳定性。麻雀搜索算法(Sparrow Search Algorithm, SSA)是薛建凯等人^[14]根据麻雀觅食并逃避天敌行为而提出的群智能优化算法,该算法在收敛速度、稳定性与收敛精度上均优于灰狼优化算法、粒子群算法、引力搜索算法^[15],且面对多峰函数时能够快速跳出局部极值,减小了陷入局部最优的概率,具有更优秀的全局搜索能力。该算法在故障诊断^[16]、轨迹规划^[17]与图像处理^[18]等领域中已有广泛应用。然而,目前尚未在航空发动机建模领域使用。利用 SSA 对 NARX 网络初始参数进行优化,可使网络对非线性系统具有更好的逼近能力。

综上,本文采用麻雀搜索算法-外部输入非线性自回归神经网络(Sparrow Search Algorithm - Non-linear Autoregressive Exogenous, SSA-NARX)对航空发动机动态特性进行辨识。首先,依据发动机原理建立参数动态模型,确立 NARX 网络结构。然后,利用 SSA 优化寻找 NARX 网络的初始参数,使用优化后网络对动态特性进行系统辨识。最后,利用飞行测试数据验证了发动机动态特性模型的准确性、实时性与稳定性。

1 SSA-NARX 原理

本节介绍了基于 SSA-NARX 的航空发动机动态特性建模的原理,阐述了 NARX 网络结构、SSA 算法流程和使用 SSA 对 NARX 初始参数迭代寻优的步骤。

1.1 NARX

NARX^[19]为具有外部输入的非线性自回归模型,其数学描述为:

$$\mathbf{Y}_t = f[\mathbf{X}_t, \dots, \mathbf{X}_{t-m}, \mathbf{Y}_{t-1}, \dots, \mathbf{Y}_{t-n}] \quad (1)$$

式中: \mathbf{Y} —输出变量; \mathbf{X} —输入变量; t —目前时刻; \mathbf{X}_{t-m} —在 m 时延前的输入变量; \mathbf{Y}_{t-n} —在 n 时延前的输出变量; $f[\cdot]$ —神经网络拟合的非线性函数。

NARX 神经网络结构如图 1 所示,包括含时延的输入层、隐含层和输出层,通过设置输入与输出的时延长度 m 和 n 完成网络的结构搭建。训练模型时采用“开环”结构,在输入层使用真实输出进行训练,提升网络准确性;训练完成后,采用虚线所示

“闭环”预测结构,将模型输出直接引回输入层,可实现预测功能。

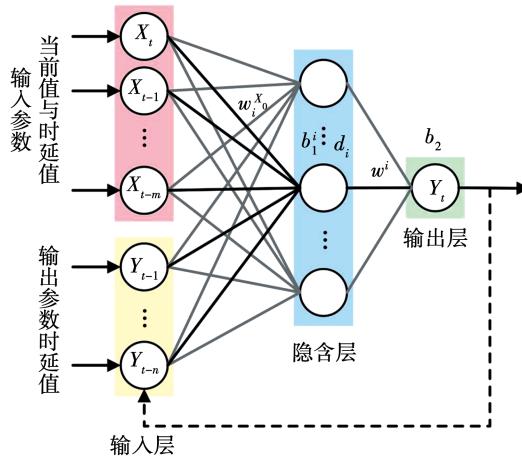


图1 NARX 神经网络结构

Fig. 1 NARX neural network structure

某 t 时刻第 i 个隐含层节点的输出 d_i 为:

$$d_i = f_a \left(\sum_{p=1}^m w_i^{X_p} X_{t-p} + \sum_{q=1}^n w_i^{Y_q} Y_{t-q} + b_1^i \right) \quad (2)$$

式中: p —输入时延阶次; q —反馈输出时延阶次; $w_i^{X_p}$ —输入 X_{t-p} 与第 i 个隐含层节点间的权值; $w_i^{Y_q}$ —输出反馈 Y_{t-q} 与节点间的权值; b_1^i —第 i 个隐含层节点的偏置; f_a —隐含层的激活函数,选取 tanh 双曲正切函数。

某 t 时刻输出层输出 Y_t 为:

$$Y_t = f_a \left(\sum_{r=1}^k w_r^i d_r^i + b_2 \right) \quad (3)$$

式中: k —隐含层节点个数; w^i —第 i 个隐含层节点与输出层节点间的权值; b_2 —输出层节点的偏置; f_a —输出层激活函数,选取 linear 线性函数。

1.2 SSA

SSA^[14]模拟麻雀觅食过程获得优化问题的解。假设在 D 维搜索空间内存在 N 只麻雀,记第 i 只麻雀位置为 $L_i = [l_{i1}, \dots, l_{id}, \dots, l_{iD}]$, $i = 1, 2, \dots, N$,其中 l_{id} 表示第 i 只麻雀在第 d 维的位置。将麻雀以适应度从高到低进行排序,前 10% 至 20% 为发现者,其余为加入者。种群中同时有 10% 至 20% 负责侦查的预警者。发现者比加入者有更大的搜索范围,加入者跟随发现者寻觅食物,预警者侦查天敌并引领种群至安全区域。

SSA 首先随机初始化麻雀种群,每只麻雀所有位置都随机取值于 $[0, 1]$ 区间。设置最大迭代次数 T 。在每步迭代中更新发现者、加入者与预警者的位置,获取当前适应度最优个体,若优于上一次迭代结果则进行更新,否则不变。迭代至设定次数时得最佳适应度和全局最优位置。

发现者位置更新描述如下:

$$l_{id}^{t+1} = \begin{cases} l_{id}^t \cdot \exp\left(\frac{-i}{\alpha T}\right), & R_2 < S_r \\ l_{id}^t + Q \cdot E, & R_2 \geq S_r \end{cases} \quad (4)$$

式中: t —目前迭代次数; α — $[0, 1]$ 间的随机数; Q —服从标准正态分布的随机数; E —元素均为 1 的 $1 \times D$ 矩阵; R_2 —预警值, $R_2 \in [0, 1]$; S_r —安全值, $S_r \in [0.5, 1]$ 。

加入者位置更新表述如下:

$$l_{id}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{l_{worst}^t - l_{id}^t}{i^2}\right), & i > \frac{N}{2} \\ l_{best}^{t+1} + |l_{id}^t - l_{best}^{t+1}| \cdot A^+ \cdot L, & \text{其他} \end{cases} \quad (5)$$

式中: l_{best}^{t+1} —目前发现者占据的最优位置; l_{worst}^t —目前全局最差位置; A^+ —元素随机为 1 或 -1 的 $1 \times D$ 矩阵,且 $A^+ = A^T (AA^T)^{-1}$ 。

预警者位置更新表述如下:

$$l_{id}^{t+1} = \begin{cases} l_{best}^t + \beta \cdot |l_{id}^t - l_{best}^t|, & f_i > f_b \\ l_{id}^t + K \cdot \frac{|l_{id}^t - l_{worst}^t|}{|f_i - f_w| + \varepsilon}, & f_i = f_b \end{cases} \quad (6)$$

式中: β —服从均值为 0,方差为 1 的正态分布随机数,是步长控制参数; K —表征麻雀移动方向的随机数,同时也是补偿控制参数, $K \in [-1, 1]$; ε —极小的参数,以避免分母出现零; f_i —第 i 只麻雀的适应度; f_b —一种群当前最优适应度; f_w —一种群当前最差适应度。

1.3 优化流程

对于输入参数为 X 、输出参数为 Y 的系统,SSA-NARX 方法的建模思路为寻求非线性函数 f ,使得模型输出值 $\hat{Y} = f(X)$ 与真实输出参数 Y 之间的误差最小。为解决 NARX 权值和偏置初值由随机函数生成带来的辨识结果的不稳定问题,首先使用 SSA 对 NARX 的权值与偏置进行迭代寻优,然后将优化结

果赋值给 NARX 权值与偏置的初值再进行训练,以保证所得辨识模型结果的稳定性与准确性。在 SSA 优化过程中,每只麻雀的位置 L_i 由权值及偏置组成:

$$\mathbf{L}_i = [w_i^0, w_i^1 \cdots, w_i^{m+n}, b_1^1, \cdots, b_1^k, w^1, \cdots, w^k, b_2] \quad (7)$$

式中: w_i —输入层与隐含层间的权值,共 $m + n + 1$ 个; k —隐含层节点个数; b_i —第 i 个隐含层节点的偏置,共 k 个; w —输入层与隐含层间的权值,共 k 个; b_2 —输出层的偏置,共 1 个。

SSA 寻优目标是使个体的适应度函数值 $f_{\text{fitness}}(\mathbf{L}_i)$ 最小,即模型输出 $\hat{\mathbf{Y}}$ 与真实输出 \mathbf{Y} 的均方误差最小。适应度函数值越小,表明该位置适应度越好。寻优目标公式表达为:

$$\min f_{\text{fitness}}(\mathbf{L}_i) = \frac{1}{N} \sum_{i=1}^N (\hat{\mathbf{Y}}_i - \mathbf{Y}_i)^2 \quad (8)$$

SSA-NARX 发动机动态模型辨识方法的具体流程如图 2 所示。

步骤 1:根据航空发动机工作原理,建立动态模型,确定输入参数、输出参数与函数关系。

步骤 2:从试飞数据中提取动态变化特征段,对数据集进行分类、归一化等预处理,划分神经网络的训练集与测试集。

步骤 3:依据发动机动态特性系统辨识的目标,确定 NARX 网络结构,包括输入与输出的时延阶次、隐含层个数、隐含层神经元个数。

步骤 4:利用 SSA 对如式(7)表示的 NARX 权重及偏置进行寻优。

首先,设置 SSA 优化算法的种群数量 N 与最大迭代次数 T 。初始化麻雀种群位置,将每支麻雀位置代表的权值与偏置赋值给 NARX 网络,并以式(8)计算出初始种群的适应度,排序并选择出当前最优值和最差值。

然后,使用式(4)至式(6)更新发现者、加入者与预警者的位置。最后获取当前个体适应度最优值与最优位置,若优于上一次迭代结果则进行更新,否则不变。

持续进行迭代操作直至最大迭代次数,最终得到全局最优位置,对应 SSA 得到的 NARX 网络最优权值及偏置初值。

步骤 5:将 SSA 寻优结果设定为 NARX 的权值

与偏置初值,以训练集数据样本为驱动,对建立的发动机动态模型进行神经网络求解,获得 SSA-NARX 航空发动机动态特性模型。

步骤 6:在线测试阶段,对于传感器获得的实时发动机工况数据,输入 SSA-NARX 模型,获得输出参数的动态变化特性。

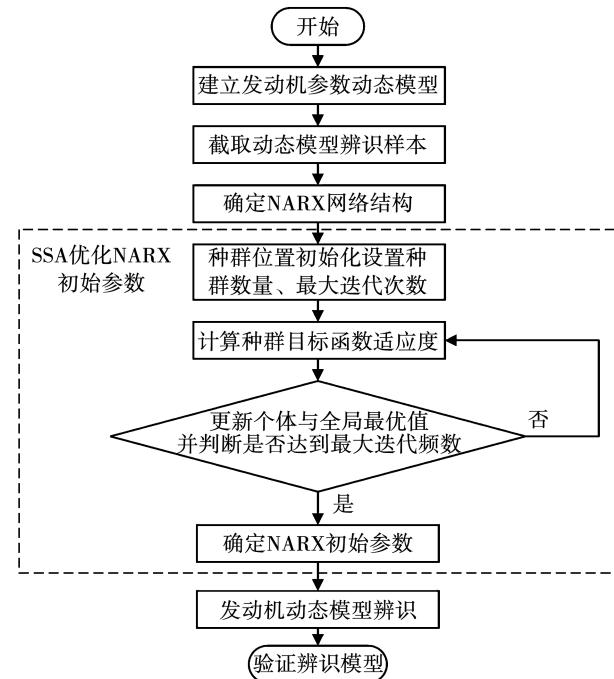


图 2 SSA-NARX 发动机动态模型辨识流程图

Fig. 2 Flow diagram of SSA-NARX engine dynamic model identification

2 数据处理与建模

2.1 数据简介与预处理

本研究使用的数据集是在商用飞机飞行测试中采集的发动机系统传感器数据。在飞行测试中,会根据检测内容选择不同的测试科目,各类传感器同时记录着飞行参数,以监测航空发动机在不同条件下的性能与健康状态。出于商业考虑,在建模时使用最大最小法(Min-Max Normalization)对数据进行了归一化处理,将所有参数在数据的最大值与最小值间进行线性映射,区间范围为 $[0, 1]$ 。归一化操作不会对系统辨识结果准确度产生影响,结果分析中通过逆归一化操作还原了对应物理量真实数值的模型输出结果。

油门杆角度 θ (Throttle Lever Angle, TLA) 是发

动机输出功率的重要控制量,调整 θ 会影响发动机动态特性。针对航空发动机动态特性研究的问题,选取包含“快速推拉油门杆”测试科目的试飞数据作为研究对象。图3(c)为某次测试的 θ 变化数据,横坐标为代表时间的采样点数,纵坐标为归一化 θ 值。该段数据包含以32 Hz为采样频率的 3×10^5 个采样点,测试过程中多次快速推拉油门杆导致 θ 产生陡峭变化。图3(a)为推杆加速过程的放大图, θ 自0平稳上升至0.76,图3(b)为拉杆减速过程, θ 自0.91迅速下降至0。由于加减速过程中 θ 变化的速率、航空发动机的工作状态存在较大差异,对应着不同的动态模型,因此对加速阶段与减速阶段分别进行建模。

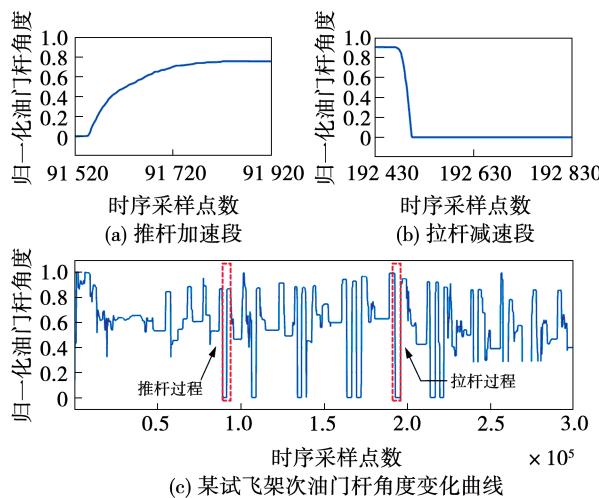


图3 油门杆角度变化图

Fig. 3 Variation diagrams of throttle lever angle

图4为加速阶段上述传感器数据的变化。图中,其他传感器数据包括气压高度 H 、大气静温 T 和马赫数 Ma 。由图可知,随着 θ 增大,发动机加速, T 与 Ma 上升, H 下降。受飞行试验成本与周期限制,本研究基于5组测试“快速推拉油门杆”科目的试飞测试数据,包括了不同飞行速度、飞行高度与环境温度的多种飞行工况,发动机工作点几乎涵盖了整个飞行包线,保证了训练数据集的完备性。从以上试飞架次数据中共提取得63段特征加速过程,包含17 126个采样点,有40段 θ 变化范围超过70°,保证了训练数据集的足量性。按8:2的比例随机分配训练集与测试集,得到51组用于发动机加速动态特性辨识的训练集和12组用于验证加速模型的测试集。

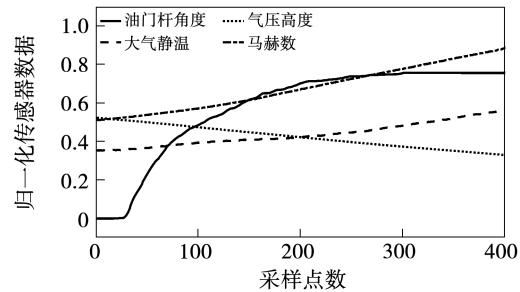


图4 某次推杆加速阶段传感器数据图

Fig. 4 Sensor data diagram in one acceleration process

如图5所示为前述减速阶段传感器数据图,与图4所示的过程相反,随着 θ 减小,发动机减速, T 与 Ma 平稳, H 上升。从上述5组试飞架次数据中共提取得52段减速过程,包含10 923个采样点,有42段 θ 变化范围超过70°。同样按8:2的比例分配训练集与测试集,分别得到42组用于减速动态特性辨识的训练集和10组测试集。

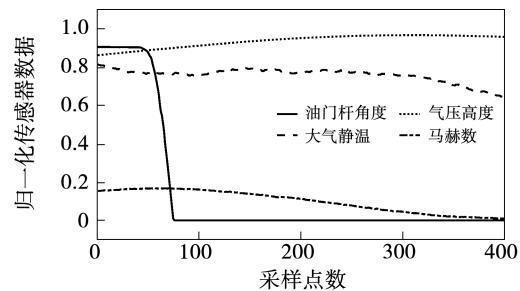


图5 某次拉杆减速阶段传感器数据图

Fig. 5 Sensor data diagram in one deceleration process

2.2 模型描述

在发动机动态特性模型辨识过程中,根据航空发动机原理^[20],使用油门杆角度 θ 、气压高度 H 、大气静温 T 和马赫数 Ma 构建系统模型的输入矩阵 $X = [\theta, H, T, Ma]$ 。 θ 为外部控制量,当推拉油门引起 θ 变化时,发动机数字电子控制器会相应改变燃油活门开度,调整燃料流量大小,以控制发动机推力与工作状态。同时,发动机的性能与油耗也受飞行速度、飞行高度与大气温度影响,故也将 Ma 、 H 和 T 选为输入参数。通常选取低压涡轮转速 N_1 、高压涡轮转速 N_2 和排气温度EGT(Exhaust Gas Temperature)表征发动机的工作状态,因此输出参数矩阵 $Y = [N_1, N_2, EGT]$ 。系统建模的过程即寻找输出参数与输入参数的函数关系 f :

$$\mathbf{Y} = f(\mathbf{X}) \quad (9)$$

航空发动机加速过程的当前工作状态与过去时刻的工作状态密切相关,因此在构建系统模型的过程中使用 NARX 方法,考虑当前时刻的状态输入值(\mathbf{X}_t)与 m 个历史时刻的输入值($\mathbf{X}_{t-1}, \mathbf{X}_{t-2}, \dots, \mathbf{X}_{t-m}$,其中 m 为输入值时延阶次)与 n 个历史时刻的输出值($\mathbf{Y}_{t-1}, \mathbf{Y}_{t-2}, \dots, \mathbf{Y}_{t-n}$,其中 n 为输出值时延阶次),因此,构建的动态系统模型为:

$$\mathbf{Y}_{t+1} = f(\mathbf{X}_t, \dots, \mathbf{X}_{t-m}, \mathbf{Y}_t, \dots, \mathbf{Y}_{t-n}) \quad (10)$$

在本研究针对的航空发动机动态响应系统中,激励主要为 θ 的变化,它通过发动机数字电子控制器改变燃油活门的开度以影响燃料流量大小^[21],系统响应为发动机工作状态的变化,具体表征为 N_1 , N_2 和 EGT 的改变。使用数字电子控制器可实现航空发动机稳定和瞬态控制^[22],极大地减小了现代航空发动机控制系统的时延。国内外针对发动机动态激励响应建模的研究^[11,23],采用了较低的采样频率(1 Hz),在此条件下将输入输出参数延时阶次设置为 2,满足了发动机仿真准确度需求。本研究同样设定输入时延阶次 m 与输出时延阶次 n 为 2,隐含层神经元个数设为 $10^{[24]}$,采用 Levenberg-Marquardt 优化算法进行网络训练。使用 SSA 对网络特征参数求解时,权衡算法收敛性与求解时间^[25]将最大迭代步数设为 100,种群数量设为 30。

2.3 评价指标

为评价发动机动态辨识模型输出的准确性,定义预测值与真实值的最大相对误差绝对值 δ_{\max} ,其表达式为:

$$\delta_{\max} = \max \left\{ \left| \frac{\hat{\mathbf{Y}}_1 - \mathbf{Y}_1}{\mathbf{Y}_1} \right|, \dots, \left| \frac{\hat{\mathbf{Y}}_i - \mathbf{Y}_i}{\mathbf{Y}_i} \right|, \dots, \left| \frac{\hat{\mathbf{Y}}_n - \mathbf{Y}_n}{\mathbf{Y}_n} \right| \right\} \times 100\% \quad (11)$$

式中: $\hat{\mathbf{Y}}_i$ —测试段第 i 个辨识模型输出参数值; \mathbf{Y}_i —测试段第 i 个输出参数实际值; n —测试段时序总长度。 δ_{\max} 记录了动态辨识模型预测结果与真实值的最大偏差, δ_{\max} 越小,发动机动态模型准确度越高。

对于发动机动态特性辨识模型,模型的响应实时性(即模型预测达到指定输出功率的时间准确性)也十分重要。引入动态特性指标参数 T_i 及 T_t 验证所得发动机模型的动态特性优劣^[26],其定义如图 6 所示。图 6 记录发动机输出参数 \mathbf{Y} 动态变化

完整过程,横轴原点为油门杆变化起始时刻,其中 t_1 为参数 \mathbf{Y} 达到其响应量 10% 的时刻, t_2 达到参数 90% 响应量的时刻, T_i 为时间段 0 至 t_1 , T_t 为时间段 t_1 至 t_2 。对真实飞行参数数据与辨识动态模型分别计算 T_i 与 T_t ,依据《飞机飞行模拟机鉴定性能标准》^[27],两者相对误差在 $\pm 10\%$ 以内时,判定发动机动态模型符合仿真测试标准,且相对误差越小,说明模型实时性越好。

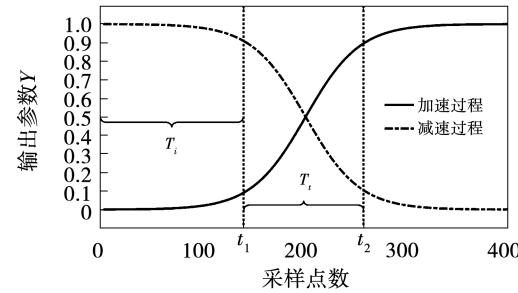


图 6 动态特性指标参数 T_i 与 T_t 示意图

Fig. 6 Schematic diagram of dynamic characteristic parameters T_i and T_t

为验证发动机动态辨识模型在动态变化过程中的稳健度与泛化能力,定义多次测试结果的均方根误差均值 $RMSE_m$,其表达式为:

$$\begin{cases} RMSE_j = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{Y}_i - Y_i)^2} \\ RMSE_m = \frac{1}{M} \sum_{j=1}^M RMSE_j \end{cases} \quad (12)$$

式中: $RMSE_j$ —第 j 组测试结果的均方根误差; N —第 j 组测段时序总长度; M —测试结果总次数。通常, $RMSE_j$ 越小表示模型预测值与实际试飞数据越接近。但单个测试集 $RMSE$ 值较小并不能有效反应模型的稳健性与泛化能力,因此使用多次测试结果的平均值 $RMSE_m$ 进行评估。

3 仿真实验结果分析

为更好地说明本文提出的基于 SSA-NARX 的发动机动态模型的优越性,依据上文介绍的训练集与网络结构,分别使用 NARX、粒子群优化算法-外部输入非线性自回归^[11](Particle Swarm Optimization - Nonlinear Autoregressive Exogenous, PSO-NARX) 和 SSA-NARX 方法对航空发动机参数加速和减速动态

特性进行辨识,用测试集验证,将模型输出与真实值对比来评价模型效果。

对于 PSO 和 SSA 算法的权值与偏置寻优能力,在同一种群初始位置条件下,用相同的种群数量和最大迭代次数进行测试,获得了两种优化算法的迭代收敛曲线,如图 7 所示。其中,SSA 在相同迭代步数下找到了适应度值更小的个体,在第 40 次迭代时已趋于收敛,这取决于其加入者对发现者的追随机制,大多个体选择在当前最优解附近进行下一次位置更新。同时,SSA 在优化求解过程中“停滞期”比 PSO 更少,这是因为侦察者的位置更新方式丰富了种群的多样性,帮助算法更易跳出局部最优解。因此,SSA 在寻优精度与收敛速度上均优于 PSO 算法,可协助 NARX 网络获得更佳的初始权值与偏置,优化辨识模型。

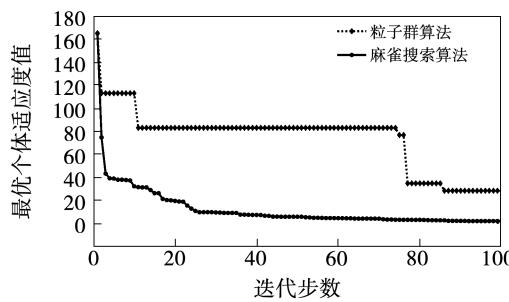


图 7 优化算法迭代收敛曲线比较图

Fig. 7 Comparison of iterative convergence curves for optimization algorithms

图 8~图 10 分别为对某一测试集数据验证所得输出 N_1 、 N_2 和 EGT 的结果误差图。其中图 8(a), 8(b) 和 8(c) 分别为使用 NARX, PSO-NARX 和 SSA-NARX 对加速动态特性的辨识结果, 图 8(d), 8(e) 和 8(f) 为三种方法对减速动态特性的辨识结果。每张子图中上半部分为辨识模型输出与真实试飞数据响应曲线, 标注的动态指标参数点按时序从小到大依次为 T_i 与 T_t , 下半部分为预测值与真实值的相对误差柱状图。

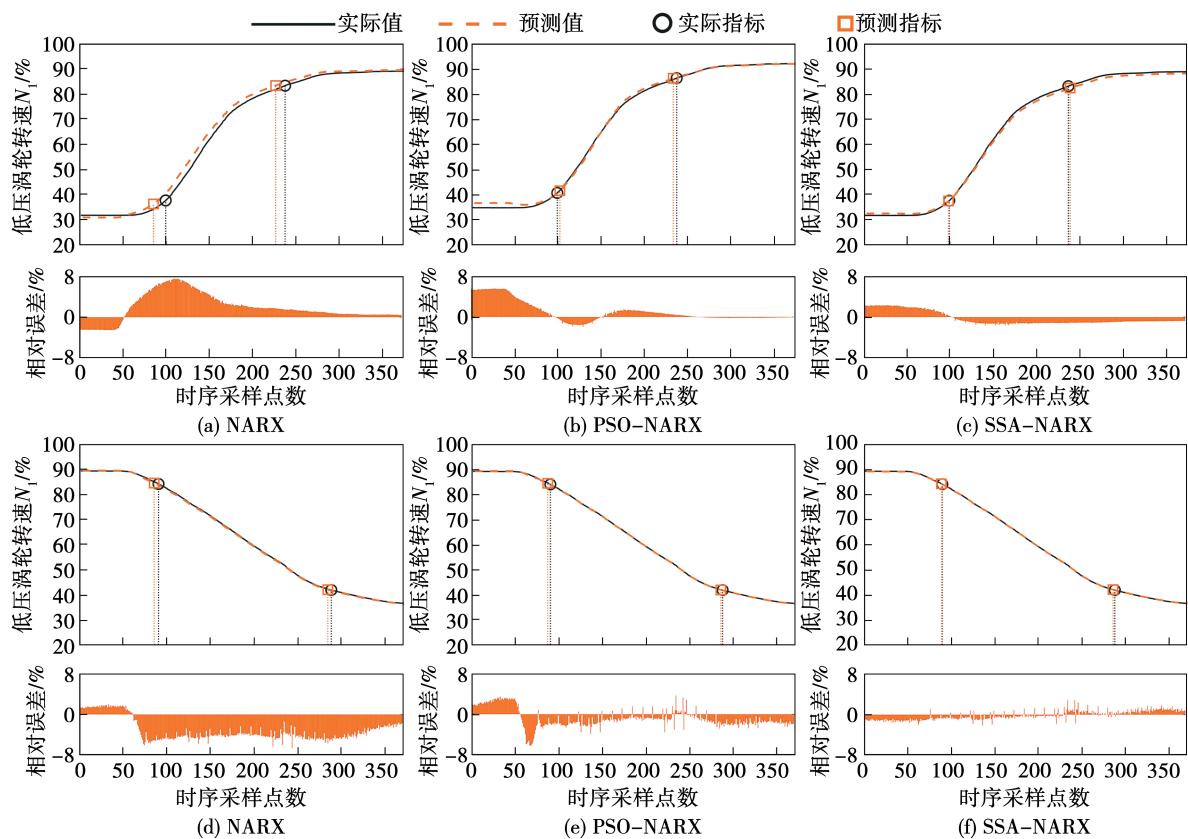
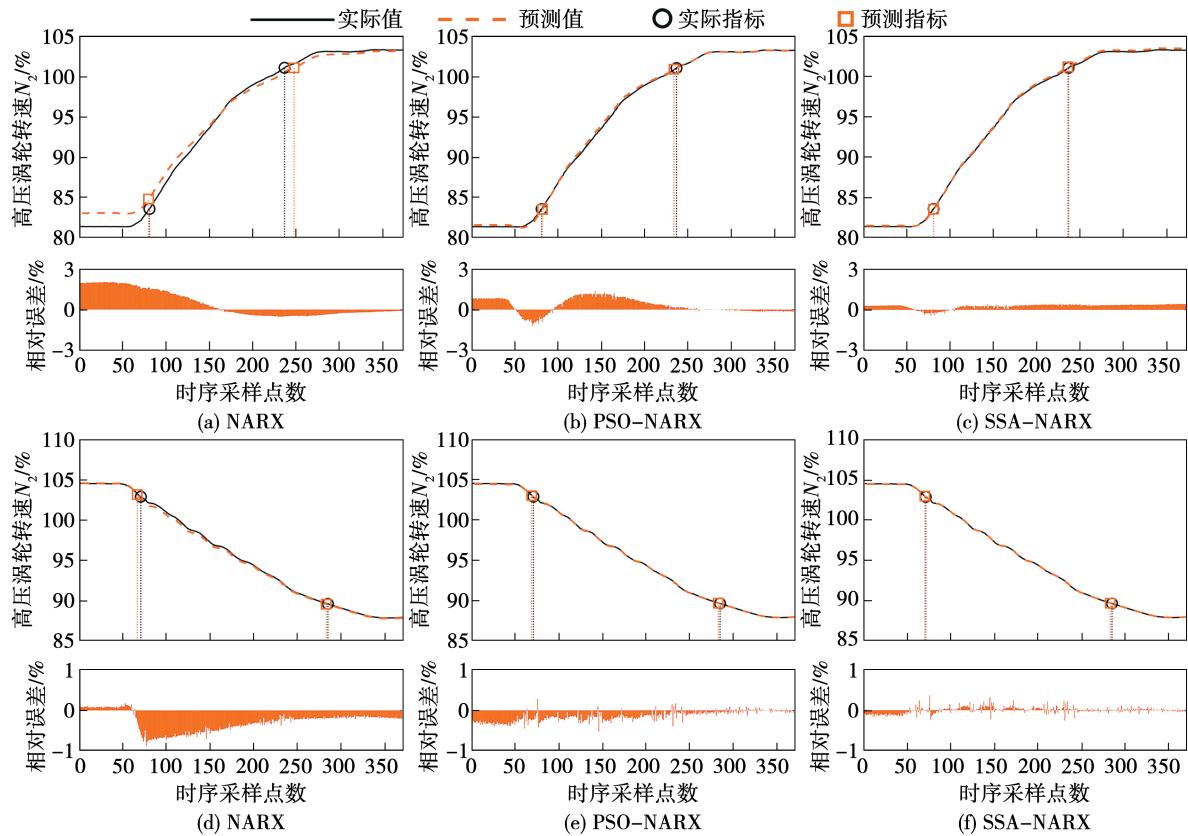
图 8 为参数 N_1 的模型辨识结果对比图。对于推杆加速阶段,由图 8(a)~8(c)可知,三种方法建立的加速动态模型输出大小与趋势和真实值基本吻合,但 T_i 和 T_t 与实际值的偏差存在显著差距。NARX 辨识模型所得参数 N_1 的 T_i 和 T_t 与真实值的相对误

差分别为 -16.8% 和 -13.6% , PSO-NARX 的结果分别为 2.7% 和 -3.4% , 而 SSA-NARX 仅为 -1.2% 和 2.2% 。此外,由相对误差柱状图可知, NARX、PSO-NARX 和 SSA-NARX 模型的输出与真实值的 δ_{\max} 分别为 7.6% 、 6.1% 和 2.4% 。因此,对于推杆加速阶段,所提出的 SSA-NARX 模型的实时性与准确性均具有明显优势。对于拉杆减速阶段(见图 8(d)~8(f)), NARX 辨识所得参数 N_1 的 T_i 和 T_t 与真实值的相对误差分别为 -3.8% 和 -3.1% , PSO-NARX 方法为 -2.8% 和 -1.6% , SSA-NARX 为 -0.9% 和 -1.2% 。前两种方法的实时性相较于加速阶段有所提升,但相对误差仍高于所提出的 SSA-NARX 方法。对于 NARX, PSO-NARX 和 SSA-NARX 三种方法的 δ_{\max} 结果分别为 0.8% 、 0.7% 和 0.3% 。

由上可知,对于推杆加速阶段和拉杆减速阶段的输出参数 N_1 , 与 NARX 和 PSO-NARX 方法相比, SSA-NARX 方法均保持了最优的建模实时性与准确性。

图 9 和图 10 分别为参数 N_2 和 EGT 的模型辨识结果对比图。与参数 N_1 的结果(见图 8)类似,三种方法对于参数 N_2 和 EGT 的预测输出与真实值基本一致, SSA-NARX 模型的 T_i 和 T_t 相对误差值与 δ_{\max} 均最小,模型在准确性、实时性方面显著优于 NARX 和 PSO-NARX 方法。

为进一步检验模型稳健性与泛化效果,对飞行参数数据集进行了 10 次随机训练集与测试集划分, 使用 NARX, PSO-NARX 和 SSA-NARX 分别建模并对测试集中所有数据进行验证,获得了三种方法的输出参数 N_1 、 N_2 和 EGT 的 δ_{\max} 、 T_i 和 T_t 相对误差均值及 10 次交叉验证测试结果均方根误差均值 $RMSE_m$ 。由表 1 可知,使用 NARX 模型参数 T_i 和 T_t 相对误差均值大部分超过了 10% , 不符合仿真测试标准。这是因为 NARX 方法的初始权值与偏置是随机生成的,不确定性影响了输出准确性。而 PSO-NARX 和 SSA-NARX 先用优化算法对网络参数迭代寻优再进行神经网络辨识,使模型的 δ_{\max} 均值和 $RMSE_m$ 均得到有效降低,满足了仿真测试需求。然而,由于 SSA 的寻优精度与收敛速度均优于 PSO,因此 SSA-NARX 方法在实时性与准确度方面优于 PSO-NARX 方法。

图 8 N_1 仿真结果误差图Fig. 8 Simulation results and relative errors of N_1 图 9 N_2 仿真结果误差图Fig. 9 Simulation results and relative errors of N_2

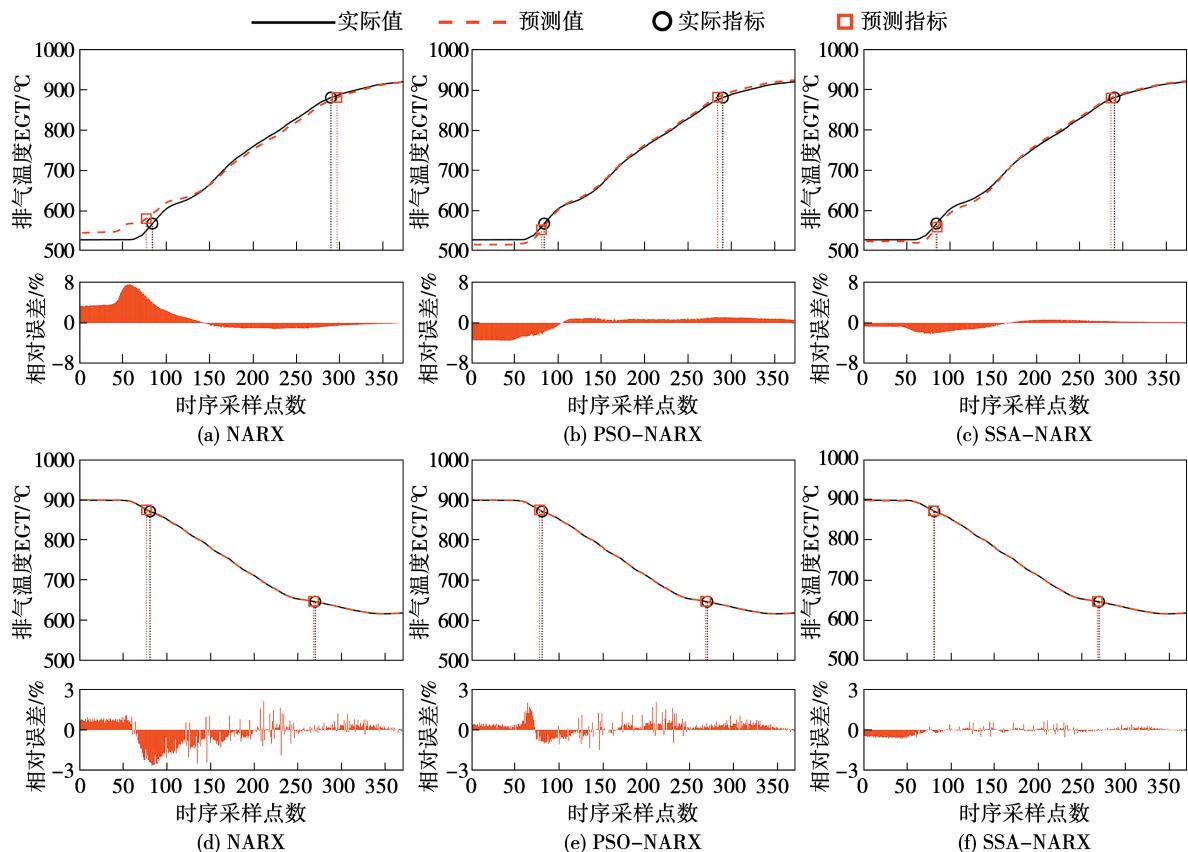


图 10 EGT 仿真结果误差图

Fig. 10 Simulation results and relative errors of EGT

表 1 发动机参数动态模型辨识准确度对比

Tab. 1 Comparison of engine dynamic model identification accuracy

方法	输出参数	δ_{\max}	T_i 相对误 均值/%	T_i 相对误 差均值/%	$RMSE_m$
		均值/%	差均值/%	差均值/%	
NARX	N_1	9.37	15.69	13.87	0.82
	N_2	4.56	4.54	10.48	0.35
	EGT	9.02	12.29	14.08	4.39
PSO-NARX	N_1	6.68	10.24	9.45	0.51
	N_2	2.48	5.51	6.79	0.26
	EGT	5.95	6.80	8.32	2.34
SSA-NARX	N_1	3.81	2.21	3.34	0.29
	N_2	1.24	1.08	2.92	0.18
	EGT	3.47	2.47	4.89	1.50

NARX 网络的航空发动机动态特性参数辨识方法。建立了由 θ, H, T 和 Ma 作为输入, N_1, N_2 和 EGT 作为输出的动态响应模型, 并使用多组测试集对模型准确性、实时性与稳健性进行了验证, 得出以下结论:

(1) SSA-NARX 辨识模型比传统方法有更高的准确性。输出参数 N_1, N_2 和 EGT 与真实值的最大相对误差绝对值 δ_{\max} 分别降低至 3.81%, 1.24% 和 3.47%, 明显优于 NARX 和 PSO-NARX 方法。

(2) SSA-NARX 对发动机输出参数动态特性预测具有更好的实时性。参数 N_1, N_2 和 EGT 的动态特性指标 T_i 与 T_i 和真实值的相对误差均小于 5%, 显著低于《飞机飞行模拟机鉴定性能标准》要求, 为民航模拟机发动机建模问题提供了更优的解决方案。

(3) SSA-NARX 模型有较强的稳定性与泛化能力。随机划分训练集与测试集进行 10 次交叉验证测试的结果表明, 参数 N_1, N_2 和 EGT 的测试结果均

4 结 论

本文提出了一种基于麻雀搜索算法(SSA)优化

方根误差均值 RMSE_m 分别为 0.29, 0.18 和 1.50。

参考文献:

- [1] 刘永泉,黎旭,任文成,等.数字孪生助力航空发动机跨越发展[J].航空动力,2021(2):24–29.
LIU Yong-quan, LI Xu, REN Wen-cheng, et al. Digital twin boosting leap-forward development of aero engine[J]. Aerospace Power, 2021(2):24–29.
- [2] 曹建国.航空发动机仿真技术研究现状、挑战和展望[J].推进技术,2018,39(5):961–970.
CAO Jian-guo. Status, challenges and perspectives of aero-engine simulation technology[J]. Journal of Propulsion Technology, 2018, 39(5):961–970.
- [3] COSTA N, SANCHEZ L. Variational encoding approach for interpretable assessment of remaining useful life estimation[J]. Reliability Engineering & System Safety, 2022, 222:108353. 1 – 108353. 2.
- [4] CHEN J, HU Z, WANG J, et al. Aero-engine real-time models and their applications [J]. Mathematical Problems in Engineering, 2021(4):1–17.
- [5] 王占学,宋甫,周莉,等.航空发动机数值缩放技术的研究进展[J].推进技术,2018,39(7):1441–1454.
WANG Zhan-xue, SONG Fu, ZHOU Li, et al. Research progress in numerical zooming technology of aero-engine[J]. Journal of Propulsion Technology, 2018, 39(7):1441–1454.
- [6] TAMARGAZIN A, PRYIMAK L. Neural network interpolation parameters of a multi-mode dynamic model of the aircraft engine[J]. Aerospace Technic and Technology, 2020(7):98–104.
- [7] WANG H, XIE S, WU W, et al. Dynamic process identification of aircraft engine based on a novel sparse least square support vector machines[J]. Journal of Aerospace Power, 2010, 25(9):2139 – 2147.
- [8] CHATI Y S, HAMSA B. Data-driven modeling of aircraft engine fuel burn in climb out and approach [J]. Transportation Research Record: Journal of the Transportation Research Board, 2018, 2672(29):1–11.
- [9] 郑斐华,胡春艳,李伟,等.基于约束卡尔曼滤波的航空发动机状态变量模型辨识方法[J].热能动力工程,2019,34(4):60–66.
ZHENG Fei-hua, HU Chun-yan, LI Wei, et al. An identification method of aero-engine state variable model based on constrained Kalman filter[J]. Journal of Engineering for Thermal Energy and Power, 2019, 34(4):60–66.
- [10] THELEN A, ZHANG X, FINK O, et al. A comprehensive review of digital twin, Part 1: Modeling and twinning enabling technologies [J]. Structural and Multidisciplinary Optimization, 2022, 65(12):1–55.
- [11] 耿宏,任道先,杜鹏.基于 NARX 神经网络航空发动机参数动态辨识模型[J].计算机工程与应用,2017,53(12):241–248.
GENG Hong, REN Dao-xian, DU Peng. Dynamic parameter identification model of aircraft engine based on NARX neural network [J]. Computer Engineering and Applications, 2017, 53 (12): 241 – 248.
- [12] GIORGI M G D, FICARELLA A, QUARTA M. Dynamic performance simulation and control of an aeroengine by using NARX models[J]. MATEC Web of Conferences, 2019, 304:03005.
- [13] ASGARI H, ORY E. Machine learning approaches for modelling a single shaft gas turbine[J]. International Journal of Modelling, Identification and Control, 2021, 37(3/4):275 – 284.
- [14] XUE J, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1):22 – 34.
- [15] 薛建凯.一种新型的群智能优化技术的研究与应用[D].上海:东华大学,2020.
XUE Jian-kai. Research and application of a novel swarm intelligence optimization technique: Sparrow search algorithm [D]. Shanghai: Donghua University, 2020.
- [16] 马晨佩,李明辉,巩强令,等.基于麻雀搜索算法优化支持向量机的滚动轴承故障诊断[J].科学技术与工程,2021,21(10):4025 – 4029.
MA Chen-pei, LI Ming-hui, GONG Qiang-ling, et al. Fault diagnosis of rolling bearing based on sparrow search algorithm optimized support vector machine[J]. Science Technology and Engineering, 2021, 21(10):4025 – 4029.
- [17] 汤安迪,韩统,徐登武,等.基于混沌麻雀搜索算法的无人机航迹规划方法[J].计算机应用,2021,41(7):2128 – 2136.
TANG An-di, HAN Tong, XU Deng-wu, et al. Path planning method of unmanned aerial vehicle based on chaos sparrow search algorithm[J]. Journal of Computer Applications, 2021, 41 (7): 2128 – 2136.
- [18] 吕鑫,慕晓冬,张钧.基于改进麻雀搜索算法的多阈值图像分割[J].系统工程与电子技术,2021,43(2):318 – 327.
LYU Xin, MU Xiao-dong, ZHANG Jun. Multi-threshold image segmentation based on improved sparrow search algorithm [J]. System Engineering and Electronics, 2021, 43(2):318 – 327.
- [19] LEONTARITIS I, BILLINGS S. Input-output parametric models for non-linear systems, Part 1: Deterministic non-linear systems, Part 2: Stochastic non-linear systems[J]. International Journal of Control, 1985, 41(2):303 – 328.
- [20] COHEN H, ROGERS G F C, STRAZNICKY P, et al. Gas turbine

- theory [M]. London: Pearson, 2017.
- [21] 张绍基. 航空发动机控制系统的研发与展望 [J]. 航空动力学报, 2004, 19(3): 375–382.
ZHANG Shao-ji. A review of aeroengine control system [J]. Journal of Aerospace Power, 2004, 19(3): 375–382.
- [22] POGORELOV G L, KULIKOV G G, ABDULNAGIMOV A L, et al. Application of neural network technology and high-performance computing for identification and real-time hardware-in-the-loop simulation of gas turbine engines [J]. Procedia Engineering, 2017, 176: 402–408.
- [23] ASGARI H, CHEN X Q, MORINI M, et al. NARX models for simulation of the start-up operation of a single-shaft gas turbine [J]. Applied Thermal Engineering, 2016, 93: 368–376.
- [24] MOHAMED O, KHALIL A. Progress in modeling and control of gas turbine power generation systems: A survey [J]. Energies, 2020, 13(9): 1–26.
- [25] XU X, PENG L, JI Z, et al. Research on substation project cost prediction based on sparrow search algorithm optimized BP neural network [J]. Sustainability, 2021, 13(24): 1–17.
- [26] 郑里鷺. 航空发动机非线性建模及控制研究 [D]. 天津: 中国民航大学, 2020.
- ZHENG Li-jiu. Research on nonlinear modeling and control of aeroengine [D]. Tianjin: Civil Aviation University of China, 2020.
- [27] AC-60-FS-2019-006, 飞机飞行模拟机鉴定性能标准 [S]. AC-60-FS-2019-006, Qualification performance standards for airplane full flight simulators [S].

(孙嘉忆 编辑)

(上接第197页)

- [11] 王明达, 韦永健, 王建军, 等. 基于 SVM-BN 的天然气长输管道燃气轮机故障预警方法研究 [J]. 天然气工业, 2017, 37(11): 112–118.
WANG Ming-da, WEI Yong-jiang, WANG Jian-jun, et al. A SVM-BN based early warning method for gas turbines of natural gas long-distance pipelines [J]. Natural Gas Industry, 2017, 37(11): 112–118.
- [12] 雷萌, 吕游, 魏玮, 等. 基于 LSTM 神经网络与贝叶斯优化的电站风机故障预警 [J]. 热能动力工程, 2022, 37(8): 213–220.
LEI Meng, LYU You, WEI Wei, et al. Fault warning of power plant fans based on long short term memory neural network and Bayesian optimization [J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(8): 213–220.
- [13] 魏永合, 宫俊宇. 基于 CNN-LSTM-Attention 的滚动轴承故障诊断 [J]. 沈阳理工大学学报, 2022, 41(4): 73–77.
WEI Yong-he, GONG Jun-yu. Fault diagnose in rolling bearings based on CNN-LSTM-Attention [J]. Journal of Shenyang Ligong University, 2022, 41(4): 73–77.
- [14] 蔡薇薇, 徐彦伟, 颜潭成. 基于 CNN-LSTM 的轴承剩余使用寿命预测 [J]. 机械传动, 2022, 46(10): 17–23.
CAI Wei-wei, XU Yan-wei, JIE Tan-cheng. Prediction of bearing remaining service life based on CNN-LSTM [J]. Journal of Mechanical Transmission, 2022, 46(10): 17–23.
- [15] 简定辉, 李萍, 黄宇航, 等. 基于 CNN-LSTM 网络的短期电力负荷预测 [J]. 电工电气, 2022, 42(9): 1–6.
JIAN Ding-hui, LI Ping, HUANG Yu-hang, et al. Short-term power load forecasting based on CNN-LSTM [J]. Electrotechnics Electric, 2022, 42(9): 1–6.
- [16] SAJJAD M, KHAN Z A, ULLAH A, et al. A novel CNN-GRU-based hybrid approach for short-term residential load forecasting [J]. IEEE Access, 2020(99): 143760–143768.

(刘颖 编辑)