

基于改进果蝇算法优化的 GRNN 航空发动机排气温度预测模型

皮骏¹, 马圣², 张奇奇², 王力平³, 崔东泽⁴

(1. 中国民航大学 通用航空学院, 天津, 300300;

(2. 中国民航大学 航空工程学院, 天津, 300300;

3. 珠海摩天宇航空发动机维修有限公司, 广东 珠海, 519030;

4. 中国民航大学 中欧航空工程师学院, 天津, 300300)

摘 要: 利用广义回归神经网络(GRNN)良好的非线性映射能力,对航空发动机排气温度(EGT)进行预测。由于 GRNN 的预测性能受宽度系数的影响,因此采用改进的果蝇算法优化广义回归神经网络(IFOA-GRNN),并用优化后的 GRNN 对航空发动机的 EGT 进行预测。以某发动机为案例,选取相关参数作为预测模型的输入变量,EGT 作为预测模型的输出变量。在相同的样本分配下,将 FOA-GRNN(fruit fly optimization algorithm to optimize GRNN)、GRNN、自回归预测模型和优化的支持向量回归机作为对比算法。分析结果表明:IFOA-GRNN 的收敛精度高于 FOA-GRNN;IFOA-GRNN 对 EGT 预测的平均相对误差为 2.47%、拟合优度为 0.8506,其预测效果均优于其他对比算法;同时,IFOA-GRNN 对噪声的敏感性也低于其他对比算法。

关键词: 航空发动机; 排气温度; 改进的果蝇算法; 广义回归神经网络; 温度预测

中图分类号: V231.1; TH17

文献标志码: A

Aero-engine exhaust gas temperature prediction model based on IFOA-GRNN

PI Jun¹, MA Sheng², ZHANG Qiqi², WANG Liping³, CUI Dongze⁴

(1. College of General Aviation,

Civil Aviation University of China, Tianjin 300300, China;

2. College of Aeronautical Engineering,

Civil Aviation University of China, Tianjin 300300, China;

3. MTU Maintenance Zhuhai Company Limited,

Zhuhai Guangdong 519030, China;

4. Sino-European Institute of Aviation Engineering,

Civil Aviation University of China, Tianjin 300300, China)

Abstract: General regression neural network (GRNN) has a good nonlinear mapping ability. So exhaust gas temperature (EGT) is predicted by GRNN. But, its accuracy of prediction is affected by the width coefficient of GRNN. To address the problem, the GRNN

收稿日期:2017-12-12

基金项目:国家自然科学基金委员会与中国民用航空局联合资助(U1633101);

中央高校基本科研业务费项目中国民航大学专项资助(3122017056);中国民航大学创业创新项目(201810059121)

作者简介:皮骏(1973—),男,副教授,博士,主要从事发动机故障诊断与机械振动研究。

引用格式:皮骏,马圣,张奇奇,等. 基于改进果蝇算法优化的 GRNN 航空发动机排气温度预测模型[J]. 航空动力学报,2019,34(1):8-17. PI Jun, MA Sheng, ZHANG Qiqi, et al. Aero-engine exhaust gas temperature prediction model based on IFOA-GRNN[J]. Journal of Aerospace Power, 2019, 34(1): 8-17.

optimized by the improved fruit fly optimization algorithm (IFOA-GRNN) was proposed. And it was used to predict EGT. Taking the engine as an example, some parameters were taken as input variables and EGT taken as output variable of prediction models. The forecast results of IFOA-GRNN, FOA-GRNN (fruit fly optimization algorithm to optimize GRNN), GRNN, auto-regressive and optimized support vector regression were compared under the same training samples and testing samples. The experiment results showed that the convergence accuracy of IFOA-GRNN was higher than FOA-GRNN. Average relative error of IFOA-GRNN for EGT prediction was 2.47%, and the goodness of fit was 0.8506, the prediction effect of IFOA-GRNN was better than other comparison algorithms. And it was more accurate than other methods in the prediction of aero-engine exhaust gas temperature under noisy and no-noise conditions.

Key words: aero-engine; exhaust gas temperature; improved fruit fly optimization algorithm; general regression neural network; prediction of temperature

航空发动机的排气温度(exhaust gas temperature, EGT)超过限制,将会对发动机的性能参数造成影响^[1]。因此能够及时有效地对 EGT 进行准确的预测,有助于监控发动机性能状况。

EGT 是航空发动机监控中常用的气动热力性能参数,通过监控和预测 EGT 能够掌握航空发动机的健康状态和性能衰退情况。由于航空发动机是一个复杂的非线性系统,EGT 随着发动机的工作状态变化而呈现复杂的多变性^[2]。对此,国内外诸多学者对 EGT 的预测进行大量研究, Kumar 等^[3]运用自回归和移动平均技术对航空发动机排气温度进行预测; Ilbas 和 Turkmen^[4]运用人工神经网络对 CFM56-7B 发动机排气温度进行预测; Yilmaz^[5]利用排气温度与发动机其他性能参数之间的关系对排气温度进行预测评估; 于广滨等^[6]运用支持过程向量机模型对航空发动机排气温度进行预测; 钟诗胜等^[7]运用卷积和离散过程神经网络模型对航空发动机排气温度进行预测; 丁刚等^[8]将航空发动机排气温度转化为泛函逼近问题,并用过程神经网络对 EGT 进行逼近。

基于神经网络的非线性映射能力,使得这些学者取得了不错的效果。但大多数神经网络的非线性映射能力均与自身的调节参数相关,诸如 SVM(support vector machines)的核参数和罚参数、部分神经网络的神经元数量、输入矩阵等的设置,会对预测模型有较大的影响,且调节参数越多,就会花费更多时间在预测模型参数调试阶段,不利于预测的实时性。而广义回归神经网络,具有结构简单、非线性映射能力强、设置参数单一以及高度的容错性和鲁棒性,适宜解决非线性问题,

因而得到广泛运用。如:陈娇等^[9]将广义回归神经网络(general regression neural network, GRNN)运用到燃气轮机排气温度传感器故障检测中。曾有学者^[10]将经过优化的 GRNN 和未被优化的 GRNN 进行对比分析,结果表明:GRNN 中宽度系数的取值会影响网络的预测效果。因而在某些领域的应用也相对较少,如:航空发动机上的运用。为了去解决这个问题,本文提出用改进的果蝇算法优化 GRNN 的宽度系数,并用优化后的网络对航空发动机排气温度进行预测。

果蝇优化算法(fruit fly optimization algorithm, FOA)^[11-12]是进化算法中的一种,相较于遗传算法、粒子群算法等,其程序简单易于理解,收敛速度快,因此而得到广泛运用^[13-16]。但经典的 FOA 在每次的迭代过程中单纯以全局最优为导向,极易陷入局部极值,导致收敛精度较低。近年来不少学者^[14-16]都对 FOA 做出改进并结合 GRNN 应用到不同领域。本文借鉴文献^[14]的思想,对经典的 FOA 做出相应调整,结合 GRNN 对航空发动机排气温度进行预测,并得到较好的结果。

1 GRNN 简介

1.1 GRNN 网络结构

1991 年 The Lockheed Palo Alto 研究实验室的 Donald Specht 提出广义回归神经网络^[17], GRNN 是 RBF(radial basis function)神经网络的一种改进型,建立在回归数理统计的基础上,能够根据样本数据逼近其中隐含的映射关系,具有极强的非线性映射能力和学习速度。GRNN 由输

入层、径向基神经元层、线性层和输出层组成。其结构如图 1 所示。

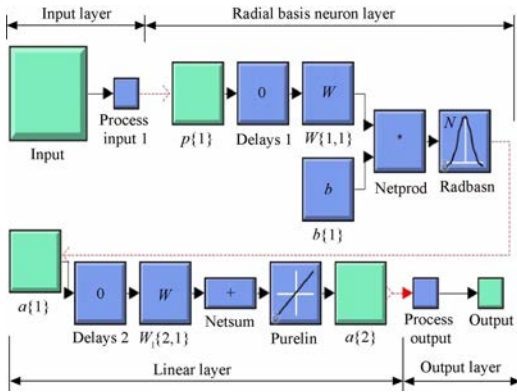


图 1 广义回归神经网络结构图

Fig. 1 Diagram of general regression neural network

1) 输入层的神经元个数与训练样本的输入向量维数相等,并经过输入层直接传到径向基神经元层;径向基神经元的神经元数目等于训练样本的数目,采用径向基函数 $\text{radbas}()$ 作为隐节点的激活函数。

2) GRNN 的求和层由两种神经元组成,即分子层神经元 S_n 和分母层神经元 S_d 。分子神经元 S_n :对径向基神经元的输出均进行加权求和,其传递函数为

$$S_n = \sum_{i=1}^m y_i P_i \quad (1)$$

分母神经元 S_d :对径向基神经元的输出均进行算术求和,其传递函数为

$$S_d = \sum_{i=1}^m P_i \quad (2)$$

3) 求和层分子、分母神经元输出到输出层神经元,输出层神经元将分子、分母神经元相除从而得到 y_i 估计值

$$\hat{y}_i = \frac{S_n}{S_d} = \frac{\sum_{i=1}^m y_i P_i}{\sum_{i=1}^m P_i} \quad (3)$$

1.2 GRNN 理论基础

GRNN 能够从观测样本中求得自变量和因变量之间的联合密度函数,从而求出因变量对自变量的回归值^[18]。假设随机变量 x 和 y 的联合概率密度函数为 $f(x, y)$,变量 x 的观测值为 x_i ,那么 y 相对 x_i 的回归值,即条件均值为

$$\hat{y}(x_i) = \frac{\int_{-\infty}^{\infty} y f(x_i, y) dy}{\int_{-\infty}^{\infty} f(x_i, y) dy} \quad (4)$$

由于在模式层神经元数目等于学习样本容量 n ,神经元 i 的输出等于输入变量与对应样本 x_i 之间的 Euclid 距离平方 $D_i^2 = (x_i - x_i)^T \cdot (x_i - x_i)$ 的指数形式,其中 x_i 为第 i 个神经元对应的学习样本。则未知的概率密度函数 $f(x_i, y)$ 的 Parzen 非参数估计为

$$f(x_i, y) = \frac{\sum_{i=1}^n e^{-\frac{(x_i - x_i)^T (x_i - x_i)}{2\sigma^2}} e^{-\frac{(x_i - y_i)^2}{2\sigma^2}}}{n(2\pi)^{\frac{(q+1)}{2}} \sigma^{q+1}} \quad (5)$$

其中 y_i 为神经 i 对随机变量 y 的观测值; n 表示样本容量; q 表示随机变量 x 的维数; σ 表示高斯函数的宽度系数,即光滑系数。将式(5)代入式(4)中,交换积分顺序,且化简(奇函数对称积分为 0)得

$$\hat{y}(x_i) = \frac{\sum_{i=1}^n y_i e^{-\frac{(x_i - x_i)^T (x_i - x_i)}{2\sigma^2}}}{\sum_{i=1}^n y_i e^{-\frac{(x_i - x_i)^T (x_i - x_i)}{2\sigma^2}}} \quad (6)$$

当宽度系数 σ 取值较大时, $\hat{y}(x_i)$ 近似等于所有样本因变量的均值;当宽度系数 σ 取值较小时, $\hat{y}(x_i)$ 与训练样本非常接近,不利于预测在训练样本集之外的点;当宽度系数 σ 取值适宜时,所有训练样本因变量均被考虑, $\hat{y}(x_i)$ 的效果最好。为解决宽度系数的取值问题,用 EGT 预测的方均根误差最小为导向,利用改进果蝇算法进行寻优,使得预测结果更为理想。

2 改进果蝇算法优化的 GRNN

2.1 经典的果蝇算法

果蝇优化算法是一种基于果蝇觅食行为为推演出全局寻优的新方法^[11-12]。果蝇本身在感官知觉上优于其他物种,因此能够很快的寻找到悬浮在气体中的味道,然后靠近目标,搜寻目标过程如图 2 所示。

利用果蝇算法优化 GRNN 宽度系数 σ ,并对 EGT 进行预测,其通常执行如下几步^[11-12,14,19]:

Step 1 随机初始化果蝇的位置坐标 (x_0, y_0) ;

Step 2 随机赋予第 i 个果蝇位置坐标的变换方向

$$\begin{aligned} x_i &= x_0 + \text{Rand}() \\ y_i &= y_0 + \text{Rand}() \end{aligned} \quad (7)$$

Step 3 计算第 i 果蝇的坐标与原点之间的

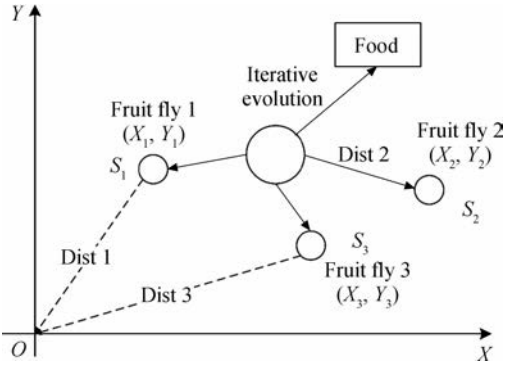


图2 果蝇群体迭代搜索食物示意图

Fig.2 Diagram of drosophila population iterative search for food

距离(D_i),再转换为待优化选择的宽度系数(σ_i)

$$\begin{cases} D_i = \sqrt{(x_i)^2 + (y_i)^2} \\ \sigma_i = \frac{1}{D_i} \end{cases} \quad (8)$$

Step 4 将 EGT 预测的方均根误差 (root mean square error, RMSE) 作为味道浓度的判定函数 $f(x)$, 并计算第 i 个果蝇所对应的宽度系数 σ_i 的味道浓度 $g_{\text{rmse}}(i)$

$$f(x) = \sqrt{\frac{\sum_{i=1}^M (\hat{y}_i - y_i)^2}{M}} \quad (9)$$

$$g_{\text{rmse}}(i) = f(\sigma_i) \quad (10)$$

式中 M 为预测数量; \hat{y}_i 为 GRNN 预测的 EGT 值; y_i 为 EGT 的实际值; $i = 1, 2, \dots, M$; $g_{\text{rmse}}(i)$ 函数下标 rmse 表示为方均根误差, 此处下标仅表示 $g_{\text{rmse}}(i)$ 函数计算依据, 无其他特殊含义。

Step 5 找到所有宽度系数中 g_{rmse} 最小个体的位置:

$$[g_{\text{bestrmse}} \ g_{\text{bestindex}}] = \min(g_{\text{rmse}}(i)) \quad (11)$$

其中 g_{bestrmse} 表示在此次搜寻过程中最佳宽度系数对应的味道浓度; $g_{\text{bestindex}}$ 则表示最佳宽度系数对应的味道浓度的位置。

Step 6 保留最佳果蝇 x 的坐标位置 (x_{best} , y_{best}), 并前往目标

$$\begin{cases} f_{\text{best}} = f(x) \\ x_{\text{best}} = x_{\text{bestindex}} \\ y_{\text{best}} = y_{\text{bestindex}} \end{cases} \quad (12)$$

其中 $x_{\text{bestindex}}$ 表示在此次搜寻过程中最佳果蝇位置的横坐标; $y_{\text{bestindex}}$ 表示在此次搜寻过程中最佳果蝇位置的纵坐标。

Step 7 循环执行步骤 2~6 直至达到最大迭代次数或者满足收敛条件。

2.2 改进的果蝇算法

经典的果蝇算法优化 GRNN 宽度系数时, 宽度系数值为果蝇个体的坐标到原点距离的倒数。但如若距离值过大, 就会导致宽度系数值很小, 这样就可能导致果蝇算法陷入局部极值。为了防止果蝇算法陷入局部极值, 因此借鉴文献[14]的思想, 采用一种基于个体极值的方法来调整宽度系数, 以便于果蝇算法跳出局部极值, 提高收敛精度。改进方法如下:

$$\begin{cases} D_i = \sqrt{(x_i)^2 + (y_i)^2} \\ D_{\max} = \max[D(i)] \\ D_{\min} = \min[D(i)] \\ \sigma(i) = \frac{1}{D_{\max} \cdot \exp\left[\lg\left(\frac{D_{\min}}{D_{\max}}\right) \times \frac{n}{m}\right]} \end{cases} \quad (13)$$

其中 n 为当前迭代次数; m 为最大迭代次数。需要说明的是: 当样本数量较大时, 建议将样本数据集分为两部分进行训练, 避免算法训练过度, 影响算法的推广。

2.3 IFOA-GRNN 预测模型的预测流程

IFOA-GRNN 预测模型的预测流程图如图 3 所示, 其详细预测步骤如下:

Step 1 收集数据并筛选主要变量, 对数据进行归一化处理, 同时将数据样本分为训练样本和预测样本;

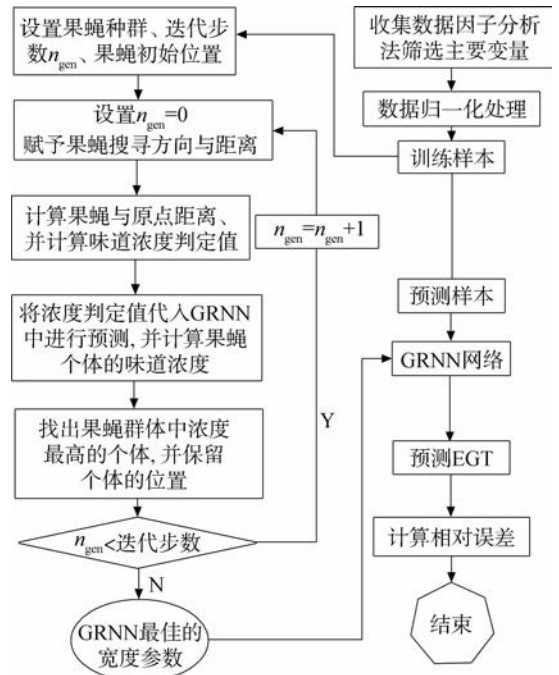


图3 IFOA-GRNN 的预测流程图

Fig.3 Flow chart of IFOA-GRNN

Step 2 设置果蝇种群、迭代步数、初始位置,同时随机赋予果蝇搜寻目标的方向;

Step 3 计算果蝇与原点的距离,并对应的宽度系数值;

Step 4 将宽度系数值代入 EGT 预测的方均根误差判定函数中,计算个体的 g_{rmse} ;

Step 5 找出果蝇群体中 g_{rmse} 最小的个体并保留个体的位置;

Step 6 判断是否满足终止条件,若否,则重复执行 Step 3 到 Step 5,直到满足终止条件为止;若是,则输出 GRNN 的最佳宽度系数;

Step 7 将得到的宽度系数代入 GRNN 网络,预测 EGT,并计算相对误差。

2.4 预测模型的重要参数分析

上述算法中果蝇种群大小、果蝇初始位置、果蝇种群迭代步数均会影响到 FOA 搜寻能力,对这些参数的影响及取值分析如下:

1) 果蝇种群大小、种群迭代步数关系着 FOA 的搜寻能力,果蝇个体愈多就愈快发现目标,但随着个体的增加会导致计算时间的增加,因此种群大小的设置显得尤为重要。基于航空发动机 EGT 数据,寻找最佳种群。由于初始种群大小的选取优化方法较少,因此本文采取遍历搜索法,图 4 和图 5 中分别呈现出部分种群大小时的搜索轨迹、误差收敛情况。从图 4 可以发现,种群越大,果蝇搜寻路径越平稳且行进速度越快;从图 5 可以发现,果蝇种群越大,EGT(记为 T_{ge}) 预测的方均根收敛速度越快。因此经过分析,IFOA-GRNN 种群大小设置为 30;迭代步数设置为 50。

2) 果蝇初始位置也影响到 FOA 算法的搜索能力,由于果蝇初始位置均为随机产生,故使用 rand 表示,文中采用扩大 rand 方式研究初始位

置对果蝇算法的影响。同样采取遍历搜索法研究果蝇初始位置对算法收敛的情况。呈现部分结果如图 6 所示:果蝇种群初始化位置影响到算法的收敛情况。因此经过分析,IFOA-GRNN 算法中果蝇初始位置设置为: $5 \times \text{rand}$ 。




图 5 基于初始种群大小的 T_{ge} 预测方均根误差收敛
Fig. 5 Convergence condition of RMSE of predictional T_{ge} with population size




图 6 基于初始种群位置的 T_{ge} 预测方均根误差收敛
Fig. 6 Convergence condition of RMSE of predictional T_{ge} with population initial position

3 航空发动机排气温度的预测

航空发动机排气温度是多因素共同耦合的产物,其影响因素大致包括压气机效率、燃油流量、涡轮效率、部件故障等。当气流通过压气机、燃烧室、涡轮时,由于个别部件或整体部件效率下降,使得流量降低,为保持额定推力,就会增大耗油量,从而导致 EGT 变化;除此之外,发动机部件故障,如燃油系统故障等亦会导致 EGT 发生变化。因此,发动机的排气温度是由各个部件性能参数耦合的效果。在 EGT 预测过程中,通常借助于安装在发动机不同部位的温度传感器、压力传感器、转速传感器等采集到的数据进行预测。




图 4 果蝇飞行路径
Fig. 4 Fruit fly flying route

文中所用数据来自某航空公司 A320 飞机的发动机,数据采集间隔时间为 1 min,共采集到 70 组数据。原始数据部分展示如表 1 所示。

表 1 原始数据
Table 1 Actual data

$t/$ min	$T_{ge}/$ K	$T_3/$ K	$N_2/$ %	$p_3/$ MPa	$T_{25}/$ K	$f_t/10^3$ (kg/h)	$N_1/$ %
1	627.1	447.4	94.8	1324	861	1299	84.2
2	635.5	448.5	95	1331	854	1321	84.6
3	645.8	466.5	95.4	1457	936	1419	83.9
⋮							
68	456.2	471.6	88.6	1896	885	1814	82.1
69	475.1	481.9	89.1	2033	1037	1867	78.3
70	423	441.6	86.6	1669	719	1539	80.5

由于影响航空发动机排气温度的因素较多,部分因子之间存在耦合作用,且在实际运用过程中经常需要对变量进行选择,在尽可能保存大量信息前提下降低计算量。因此,可利用统计学上的因子分析法选择变量。

首先用 SPSS(statistical product and service solutions)软件进行因子分析,根据碎石图因子特征值递减情形(如图 7 所示)来选择前面几个影响最大的因子,并结合累积方差贡献率进行选择。经过分析选取累积方差贡献率达到 99.383% 的前几个因子用于 EGT 的预测,即:低压压气机转速 N_1 、高压压气机转速 N_2 、燃油流量 f_t 、低压压气机出口温度 T_{25} 以及时间 t 。经过变量选择后,其部分数据如表 2 所示。

3.1 数据归一化

航空发动机排气温度以及相关的性能参数在




图 7 碎石图
Fig. 7 Scree plot

表 2 选择后的数据

Table 2 Selected data

$t/$ min	$T_{ge}/$ K	$N_1/$ %	$N_2/$ %	$T_{25}/$ K	$f_t/10^3$ (kg/h)
1	627.1	84.2	94.8	861	1299
2	635.5	84.6	95	854	1321
⋮					
69	475.1	78.3	89.1	1037	1867
70	423	80.5	86.6	719	1539

飞机飞行过程中波动幅度较大,且如表 2 中所示,且数量量纲、量级不一致,为了消除这些影响,需要对数据按式(14)进行归一化处理。

$$x = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (14)$$

式中 x_{\min} 、 x_{\max} 分别为输入样本 x_i 的最小值、最大值, x 为归一化处理得到的数值。经过归一化处理后的数据如表 3 所示。

表 3 归一化后的数据

Table 3 Data of normalization

$t/$ min	$T_{ge}/$ K	$N_1/$ %	$N_2/$ %	$T_{25}/$ K	$f_t/10^3$ (kg/h)
1	0.6764	0.9186	0.8699	0.6455	0.3734
2	0.6986	0.9257	0.8773	0.6391	0.3819
⋮					
69	0.2749	0.8142	0.6579	0.8076	0.5923
70	0.1373	0.8531	0.5651	0.5147	0.4659

3.2 IFOA-GRNN 预测模型评价标准

利用对 EGT 预测的平均相对误差作为评价预测模型好坏的标准,即

$$E_{\text{mape}} = \frac{1}{M} \sum_{i=1}^M \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (15)$$

式中 M 为预测数量, \hat{y}_i 为 IFOA-GRNN 预测的 EGT 值, y_i 为 EGT 的实际值。

4 EGT 预测结果分析

计算时所使用的电脑及软件版本如下:AMD A8-5500B APU with Radeon HD Graphics 四核处理,金士顿 DDR3L 4G 1600MHz 内存,Windows7 旗舰版,MATLAB2014b。

4.1 IFOA-GRNN 与 FOA-GRNN 预测性能分析

为了验证本文提出的 IFOA-GRNN 和传统的 FOA-GRNN 的区别,现以发动机前 50 组训练样本为依据,从果蝇搜索路径、RMSE 收敛情况

和运行时间进行比较分析。对两种算法进行仿真,输出结果如图8、图9、表4所示。从图8中可以看出,两种算法搜索路径平稳,但仔细观察发现 IFOA-GRNN 算法的行进速度更快;从图9中可以发现,相比之下 IFOA-GRNN 算法的收敛速度较快,但收敛的 RMSE 精度较低,这可能是由于陷入局部极优所导致;从表4中可知,两种预测方法训练时间相差不到 10 s,算法的改进并未对计算成本造成太大影响。从而说明 IFOA-GRNN 比传统的 FOA-GRNN 性能更佳。

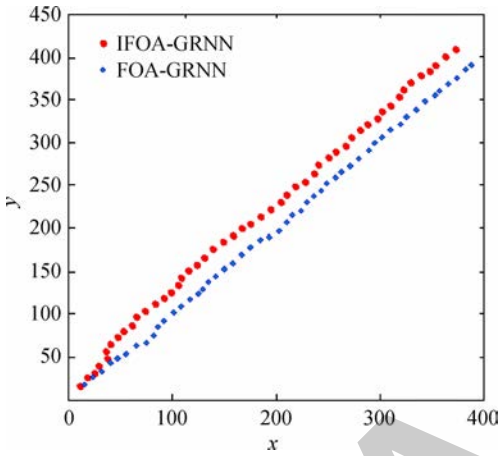


图8 改进果蝇算法与经典果蝇算法的果蝇飞行路线对比
Fig. 8 Comparison of drosophila flight routes between improved drosophila algorithm and classical drosophila algorithm

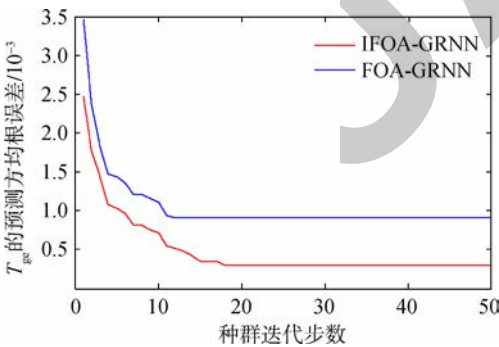


图9 T_{ge} 的预测方均根误差收敛情况比较
Fig. 9 Convergence condition of RMSE of predictional T_{ge} with iteration of IFOA-GRNN and FOA-GRNN

表4 运行时间
Table 4 Elapsed time

预测方法类型	预测时间/s
IFOA-GRNN	101.729
FOA-GRNN	92.24394

4.2 EGT 预测方法对比分析

为了验证 IFOA-GRNN 在航空发动机排气温度预测的有效性,同时将 FOA-GRNN、GRNN、自回归预测模型(AR)以及支持向量回归机(SVR)作为对比预测方法,先对 EGT 样本的前 50 组数据样本进行训练,再分别对后 20 组样本进行预测。

关于对比算法的参数设置说明:果蝇算法优化的 GRNN 中,宽度系数为算法的寻优值,其他参数设置相同;未优化的 GRNN 中,宽度系数经过多次试验,取值: $\sigma=0.1$;自回归预测模型,采用 SAS 自动回归线性建模;支持向量回归机采用 Sigmoid()核函数,其核参数和罚参数的选择由粒子群算法优化选择。(文中结果为运行 10 次后的平均值)

5 种算法的预测结果如图 10 所示。图 10 为 5 种方法在训练样本 50 组、测试样本为 20 组时,EGT 的预测值与真实值对比。从图 10 中可以看出 5 种方法的预测值能够较好的跟随 EGT 的变化;图 11 为各预测模型对 EGT 预测的相对误差,图 10 与图 11 中横坐标为预测样本序列(无量

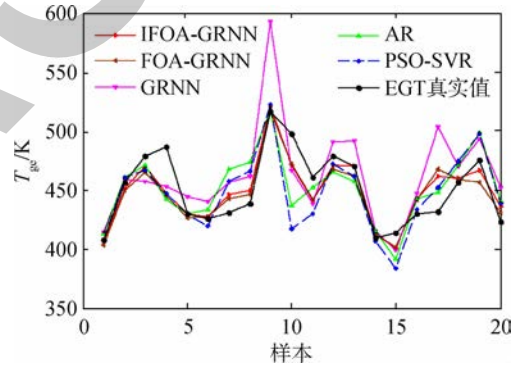


图10 T_{ge} 预测值

Fig. 10 Prediction value of T_{ge}

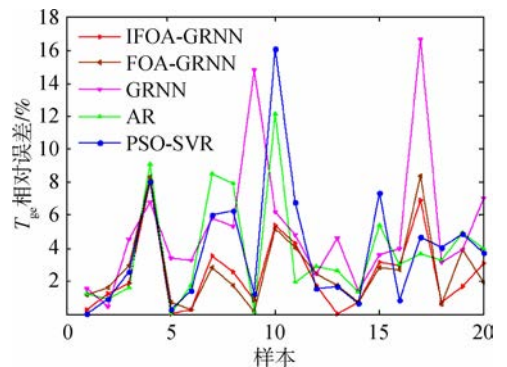


图11 预测误差

Fig. 11 Errors of prediction value

纲)。从图 10 中仅能大概看出几种预测方法均适宜于 EGT 的预测,但几种预测方法的差异表现并不明显。观察 EGT 预测的相对误差图(图 11)可以发现,GRNN、AR、PSO-SVR 预测误差波动仍较为明显,而 IFOA-GRNN 和 FOA-GRNN 相对较好。经过计算,5 种预测模型对这 20 组样本的预测平均相对误差分别为:2.47%、2.71%、5.19%、3.82%、3.95%。IFOA-GRNN 的平均预测误差最小,GRNN 平均预测最差最大,而 EGT 预测常用方法中的回归建模和支持向量回归机平均预测误差区别较小。因而,相比之下果蝇算法优化的广义回归预测模型更适宜于 EGT 的预测。

4.3 拟合优度分析

拟合优度是用于衡量预测值和真实值之间的有效指标,因而利用拟合优度对几种预测模型的性能进行分析。拟合优度计算公式如下:

$$R^2 = \frac{l \sum_{i=1}^l \hat{y}_i y_i - \sum_{i=1}^l \hat{y}_i \sum_{i=1}^l y_i}{\left[l \sum_{i=1}^l \hat{y}_i^2 - \left(\sum_{i=1}^l \hat{y}_i \right)^2 \right] \left[l \sum_{i=1}^l y_i^2 - \left(\sum_{i=1}^l y_i \right)^2 \right]} \quad (16)$$

其中 l 为测试集样本个数; $y_i (i=1, 2, \dots, l)$ 为第 i 个样本的真实值; $\hat{y}_i (i=1, 2, \dots, l)$ 为第 i 个样本的预测值。经计算,几种预测方法的拟合优度如表 5 所示。

表 5 预测模型的拟合优度

Table 5 Predictive models goodness of fit

拟合优度	IFOA-GRNN	FOA-GRNN	GRNN	AR	PSO-SVR
R^2	0.8506	0.8286	0.6126	0.7782	0.7504

从表 5 中可以发现,优化后的 GRNN 拟合优度相比较,而 AR 和 PSO-SVR 拟合优度却较低。在 4.2 节的计算中显示,5 种预测方法预测的相对误差均很小,而现在的拟合优度却较低,两者结论看似矛盾。造成这一现象的原因在于,相对误差计算时着眼于单个点,而拟合优度则是着眼于整个样本的大体趋势,一个从局部出发一个从全局考虑。

因而,拟合优度和平均相对误差的分析结果表明:果蝇算法优化的 GRNN 相比更适宜于 EGT 的预测。

4.4 抗噪性能分析

在对航空发动机 EGT 进行预测时,数据样本中掺杂噪声信号是不可避免的,噪声信号的大小将影响到对航空发动机排气温度预测的准确性。因此为了验证算法的抗噪能力,本文对样本数据添加噪声信号,用以模拟发动机真实的 EGT 数据样本。文中所用噪声数据通过以下方法获得

$$X^n = X + K\delta\text{Rand}() \quad (17)$$

其中 X 表示样本数据, K 表示噪声水平, δ 表示样本的标准差。 X_n 表示添加噪声后生成的数据样本。分别对样本数据添加不同水平的噪声(即: $K=1, 3, 5, 7$),用上小节提到的 5 种预测方法对 EGT 进行预测,其预测结果的平均相对误差如表 6 所示。

表 6 噪声情况下的 EGT 的平均相对误差预测结果对比
Table 6 Comparison of forecast results with noise signal

预测方法	EGT 的平均相对误差/%				
	噪声水平				
	0	1	3	5	7
IFOA-GRNN	2.47	2.76	3.14	3.52	4.30
FOA-GRNN	2.71	3.12	3.58	3.67	4.21
GRNN	5.19	5.87	7.35	10.89	15.74
AR	3.82	4.27	4.81	4.23	4.68
PSO-SVR	3.95	4.29	4.50	4.32	4.23

从表 6 可以看出,随着噪声强度的增加,几种诊断方法的相对误差均发生变化。比较明显的是 GRNN 网络的预测误差效果显著变差,导致这一原因是由于 GRNN 网络的宽度系数设置不合理;而优化的 GRNN 通过算法寻优之后,其参数设置合理,因此预测效果较为稳定。同样,支持向量回归机的参数通过 PSO 算法得到,自回归预测模型的参数随训练数据样本发生变化,因此它们的预测效果也相对较好。但相比之下 IFOA-GRNN 的预测效果,抗噪能力更强。

5 结 论

由于 EGT 呈现复杂的非线性,因而对其预测难度较大;而 GRNN 具有良好的非线性映射能力、高鲁棒性和容错性,且能够较好的适应小样本数据集,但 GRNN 的效果受宽度系数影响。基于这些原因,本文利用改进果蝇算法优化 GRNN,并应用于 A320 飞机的发动机 EGT 预测。

将 FOA-GRNN、GRNN、自回归预测模型和优化的支持向量机作为对比算法,预测结果表明:GRNN 预测效果最差,而优化的 GRNN、自回归预测模型和优化的 SVR,大体效果均较好;但 IF-OA-GRNN 预测的平均相对误差为 2.47%,其误差值最小,而自回归和 SVR 预测的平均相对误差分别为:3.82%、3.95%;GRNN 的预测效果最差,但其平均相对误差为 5.19%,小于 10%。从整体趋势逼近程度而言,优化后的 GRNN 的拟合优度相较最好,而 AR 和 PSO-SVR 效果则较差。优化的 GRNN 与 EGT 预测的常用方法(自回归和 SVR)一样,对噪声的敏感度较低,其平均相对误差计算如表 6 所示。

综上所述,GRNN 适宜于航空发动机 EGT 的预测。

参考文献:

- [1] 薛薇,郭迎清,李睿.航空发动机状态监视、故障诊断及验证[J].推进技术,2011,32(2):271-275.
XUE Wei, GUO Yingqing, LI Rui. Algorithm and experimental validation for condition monitoring, fault detection for gas turbine engine[J]. Journal of Propulsion Technology, 2011, 32(2): 271-275. (in Chinese)
- [2] 吕永乐,郎荣玲,路辉,等.航空发动机性能参数联合 RBF-PN 和 FAR 预测[J].北京航空航天大学学报,2010,36(2):131-134.
LÜ Yongle, LANG Rongling, LU Hui, et al. Prediction of aeroengine's performance parameter combining RBF-PN and FAR[J]. Journal of Beijing University of Aeronautics and Astronautics, 2010, 36(2): 131-134. (in Chinese)
- [3] KUMAR A, SRIVASTAVA A, GOEL N, et al. Exhaust gas temperature prediction by autoregressive models [C]//Proceeding of the IEEE 28th Canadian Conference on Electrical and Computer Engineering. Halifax, Canada: IEEE, 2015: 976-981.
- [4] ILBAS M, TURKMEN M. Estimation of exhaust gas temperature using artificial neural network in turbofan engines [J]. Journal of Thermal Science and Technology, 2012, 32(2): 11-18.
- [5] YILMAZ I. Evaluation of the relationship between exhaust gas temperature and operational parameters in CFM56-7B engines [J]. Proceedings of the Institution of Mechanical Engineers, 2009, 223(4): 433-440.
- [6] 于广滨,丁刚,姚威,等.基于支持过程向量机的航空发动机排气温度预测[J].电机与控制学报,2013,17(8):30-36.
YU Guangbin, DING Gang, YAO Wei, et al. Aeroengine exhaust gas temperature prediction using support process vector machine [J]. Electric Machines and Control, 2013, 17(8): 30-36. (in Chinese)
- [7] 钟诗胜,雷达,丁刚.卷积和离散过程神经网络及其在航空发动机排气温度预测中的应用[J].航空学报,2012,33(3):438-445.
ZHONG Shisheng, LEI Da, DING Gang. Convolution sum discrete process neural network and its application in aero-engine exhausted gas temperature prediction [J]. Acta Aeronautica et Astronautica Sinica, 2012, 33(3): 438-445. (in Chinese)
- [8] 丁刚,徐敏强,侯立国.基于过程神经网络的航空发动机排气温度预测[J].航空动力学报,2009,24(5):1035-1039.
DING Gang, XU Minqiang, HOU Ligu. Prediction of aeroengine exhaust gas temperature using process neural network [J]. Journal of Aerospace Power, 2009, 24(5): 1035-1039. (in Chinese)
- [9] 陈娇,王永泓,翁史烈.广义回归神经网络在燃气轮机排气温度传感器故障检测中的应用[J].中国电机工程学报,2009,29(32):92-97.
CHEN Jiao, WANG Yonghong, WENG Shilie. Application of general regression neural network in fault detection of exhaust temperature sensors on gas turbines [J]. Proceedings of the CSEE, 2009, 29(32): 92-97. (in Chinese)
- [10] PANDA B N, BAHUBALENDRUNI V A R M, BISWAL B B. Optimization of resistance spot welding parameters using differential evolution algorithm and GRNN [C]//Proceedings of 8th IEEE International Conference on Intelligent Systems and Control. Coimbatore, India: IEEE, 2014: 50-55.
- [11] 潘文超.果蝇最佳化演算法:最新演化式计算技术[M].台北:沧海书局,2011.
- [12] PAN W T. A new fruit fly optimization algorithm: taking the financial distress model as an example [J]. Knowledge-Based Systems, 2012, 26: 69-74.
- [13] LI Hongze, GUO Sen, LI Chunjie, et al. A hybrid annual power load forecasting model based on generalized regression neural network with fruit fly optimization algorithm [J]. Knowledge-Based Systems, 2013, 37: 378-387.
- [14] 王友卫,朱建明,凤丽洲.基于群密度的改进果蝇优化算法及在异常检测中的应用[J].工程科学与技术,2017,49(5):127-134.
WANG Youwei, ZHU Jianming, FENG Lizhou. Improved fruit fly optimization algorithm based on population density and its application in anomaly detection [J]. Advanced Engineering Sciences, 2017, 49(5): 127-134. (in Chinese)
- [15] 唐鸣东,史秀志,周健,等.基于CFOA-GRNN的冲击地压危险等级预测[J].中国安全科学学报,2016,26(12):110-115.
TANG Mingdong, SHI Xiuzhi, ZHOU Jian, et al. Prediction of rock-burst risk rating based on CFOA-GRNN network [J]. China Safety Science Journal, 2016, 26(12): 110-115. (in Chinese)
- [16] 李冬辉,尹海燕,郑博文.基于MFOA-GRNN模型的年电力负荷预测[J].电网技术,2018,42(2):585-590.
LI Donghui, YIN Haiyan, ZHENG Bowen. An annual load forecasting model based on generalized regression neural

- network with multi-swarm fruit fly optimization algorithm [J]. Power System Technology, 2018, 42(2): 585-590. (in Chinese)
- [17] LI Penghua, HU Fangchao, LI Yingguo. Speaker identification based on gammatonecepstral coefficients and general regression neural network [C] // Proceedings of Control and Decision Conference (2014 CCDC). Changsha, China: IEEE, 2014: 751-756.
- [18] TOMANDL D, SCHOBER A. Modified general regression neural network (MGRNN) with new efficient training algorithms as a robust black box-tool for data analysis [J]. Neural Network, 2001, 14(8): 1023-1034.
- [19] LI Hongze, GUO Sen, ZHAO Huiru, et al. Annual electric load forecasting by a least squares support vector machine with a fruit fly optimization algorithm [J]. Energies, 2012, 5(11): 4430-4445.

(编辑:李岩梅)

SAU