

基于改进灰狼算法的并行极限学习机 发动机排气温度预测策略

卢燃, 庞博

(国能北电胜利能源有限公司, 内蒙古 锡林浩特 026015)

摘要: 针对不同工况下发动机排气温度预测精度差的问题, 提出一种基于灰狼算法的并行极限学习机发动机排气温度预测策略; 针对传统灰狼算法全局收敛精度低和在迭代后期容易过早收敛陷入局部最优的问题, 通过立方混沌映射对全部灰狼个体的位置进行初始化进行改进, 同时在灰狼算法进行位置更新的过程中, 加入历史信息学习因子的搜索策略, 使得算法在更新过程中不因过多依赖局部最优解的位置信息而早熟收敛, 提高算法的收敛精度和收敛速度; 将改进后的灰狼算法对并行极限学习机中的隐层阈值和输入权值进行在线整定, 提高并行学习机的预测精度和泛化能力; 实验结果表明, 相较于其他预测方法, 改进灰狼算法的并行极限学习机具备较高的预测能力和泛化能力, 可以精确预测发动机的排气温度。

关键词: 发动机; 排气温度; 灰狼优化算法; 并行极限学习机; 历史学习因子; 立方混沌映射

Prediction Strategy of Engine Exhaust Temperature Based on Parallel Limit Learning Machine Based on Improved Grey Wolf Algorithm

LU Ran, PANG Bo

(Guoneng Beidian Shengli Energy Co., Ltd., Xilinhaote 026015, China)

Abstract: Aiming at the poor prediction accuracy of engine exhaust temperature under different operating conditions, a parallel extreme learning machine prediction strategy based on the grey wolf algorithm is proposed. In response to low global convergence accuracy and falling into local optimum in the later stage of iteration, cubic chaotic mapping is used to initialize and improve the positions of all grey wolves, and in the updating process of gray wolf algorithm, a history information learning factor is added to the search strategy, which makes the algorithm converge prematurely during the update process without relying too much on the position information of local optimal solutions, improving the precision and speed of convergence. The improved gray wolf algorithm is used to adjust the hidden layer threshold and input the weight value of parallel extreme learning machine on line, improving its prediction accuracy and generalization ability. Experimental results show that, compared with other prediction methods, the parallel extreme learning machine for improving the grey wolf algorithm has high prediction and generalization ability, and can accurately predict the exhaust temperature of the engine.

Keywords: engine; exhaust temperature; grey wolf optimization algorithm; parallel extreme learning machine; historical learning factor; cubic chaotic mapping

0 引言

伴随着中国科技能力的提高, 发动机生产技术有了显著的进步。与传动汽油发动机的不同, 天然气发动机在运行过程中, 消耗的燃料更少, 排放的有害物更少, 且防爆性能更高^[1]。由于天然气的燃化特性与汽油的燃

化特性不同, 因此传统的汽油发动机的汽油排放温度预测模型不能应用于天然气发动机的排气温度预测模型^[2]。发动机具有非线性多耦合的特点, 受扭矩, 转速等多方面因素影响, 发动机排气温度的时变规律呈非线性特点, 仅依赖经验, 难以有效对排气温度进行预测。

收稿日期: 2023-11-30; 修回日期: 2024-01-10。

作者简介: 卢燃 (1985-), 男, 大学本科, 高级工程师。

引用格式: 卢燃, 庞博. 基于改进灰狼算法的并行极限学习机发动机排气温度预测策略[J]. 计算机测量与控制, 2025, 33(2): 80-87, 102.

因此, 构建发动机排气温度的预测模型成为国内外研究者关注的焦点^[3-6]。

文献 [7] 提出一种基于经验模态分解与卷积神经网络相结合的排气温度预测模型, 提取各分量之间的非线性关系, 提高了预测的精度和稳定性。文献 [8] 提出一种基于集成学习的发动机排气温度预测模型, 该模型中集成多种预测子模型, 并设定相对权重, 通过调整权重系数, 适应各分量之间的预测关系, 提高预测时间和预测精度。文献 [9] 提出一种基于径向基过程神经网络的预测模型, 在训练样本足够多的前提下, 具有较高的训练精度, 泛化能力较强, 但其对参数设定具有极高的要求, 在实际预测过程中, 预测精度一般。为减少发动机排气温度的随机性的问题, 文献 [10] 提出一种基于改进量子粒子群的支持向量机预测模型, 以转速, 燃油流量以及高压压气机等参数作为样本的输入, 以排气温度为输出, 在训练样本数不定的情况下, 依然具有较高的预测能力。文献 [11] 提出一种基于改进果蝇算法的广义回归神经网络预测模型, 针对发动机非线性多耦合的特点, 该预测模型具有较强的非线性映射能力和解耦能力, 可精准预测排气温度, 具有较强的泛化能力。文献 [12] 提出了一种发动机排气温度预测模型, 该模型基于长短期记忆网络, 通过前向计算和错误反馈来计算排气规律, 从而精准预测排气温度。

由于以上传统的神经网络模型在处理具有复杂非线性和多耦合特性的问题时, 训练时间过长, 泛化能力不足, 难以求解非线性等问题^[13-16]。因此今年来, 极限学习机代替传统的神经网络模型成为研究人员用于解决工程控制问题和进行模型预测的重要手段之一。

并行极限学习机^[17] (PELM, parallel extreme learning machine) 相较传统的极限学习机或 LSSVM 预测模型而言, 泛化能力和预测精度更强, 但 PELM 的预测精度依赖输入权值和初始阈值。因此, 本文首先通过非线性时变控制因子等策略对传统灰狼优化算法进行改进^[18] (GWO, grey wolf optimizer), 提高算法的搜索精度和寻优能力。其次将改进后的灰狼优化算法对 PELM 的输入权值和初始阈值进行优化。最后将优化后的 PELM 对发动机排气温度进行预测。

1 并行极限学习机数学模型

并行极限学习机在传统极限学习机的基础上加入了一个并行的线性网络学习部分。设系统的实验样本为 (x_i, y_i) , 其中 $i = 1, 2, \dots, N, N$ 为实验样本个数。 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]$ 表示第 i 个样本的第 n 维输入向量。 $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]$ 表示第 i 个样本的第 m 维输出向量。其中 n 为输入节点个数。设每个隐含层存在 m

个神经元, 存在线性 1 的矩阵 p 为线性网络学习部分的输入权值, 随机数矩阵 q 非线性网络学习部分的输入权值。 W_{oh} 为输出权值矩阵。因此并行极限学习机的结构如图 1 所示。

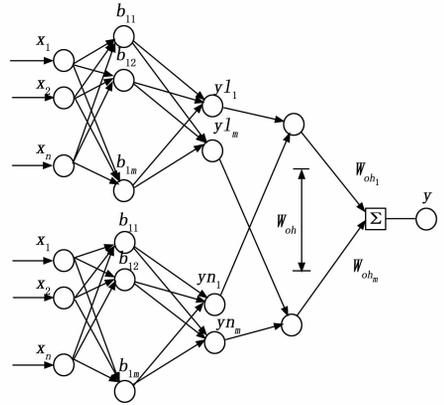


图 1 并行极端学习机结构图

图 1 中, yl 和 yn 分别为线性隐含层输出值和非线性隐含层输出值, 设极限学习及的隐含层激励函数 $g(x)$ 为 sigmoid 函数, 因此并行极限学习及的数学模型如下所示:

$$\begin{cases} y_j = \sum_{k=1}^m W_{oh_k} \cdot yl_k \cdot yn_k \\ yl_k = \sum_{i=1}^n g(p_{k,i} x_{k,i} + b_{l,k}) \\ yn_k = \sum_{i=1}^n g(q_{k,i} x_{k,i} + b_{n,k}) \end{cases} \quad (1)$$

式中, $p_{k,i}$ 为线性隐含层输入值到第 k 个隐含层神经元之间的权值, $b_{l,k}$ 为第 k 个线性隐含层中阈值。 $q_{k,i}$ 为非线性隐含层输入值到第 k 个隐含层神经元之间的权值。 $b_{n,k}$ 为第 k 个非线性隐含层中的阈值。 W_{oh_k} 为第 k 个隐含层神经元到输出层 y_j 之间的连接权值。

设 X 为系统输入矩阵, Y 为系统期望输出矩阵, P 为线性输入权值矩阵, Q 为非线性输入权值矩阵, B_L 为线性隐含层阈值矩阵, B_N 非线性隐含层阈值矩阵, 如式 (1) 所示:

$$Y = W_{oh} G \quad (2)$$

$$G(P, Q, B_L, B_N, X) =$$

$$\begin{bmatrix} yl_1(x_1) yn_1(x_1) \cdots yl_n(x_n) yn_n(x_n) \\ \vdots \\ yl_m(x_1) yn_m(x_1) \quad yl_m(x_n) yn_m(x_n) \end{bmatrix}_{m \times n} \quad (3)$$

设 W'_{oh} 为 W_{oh} 的 M-P 广义逆, 可得:

$$W'_{oh} = Y(G^T G)^{-1} G^T \quad (4)$$

由此可得并行极限学习机的预测步骤如下所示:

- 1) 随机初始化非线性隐含层阈值; 非线性输入惯

性权重。取线性 1 矩阵为线性输入惯性权重，线性隐含层阈值设为 0 矩阵。

- 2) 根据式 (3) 计算矩阵 G 的值；
- 3) 根据式 (4) 计算输出权值矩阵 W'_{oh} ；
- 4) 根据式 (2) 计算期望输出矩阵 Y 。

2 改进灰狼优化算法 (IGWO)

2.1 基本灰狼优化算法

基本灰狼优化算法的求解流程如下所示：

1) 种群初始化：设灰狼优化算法中，种群规模为 NP ，维数为 ND ，因此对种群中全部灰狼个体进行位置初始化 $X_i = (X_i^1, X_i^2, \dots, X_i^{ND})$ ，其中 $i = (1, 2, \dots, NP)$ ， X_i^1 表示第 i 个个体在第 1 维的位置。

2) 群体适应度值计算，并挑选出头狼：计算全部灰狼个体的适应度函数值，并进行排序，适应度值最小的个体为最优解，记为 α 。适应度值第二小的个体为次优解，记为 β 。适应度值第三小的个体为第三优解，记为 γ 。其余个体记为 δ 。其中 α 为头狼。

3) 位置更新：种群中的灰狼个体会在捕猎过程中不断向食物源缩小包围圈，通过缩小包围圈捕猎所产生的位置更新方式可由式 (5) 进行描述：

$$X_i^d(t+1) = X_p^d(t) - A_i^d | C_i^d X_p^d(t) - X_i^d(t) | \quad (5)$$

式中， $t = (1, 2, \dots, t_{\max})$ 为当前迭代次数， t_{\max} 为最大迭代次数。 X_p^d 为猎物位置， X_i^d 为灰狼个体的位置。 A_i^d 和 C_i^d 为包围步长因子，控制灰狼群体包围圈缩小的步长。其数学表达式如下所示：

$$A_i^d = 2a \cdot \text{rand}_1(\cdot) - a \quad (6)$$

$$C_i^d = 2 \cdot \text{rand}_2(\cdot) \quad (7)$$

式中， $a = 2 - 2t/t_{\max}$ 为控制参数，随迭代次数增加从 2 到 0 线性减小。因此使得灰狼个体在捕猎时线性缩小包围圈，缩小范围的速率基本一致。 $\text{rand}_1(\cdot)$ 和 $\text{rand}_2(\cdot)$ 为 $[0, 1]$ 之间的随机数，目的是使灰狼个体可沿搜索路径进行小范围随机搜索，丰富种群多样性。

4) 计算包围步长因子 A_i^d 和 C_i^d 以及控制因子 a 的取值。

5) 根据式 (8) 和式 (9) 对灰狼个体 α 、 β 、 γ 和 δ 进行位置更新，其数学表达式如下所示：

$$\begin{cases} X_{i,\alpha}^d(t+1) = X_\alpha^d(t) - A_{i,1}^d | C_{i,1}^d X_\alpha^d(t) - X_i^d(t) | \\ X_{i,\beta}^d(t+1) = X_\beta^d(t) - A_{i,2}^d | C_{i,2}^d X_\beta^d(t) - X_i^d(t) | \\ X_{i,\gamma}^d(t+1) = X_\gamma^d(t) - A_{i,3}^d | C_{i,3}^d X_\gamma^d(t) - X_i^d(t) | \end{cases} \quad (8)$$

$$X_{i,\delta}^d(t+1) = \frac{X_{i,\alpha}^d(t+1) + X_{i,\beta}^d(t+1) + X_{i,\gamma}^d(t+1)}{3} \quad (9)$$

6) 判断算法迭代是否达到最大迭代次数，若 $t =$

t_{\max} 则输出最优解。若 $t < t_{\max}$ 则返回 2)。

2.2 立方混沌初始化

基本灰狼优化算法的全局寻优能力主要依赖于初始种群的位置和全局最优解信息的位置更新策略。由于灰狼算法一般采用随机位置策略进行种群位置初始化，因此无法预测或平均分布种群的位置，如果全部灰狼个体的初始位置均集中在一个区域，并该区域远离全局最优解辐射范围，则会造成算法收敛速度降低，搜索精度下降的问题。针对上述问题，本文引入立方混沌映射策略，对算法的初始种群进行更新，使得算法的初始解可以均匀分布在解空间内。立方混沌映射的数学表达式如下所示：

$$x(n+1) = 4x(n)^3 - 3x(n) \quad (10)$$

式中， $-1 \leq x(n) \leq 1$ 。灰狼算法的立方混沌初始化流程如下所示：

1) 在解空间内，随机生成一个值为 $[-1, 1]$ 内的 d 维个体。

2) 以第一个 d 维个体的位置信息为准，通过式 (10) 生成其他灰狼个体的映射信息，形成混沌映射序列。

3) 通过式 (11) 将全部灰狼个体的映射信息，映射到初始解空间内，形成新的初始种群。

$$X_d = (u_d - l_d) \times \frac{(1+x)}{2} + l_d \quad (11)$$

式中， u_d 为解空间的上限， l_d 为解空间的下限。 X_d 为新形成的初始解位置。

2.3 基于历史学习因子的位置更新

根据灰狼算法的更新方式可知，基本狼群算法在每次迭代过程中，全部灰狼个体均会向当前最优个体即 3 个头狼的位置信息靠近，因此在迭代过程中只考虑当前最优个体的位置信息，并未对上一时刻的最优个体位置信息进行参考。通过实验表明，在迭代过程中，历史最优信息也可对当前的寻优路径起到协同搜索和动态调整的作用。因此本文引入历史学习因子，对算法进行改进，使得灰狼算法在迭代过程中，不仅考虑当前最优解的信息，同时也会参考历史最优解的信息，丰富种群的寻优多样性，扩大寻优范围，提高算法的全局搜索能力。

设历史学习因子 η_{mist} 为：

$$\eta_{\text{mist}} = \begin{cases} \omega_i & t < 0.5 * T_{\max} \\ \text{argmin}f(\omega, x) & t \geq 0.5 * T_{\max} \end{cases} \quad (12)$$

当 $t < 0.5 * T_{\max}$ 时， ω 为学习因子集合， $i = \text{rand}(1; \text{length}(\omega))$ ， $\text{length}(\omega)$ 为集合长度，因此 ω_i 表示第 i 个学习因子，算法在迭代过程中，每个灰狼个体会随机分配一个历史学习因子，扩大灰狼个体的邻域寻优范围和寻优路径的随机性。为防止灰狼个体的朝较差

的位置信息进行路径寻优, 当 $t \geq 0.5 * T_{max}$ 时, 寻找上一迭代过程中的最优历史学习因子, 即上次迭代过程中最优个体所对应的历史学习因子, 对当前个体的路径学习方向进行有效指引, 以此来促进算法的收敛速度和全局搜索能力的提升。

改进后的位置更新方式为:

$$X_{i,\delta}^d(t+1) = \eta_{hist} X_{i,\delta}^d(t) + (1 - \eta_{hist}) X_{i,\delta}^d(t+1) \quad (13)$$

2.4 改进灰狼优化算法的寻优过程

改进后的灰狼优化算法 (IGWO, improve grey wolf optimization algorithm) 的寻优过程如下所示:

- 1) 初始化灰狼种群, 包括种群规模 NP , 维数 ND , 最大迭代次数 t_{max} , 参数 u_d, l_d ;
- 2) 通过式 (10) 和式 (11) 对初始种群进行立方混沌映射, 形成平均分布在解空间的新的初始种群;
- 3) 计算种群中全部个体的适应度函数值, 并进行排序, 挑选适应度值最优的 3 个个体, 记为 α, β, γ ;
- 4) 通过公式 (8) 和式 (9) 对灰狼个体 α, β, γ 进行位置更新;
- 5) 通过式 (12) 计算历史学习因子, 基于历史信息, 通过式 (13) 对灰狼个体进行位置初始化;
- 6) 判断是否达到最大迭代次数, 是则输出最优解, 否则返回 3)。

3 实验结果与分析

3.1 测试函数集选取

为了证实 IGWO 算法的算法性能, 选择了 10 个国际通用的基准测试函数, 进行数值试验。并将所得实验结果与量子自适应鸟群算法^[19]、混沌鲸鱼优化算法^[20]和改进粒子群算法^[21]的实验结果进行对比。3 种对比算法均应用于求解发动机排气温度的预测模型中。10 个基准测试函数如表 1 所示。

表 1 测试函数集

函数序号	函数名称	寻优区间	极值点
F1	Sphere	$[-100, 100]$	0
F2	Schwefel1.2	$[-100, 100]$	0
F3	Schwefel2.21	$[-100, 100]$	0
F4	Rosenbrock	$[-30, 30]$	0
F5	Step	$[-100, 100]$	0
F6	Rastrigin	$[-5.12, 5.12]$	0
F7	Ackley	$[-32, 32]$	0
F8	Griewank	$[-600, 600]$	0
F9	Penalized1	$[-50, 50]$	0
F10	Penalized2	$[-50, 50]$	0

3.2 数值仿真实验

本文对 4 种算法针对测试函数集进行数值仿真实验,

用于验证本文所提 IGWO 算法的优化能力和寻优精度。4 种算法的种群规模均为 30, 迭代次数为 1 000。为了保证对比结果的公平性, 4 种算法独立运行 50 次取实验结果的平均值、最小值、标准差, 并记录求解成功率 SR 和平均耗时 T 。具体实验结果如表 2 所示, 其中最优解用加粗字体表示。下面将本文所提 IGWO 记为 AIO1, 量子自适应鸟群算法记为 AIO2, 混沌鲸鱼优化算法记为 AIO3, 改进粒子群算法记为 AIO4。

表 2 测试结果对比

	算法	Min	Ave	Std	SR/%	T/s
F1	AIO1	1.25×10^{-36}	5.67×10^{-33}	4.32×10^{-33}	100	0.26
	AIO2	6.37×10^{-19}	3.56×10^{-15}	1.06×10^{-15}	100	0.35
	AIO3	4.23×10^{-22}	2.60×10^{-19}	2.04×10^{-19}	100	0.29
	AIO4	6.54×10^{-26}	7.09×10^{-23}	6.54×10^{-23}	100	0.54
F2	AIO1	5.68×10^{-34}	4.23×10^{-30}	3.06×10^{-30}	100	1.39
	AIO2	4.20×10^{-30}	6.59×10^{-27}	4.21×10^{-27}	100	2.43
	AIO3	8.83×10^{-26}	5.44×10^{-23}	3.60×10^{-23}	100	1.64
	AIO4	4.27×10^{-21}	7.29×10^{-17}	4.17×10^{-17}	100	2.49
F3	AIO1	7.89×10^{-22}	5.37×10^{-19}	3.29×10^{-19}	100	0.85
	AIO2	6.33×10^{-06}	4.19×10^{-02}	2.47×10^{-02}	87	1.06
	AIO3	5.27×10^{-06}	7.39×10^{-02}	5.30×10^{-02}	89	1.02
	AIO4	7.32×10^{-15}	4.55×10^{-12}	2.59×10^{-09}	96	0.96
F4	AIO1	6.89×10^{-29}	4.19×10^{-27}	2.04×10^{-27}	100	0.67
	AIO2	7.56×10^{-27}	5.61×10^{-24}	4.19×10^{-24}	100	0.73
	AIO3	5.49×10^{-05}	6.33×10^{-02}	3.48×10^{-02}	86	1.24
	AIO4	9.02×10^{-06}	5.99×10^{-03}	4.27×10^{-03}	92	1.05
F5	AIO1	0	0	0	100	0.42
	AIO2	3.69×10^{-16}	6.39×10^{-13}	2.18×10^{-19}	100	1.04
	AIO3	5.88×10^{-07}	6.19×10^{-04}	5.08×10^{-04}	64	2.33
	AIO4	7.49×10^{-03}	2.04×10^{-01}	1.24×10^{-01}	49	3.04
F6	AIO1	0	0	0	100	0.57
	AIO2	1.57×10^{-07}	5.67×10^{-03}	4.18×10^{-03}	56	1.75
	AIO3	5.49×10^{-01}	$5.03 \times 10^{+01}$	$2.07 \times 10^{+01}$	13	2.49
	AIO4	7.82×10^{-01}	$3.04 \times 10^{+01}$	$1.58 \times 10^{+01}$	17	2.57
F7	AIO1	4.78×10^{-18}	7.43×10^{-15}	3.62×10^{-15}	100	1.02
	AIO2	1.59×10^{-05}	9.82×10^{-02}	8.24×10^{-02}	76	2.39
	AIO3	6.74×10^{-09}	7.44×10^{-06}	6.74×10^{-06}	83	1.96
	AIO4	5.68×10^{-14}	6.59×10^{-11}	4.47×10^{-11}	100	1.43
F8	AIO1	0	0	0	100	0.93
	AIO2	4.17×10^{-03}	9.81×10^{-01}	4.18×10^{-01}	29	2.17
	AIO3	$2.69 \times 10^{+01}$	$4.74 \times 10^{+02}$	$1.27 \times 10^{+02}$	0	0.74
	AIO4	$5.47 \times 10^{+01}$	$9.67 \times 10^{+02}$	$5.49 \times 10^{+02}$	0	0.88
F9	AIO1	1.29×10^{-26}	5.49×10^{-23}	4.71×10^{-23}	100	0.83
	AIO2	4.76×10^{-17}	6.27×10^{-13}	4.38×10^{-13}	100	1.05
	AIO3	4.79×10^{-17}	4.75×10^{-13}	3.57×10^{-13}	100	1.37
	AIO4	7.29×10^{-12}	9.57×10^{-09}	4.72×10^{-09}	100	1.15
F10	AIO1	2.47×10^{-26}	4.73×10^{-23}	2.80×10^{-23}	100	0.89
	AIO2	4.68×10^{-17}	8.60×10^{-13}	7.85×10^{-13}	100	1.14
	AIO3	2.60×10^{-17}	2.37×10^{-13}	1.60×10^{-13}	100	1.55
	AIO4	7.99×10^{-12}	6.37×10^{-09}	5.32×10^{-09}	100	1.37

从表 2 中单峰测试函数的实验对比结果而言, 本文所提 IGWO 算法所求解的平均值和最小值均优于其他 3 种算法的求解结果, 说明引入历史学习因子后, 灰狼算法在迭代过程中充分考虑的当前局部最优解的位置信息和上一次迭代的局部最优解的历史信息, 使寻优路径始终保持正确的方向, 增强了算法的局部搜索能力。对于测试函数 F5 而言, IGWO 算法可以求解到理论极值点, 说明 IGWO 算法在进行立方混沌映射后, 初始化种群在解空间的分布更加均匀, 有效地将全局最优解包含在搜索范围内。此外, IGWO 算法求解的标准差同样最小, 说明 IGWO 算法的全局搜索稳定性更强, 同时从寻优成功率 SR 的对比结果可知, IGWO 算法均可求解到全局最优解, 无早熟收敛情况出现。最后从寻优时间的对比结果可知, IGWO 算法的寻优时间远低于其他 3 种算法的寻优时间, 说明 IGWO 算法求解到最优解所花费的时间最短。

从多峰测试函数的测试结果可知, IGWO 算法求解的平均值和最小值同样优于其他 3 种算法的求解结果, 说明 IGWO 算法的局部开发能力更强, 黄金正弦局部搜索策略可使算法在当前极值点附近进行精确搜索的同时, 降低了极值点对种群个体的吸引力, 避免算法陷入局部最优。同样对于测试函数 F6 和 F7 而言, IGWO 算法可求解到理论最优值, 说明算法在迭代后期通过历史学习因子的信息和当前全局最优解的位置信息, 有效减小寻优步长, 提高了算法的局部收敛精度。同时对于测试函数 F8 而言, 混沌鲸鱼优化算法和改进粒子群算法均早熟收敛, 陷入局部最优, 但 IGWO 算法的寻优成功率 SR 始终为 100%。

4 发动机排气温度预测实验

4.1 基于 IGWO 算法的 PELM 预测模型

针对 PELM 预测模型的输入权值和隐含层阈值难以确定, 导致 PELM 泛化能力和预测精度较差的问题, 通过 IGWO 算法在线优化输入权值和隐含层阈值。图 2 给出了 IGWO 算法优化 PELM 模型的过程。

具体步骤如下所示:

1) 对 IGWO 算法进行种群初始化, 按输入权值和隐含层阈值对种群中全部灰狼个体进行编码:

$$X_i = (q_{11}, \dots, q_{1m}, \dots, q_{m1}, \dots, q_{mm}, b_1, \dots, b_m)。$$

2) 变量采集。根据发动机天然气燃烧方式, 选择相关操作参数作为预测模型的输入, 并从燃烧系统中采集相关数据, 并将所得数据分为训练集和测试集。

3) 适应度函数。

$$fitness = \frac{1}{M} \sum_{i=1}^M |y_i - f(x_i)| \quad (14)$$

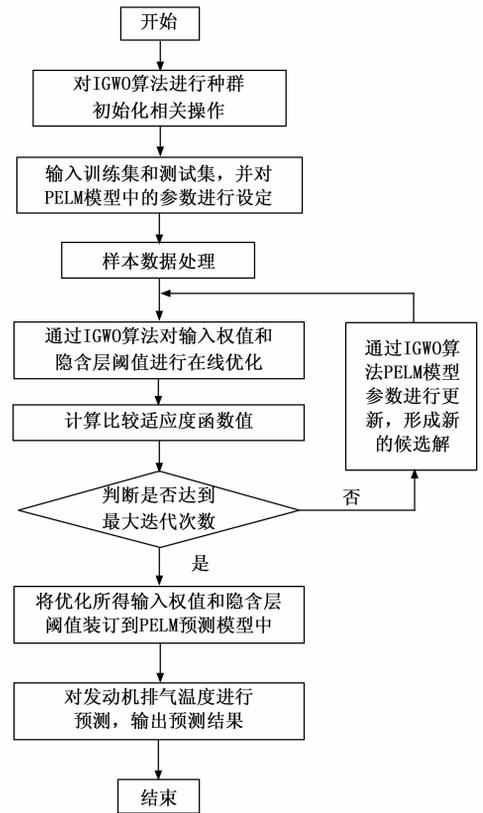


图 2 改进灰狼算法并行极端学习机结构图

式中, $f(x_i)$ 为 IGWO 优化后 PELM 预测模型的预测发动机排气温度, y_i 为训练样本实际所得发动机排气温度, $i = 1, 2, \dots, n$ 。

4) 依据式 (14) 计算 IGWO 算法中种群个体的适应度函数值, 并进行排序, 保存当前迭代产生的最优解。

5) 检查是否已经达到预设的最大迭代次数。如果达到了, 就输出当前的最优解。如果未达到, 就继续执行迭代求解的过程。

4.2 基于时间序列预测模型的发动机排气预测结果

该实验数据来自某发动机的实际采样数据, 数据每 10 s 采集一次, 共选取 300 个不同负荷 (发动机负荷在 10、20、30、40 和 50%) 下的数据点作为实验数据, 并将 300 个实验数据进行归一化处理。在 300 个实验数据中, 我们初步选定 100 个作为训练样本, 而剩余的 200 个数据点将被用作测试样本。发动机排气温度时间序列的预测模型为:

$$y(\beta_{step} + t) = f[y(t-1), y(t-2), \dots, y(t-ND_{embed})] \quad (15)$$

式中, $ND_{embed} = 4$ 表示嵌入维数, $\beta_{step} = 3$ 表示预测步长, 通过本文所提 IGWO-PELM 算法分别对发动机排

气温度时间序列进行 3 步优化, 并将实验结果与基本灰狼算法 (GWO-PELM) 的预测结果、基于量子自适应鸟群算法的 PELM (QBSA-PELM) 预测结果、基于混沌鲸鱼算法的 PELM 预测结果 (CAWOA-PELM) 以及基于改进粒子群算法的 PELM (ILPSO-PELM) 预测结果进行对比, 选取平均绝对误差 (MAE)、均方根误差 (RMSE) 以及预测时间 (Times) 作为评价标准, MAE 的数学式如式 (16) 所示:

$$E_{MAE} = N^{-1} \sum_{i=1}^N |y(i) - \bar{y}(i)| \quad (16)$$

式中, $y(i)$ 和 $\bar{y}(i)$ 分别表示发动机的实际排气温度和预测模型计算所得发动机排气温度, N 为样本个数。实验结果如表 3~5 以及图 3 所示。

表 3 1 步预测结果

模型	RMSE	MAE	预测时间/s
GWO-PELM	5.423	5.019	0.59
IGWO-PELM	1.058	0.934	0.21
CAWOA-PELM	6.544	6.021	0.54
QBSA-PELM	2.048	1.963	0.67
ILPSO-PELM	2.679	2.155	0.69

表 4 2 步预测结果

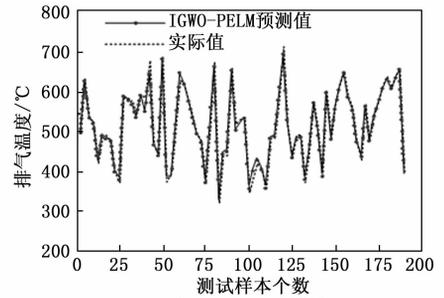
模型	RMSE	MAE	预测时间/s
GWO-PELM	5.744	5.433	0.76
IGWO-PELM	1.244	1.076	0.20
CAWOA-PELM	8.447	7.961	0.89
QBSA-PELM	4.660	4.156	1.43
ILPSO-PELM	4.871	4.332	1.28

表 5 3 步预测结果

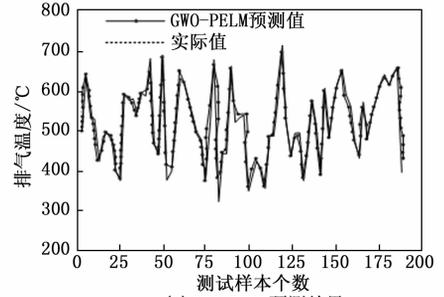
模型	RMSE	MAE	预测时间/s
GWO-PELM	6.402	6.176	0.69
IGWO-PELM	2.416	2.144	0.22
CAWOA-PELM	11.544	14.734	0.74
QBSA-PELM	8.493	8.047	1.22
ILPSO-PELM	9.611	9.422	1.39

从表 3~5 可以看出, 5 种预测模型的精度都随着预测步数的增长而有所降低。然而, 本研究提出的 IGWO-PELM 方法产生的平均绝对误差和均方根误差仍然是最低的。IGWO-PELM 的平均绝对误差仅为 GWO-PELM 的 10.3%, CAWOA-PELM 的 12.5%, QBSA-PELM 的 25.9%, ILPSO-PELM 的 24.8%。IGWO-PELM 的均方根误差仅为 GWO-PELM 的 14.9%, CAWOA-PELM 的 16.2%, QBSA-PELM 的 51.6%, ILPSO-PELM 的 39.5%。随预测步数的增加, IGWO-PELM 求解的平均绝对误差与均方根误差值相较其他 4 种算法而言误差

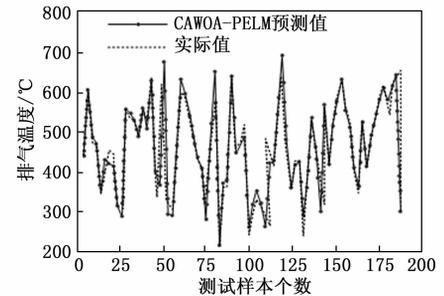
更小。因此, 说明本文所提 IGWO-PELM 预测模型的预测精度更高, 泛化能力更强。为了更加直观地观察, 以 3 步预测为例, 绘制了 5 种预测模型真实值和预测值的对比曲线, 实验结果如图 3 所示。由图 3 可知, IGWO-



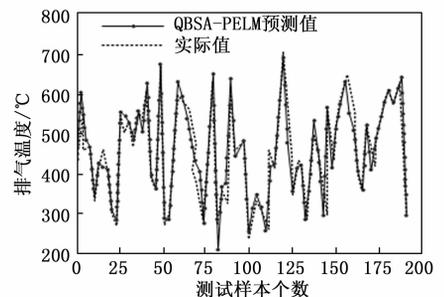
(a) IGWO-PELM 预测结果



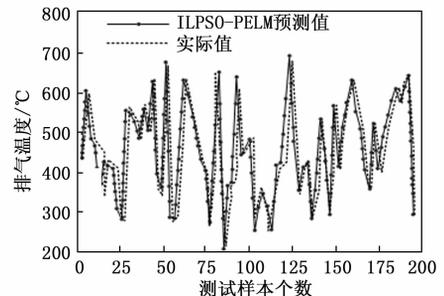
(b) GWO-PELM 预测结果



(c) CAWOA-PELM 预测结果



(d) QBSA-PELM 预测结果



(e) ILPSO-PELM 预测结果

图 3 排气温度时间序列 3 步预测结果

PELM 算法求解的预测值曲线和真实值曲线拟合程度最高, 说明 IGWO-PELM 算法的预测精度更高。同时, 在进行三步预测过程中, IGWO-PELM 预测模型的预测时间最少, 随预测步数的增加, 几乎没有变化, 进一步说明了 IGWO-PELM 预测模型的泛化能力优于其他 4 类预测模型。

4.3 基于实际发动机排气温度的预测结果

从某发动机控制系统中, 采集排气温度数据, 采集周期为 30 s, 共取 300 组数据作为基于 IGWO 算法的 PELM 预测模型的测试样本和训练样本。从每组数据中提取低气压压气机转速, 高压压气机转速, 发动机排气温度, 燃油流量, 压气机出口温度, 作为模型的输入, 因此基于 IGWO 算法的 PELM 预测模型的输入节点个数为 25, 输出节点个数为 1。选取 275 组数据作为训练样本, 25 组数据作为测试样本。300 组数据如表 6 所示。

表 6 300 组测试数据

参数	数据序列号						
	300	1	2	3	4	5	...
T_{gc}/K	633.4	635.8	636.4	638.1	642.4	...	650.1
T_3/K	452.6	451.3	445.8	442.1	441.6	...	480.4
$N_2/\%$	97.2	97.2	97.1	97.1	96.8	...	94.2
$f_1/10^3(kg/h)$	1 457	1 472	1 486	1 559	1 571	...	2 044
$N_1/\%$	89.1	89.0	89.0	88.7	88.7	...	82.4

为了可以直观地对 IGWO-PELM 预测模型的预测精度进行分析验证, 本文将 IGWO-PELM 对排气温度的预测实验结果与基本灰狼算法的预测结果 (GWO-PELM)、基于量子自适应鸟群算法的 PELM (QBSA-PELM) 预测结果、基于混沌鲸鱼算法的 PELM 预测结果 (CAWOA-PELM) 以及基于改进粒子群算法的 PELM (ILPSO-PELM) 预测结果进行对比, 实验结果如图 4 和图 5 所示。

图 4 呈现了 5 种算法预测发动机排气温度与实际发动机排气温度误差的结果。从图中可知, 本文所提 IGWO-PELM 模型的预测趋势与实际值相同, 预测结果与实际值基本一致, 相较其他 4 种算法优化后的预测模型而言, IGWO-PELM 模型对训练样本的拟合度最高, 预测精度最高。

从图 5 中可知, 本文所提 IGWO-PELM 预测模型对测试样本的预测误差最大仅为 2%, 远低于其他 4 种算法优化后的 PELM 模型的预测误差, 同时 IGWO-PELM 模型在对测试样本进行预测的过程中, 相对于其他 4 种预测模型, IGWO-PELM 的预测精度更高, 鲁棒性更强且泛化能力更强。

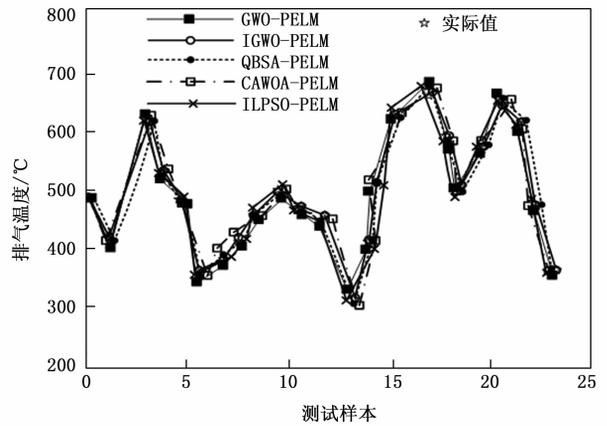


图 4 发动机排气温度预测对比结果

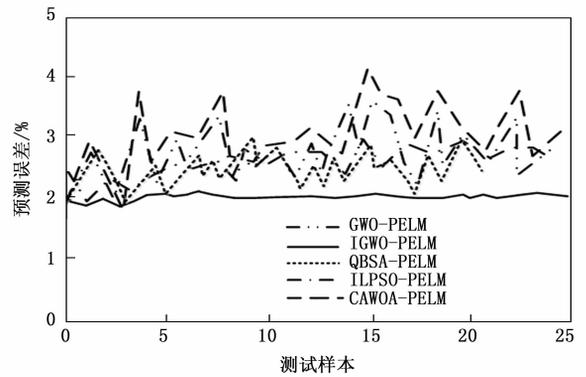


图 5 发动机排气温度预测误差对比结果

为了能更深入地评估 4 种预测模型的预测性能和精度。选取平均绝对误差 (MAE)、均方根误差 (RMSE) 以及平均相对百分比误差 (MAPE) 3 个评价指标对 5 种预测模型的预测结果进行对比验证, 具体结果如表 7 和表 8 所示。

表 7 测试样本精确度对比

模型	RMSE	MAE	MAPE	预测时间/s
GWO-PELM	5.941	5.648	8.04×10^{-09}	3.24
IGWO-PELM	4.29×10^{-02}	3.75×10^{-02}	6.07×10^{-18}	1.17
CAWOA-PELM	18.967	14.734	6.24×10^{-05}	3.64
QBSA-PELM	0.574	0.526	7.74×10^{-11}	2.07
ILPSO-PELM	5.304	4.088	7.73×10^{-09}	5.24

表 8 训练样本精确度对比

模型	RMSE	MAE	MAPE	预测时间/s
GWO-PELM	5.209	5.044	9.27×10^{-11}	4.04
IGWO-PELM	7.49×10^{-02}	6.94×10^{-02}	2.07×10^{-18}	1.49
CAWOA-PELM	17.496	16.553	4.02×10^{-05}	3.42
QBSA-PELM	0.344	0.283	4.73×10^{-11}	2.59
ILPSO-PELM	4.196	3.971	8.84×10^{-11}	4.76

从表 7 和表 8 可知, 对于测试样本而言, 本文所提 IGWO-PELM 预测模型的 $RMSE$ 值和 MAE 值远低于其他 4 种算法, 相对于其他 4 种预测模型, 所求之解的精确度低了 11 个数量级, 这进一步证明了 IGWO-PELM 预测模型的预测精度明显优于其他 4 种预测模型。同样对于训练样本而言, IGWO-PELM 预测模型的 $RMSE$ 值和 MAE 值同样远低于其他 4 种算法, 这也表明 IGWO-PELM 预测模型在预测精度和泛化性上远超其它 4 种预测模型, 且预测所需时间最短。

表 9 和表 10 为本文所提 IGWO-PELM 预测模型与长短期记忆神经网络 (EMD-LSTM)^[22]、改进广义回归神经网络 (GRNN)^[23]、径向基过程神经网络^[24] 以及支持过程向量机^[25] 的发动机排气温度预测对比结果。

表 9 测试样本精确度对比

模型	$RMSE$	MAE	$MAPE$	预测时间/s
IGWO-PELM	4.29×10^{-02}	3.75×10^{-02}	6.07×10^{-18}	1.17
EMD-LSTM	5.71×10^{-01}	5.22×10^{-01}	7.52×10^{-12}	2.04
GRNN	6.33×10^{-01}	5.91×10^{-01}	7.99×10^{-12}	2.61
径向基过程神经网络	6.94×10^{-01}	6.42×10^{-01}	8.15×10^{-12}	1.49
支持过程向量机	9.88×10^{-02}	9.37×10^{-02}	4.29×10^{-17}	1.47

表 10 训练样本精确度对比

模型	$RMSE$	MAE	$MAPE$	预测时间/s
IGWO-PELM	7.49×10^{-02}	6.94×10^{-02}	2.07×10^{-18}	1.49
EMD-LSTM	5.41×10^{-01}	5.09×10^{-01}	7.43×10^{-12}	2.27
GRNN	5.93×10^{-01}	5.52×10^{-01}	8.07×10^{-12}	2.44
径向基过程神经网络	7.39×10^{-01}	6.83×10^{-01}	9.07×10^{-12}	1.22
支持过程向量机	1.63×10^{-01}	1.27×10^{-01}	7.22×10^{-17}	2.19

从表 9 和表 10 可知, 本文所提 IGWO-PELM 预测模型的 $RMSE$ 值和 MAE 值优于支持过程向量机的求解精度。相较 EMD-LSTM、GRNN 和径向基过程神经网络的预测精度低了 6 个数量级。这也表明 IGWO-PELM 预测模型在预测精度和泛化性上远超其它 4 种预测模型, 且预测所需时间最短。

5 结束语

为精准预测发动机的排气温度, 本文提出一种改进灰狼算法并行极限学习机预测模型。针对 PELM 预测模型中输入权值和隐含层阈值难以确定导致影响 PELM 预测模型预测精度的问题, 通过立方混沌初始化策略以及基于历史学习因子的位置更新对 GWO 算法进行改进, 提高算法的收敛精度以及寻优鲁棒性, 并将改进后的算法 (IGWO) 对输入权值和隐含层阈值进行优化。

最后通过 IGWO-PELM 预测模型对发动机排气温度从不同方面进行对比预测实验。通过发动机排气温度时间序列的预测结果可知, IGWO-PELM 求解的 3 步 MAE 值均为最小, 仅为其他 4 种对比算法求解 MAE 最优值的 42%、48%、26%、27%。通过基于实际发动机排气温度预测结果可知, IGWO-PELM 模型对训练样本的拟合度最高, 预测精度最高。IGWO-PELM 求解的测试样本 MAE 、 $RMSE$ 和 $MAPE$ 值最小, 仅为其他 4 种对比算法求解 MAE 最优值的 7%、 $RMSE$ 最优值的 7.5%、 $MAPE$ 最优值的 8.5×10^{-6} 。IGWO-PELM 求解的训练样本 MAE 、 $RMSE$ 和 $MAPE$ 值同样最小, 仅为其他 4 种对比算法求解 MAE 最优值的 24%、 $RMSE$ 最优值的 22%、 $MAPE$ 最优值的 4.3×10^{-6} 。从以上结论可知, 本文所提 IGWO 算法优化后的 PELM 预测具备较强的泛化能力和预测精度, 具有很高的使用价值。

参考文献:

- [1] 刘 飞, 韩 冰, 尤建国. 发动机排气系统结构优化设计与仿真研究 [J]. 机械设计与制造, 2023 (5): 287-291
- [2] 李锦轩. 船用发动机排气温度测量与影响研究 [J]. 内燃机与配件, 2023 (3): 7-9.
- [3] WANG J J, ZHANG W Y, LI Y N, et al. Forecasting wind speed using empirical mode decomposition and Elman neural network [J]. Applied Soft Computing Journal, 2014, 23: 452-459.
- [4] FU X Y, SHAN Z Y, LI Z, et al. Timevarying fuzzy neural network and its application in aeroengine exhaust temperature prediction [J]. Computer Integrated Manufacturing System, 2014, 20 (4): 919-925.
- [5] ZHANG X C, YUE J J. Application of an improved adaptive chaos prediction model in aero-engine performance parameters [J]. WSEAS Transactions on Mathematics, 2012, 11 (2): 114-124.
- [6] WU J, HUA K, CHENG Y W, et al. Data-driven remaining useful life prediction via multiple sensor signals and deep long short-term memory neural network [J]. ISA transactions, 2020, 97: 241-250.
- [7] 李 杰, 孟凡熙, 张子辰, 等. 基于融合神经网络的发动机排气温度裕度预测 [J]. 华东交通大学学报, 2022, 39 (6): 90-97.
- [8] 易文川, 王 兴, 王 翔, 等. 基于集成学习的航空发动机排气温度预测 [J]. 航空计算技术, 2022, 52 (5): 87-91.
- [9] 陈庆贵, 李洪伟, 李 明, 等. 基于径向基过程神经网络的航空发动机排气温度预测 [J]. 兵器装备工程学报, 2019, 40 (6): 154-157.

(下转第 102 页)