

# 基于 AFOA-BP 神经网络的燃气轮机研制风险预测

谢雨诗<sup>1</sup>, 何丽娜<sup>1</sup>, 徐文燕<sup>2</sup>, 明新国<sup>3</sup>

(1. 西南交通大学 机械工程学院, 四川 成都 611730; 2. 中国船舶集团有限公司第七〇三研究所, 黑龙江 哈尔滨 150078;  
3. 上海交通大学 机械与动力工程学院, 上海 200240)

**摘要:**为提高燃气轮机研制过程中的风险管理能力, 针对果蝇算法(Fruit Fly Optimization Algorithm, FOA)及BP神经网络的缺陷, 构建了自适应果蝇算法(Adaptive Fruit Fly Optimization Algorithm, AFOA), 提出基于自适应果蝇算法优化BP神经网络的风险预测模型, 利用自适应果蝇算法优化BP神经网络的阈值和权值。挖掘燃气轮机研制风险因素及风险事件之间的关系, 并根据风险因素的权重预测风险事件的权重。利用燃气轮机研制风险的相关历史数据进行验证, 表明该模型具有较高的预测精度和应用价值。

**关键词:**燃气轮机; 风险预测; 果蝇优化算法; BP神经网络

中图分类号: C935 文献标识码: A DOI: 10.16146/j.cnki.rndlgc.2021.10.030

[引用本文格式] 谢雨诗, 何丽娜, 徐文燕, 等. 基于 AFOA-BP 神经网络的燃气轮机研制风险预测[J]. 热能动力工程, 2021, 36(10): 228-234. XIE Yu-shi, HE Li-na, XU Wen-yan, et al. Risk prediction of gas turbine development based on AFOA-BP neural network[J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(10): 228-234.

## Risk Prediction of Gas Turbine Development based on AFOA-BP Neural Network

XIE Yu-shi<sup>1</sup>, HE Li-na<sup>1</sup>, XU Wen-yan<sup>2</sup>, MING Xin-guo<sup>3</sup>

(1. School of Mechanical Engineering, Southwest Jiaotong University, Chengdu, China, Post Code: 611730;  
2. No. 703 Research Institute of CSSC, Harbin, China, Post Code: 150078; 3. School of Mechanical and Power Engineering, Shanghai Jiao Tong University, Shanghai, China, Post Code: 200240)

**Abstract:** In order to improve the ability of risk management in the process of gas turbine development, aiming at the inherent defects of fruit fly optimization algorithm (FOA) and BP neural network, the adaptive fruit fly optimization algorithm (AFOA) is built, and the risk prediction model based on AFOA optimized BP neural network is proposed, by use of the parameters of the thresholds and weights of BP neural network optimized by AFOA. The prediction model can explore the relationship between risk factors and risk events in gas turbine development, and predict the weights of risk events according to the weights of risk factors. The model is verified by the relevant historical data about gas turbine development risk. The result shows that the model has higher prediction accuracy and application value.

收稿日期: 2021-04-07; 修订日期: 2021-05-31

基金项目: 国家科技重大专项(2017-I-0011-0012); 国家自然科学基金委项目(51705436); 四川省科技计划项目(2021JDRC0174); 船舶与海洋工程动力系统国家工程实验室-海洋工程燃气轮机实验室资助项目

Fund-supported Project: National Science and Technology Major Project of China (2017-I-0011-0012); National Natural Science Foundation of China (51705436); Sichuan Science and Technology Program (2021JDRC0174); Supported by National Engineering Laboratory for Marine and Ocean Engineering Power System - Laboratory for Ocean Engineering Gas Turbine

作者简介: 谢雨诗(1995-), 女, 四川成都人, 西南交通大学硕士研究生。

通讯作者: 何丽娜(1987-), 女, 山西运城人, 西南交通大学讲师。

**Key words:** gas turbine, risk prediction, fruit fly optimization algorithm, BP neural network

引 言

燃气轮机在军用及民用领域占据着重要地位,是国家工业水平的重要体现<sup>[1]</sup>。由于燃气轮机具有结构复杂、研制周期长、技术密集且要求高、涉及学科广、参研人员众多等特点,研制过程中必然存在多种不确定性,从而导致风险事件的产生,影响研制计划的顺利开展<sup>[2]</sup>。因此,开展燃气轮机研制风险预测有非常重要的意义,有利于提前识别关键风险事件,为燃气轮机研制的管理和决策提供理论和技术支持。

燃气轮机是一种典型的大型复杂产品,针对复杂产品研制风险管理的研究主要集中于风险识别及风险评价阶段,常用的方法有风险概率影响矩阵法<sup>[3]</sup>、综合模糊评价法<sup>[2-4]</sup>、层次分析法<sup>[4]</sup>和云推理模型<sup>[5]</sup>等。这些方法主要基于主观评价确定研制风险的权重,评价过程耗时长、依赖于专家知识及经验、计算繁琐,难以实现研制风险预测。

燃气轮机研制过程中存在各种风险因素,导致风险事件的产生。准确表达风险因素与风险事件之间复杂的非线性映射关系是燃气轮机研制风险事件预测的关键,基于映射关系及风险因素的权重可预测风险事件的权重,从而为风险缓解策略的制定提供决策依据。目前,关于风险预测的方法主要有逻辑回归策略<sup>[6]</sup>、多判别分析法、决策树算法<sup>[7]</sup>、似然比回归算法、支持向量机算法<sup>[8]</sup>和神经网络算法<sup>[9]</sup>等。其中,BP 神经网络因其结构简单、具有较强的非线性映射能力和自学习能力<sup>[10]</sup>,在风险预测中得到了广泛应用。但是 BP 神经网络存在容易陷入局部极小值、收敛速度较慢等问题<sup>[11]</sup>。

针对 BP 神经网络存在的问题,本文采用自适应果蝇算法优化 BP 神经网络的阈值和权值,基于自适应果蝇算法优化的 BP 神经网络挖掘燃气轮机研制风险因素及风险事件之间的关系,并根据风险因素的权重预测风险事件的权重。

1 BP 神经网络

BP 神经网络是通过误差反向传播训练的多层前馈网络,具有较强的非线性逼近能力、自组织及自学习能力,在处理复杂的非线性问题建模方面具有一定的优势<sup>[12]</sup>。其模型结构如图 1 所示。结构分为输入层、隐含层和输出层。BP 神经网络的实现原理是将样本通过输入层接入网络,在隐含层分析处理,学习的结果从输出层得到;如果输出结果与实际存在误差,误差将通过原来的逆路径修正网络的权值和阈值,直到满足误差精度为止。

BP 神经网络权值与阈值的取值对模型的训练速度及预测精度有重要作用<sup>[10-11]</sup>,而传统 BP 神经网络模型的初始权值与阈值通过随机赋值的方式确定,可能导致模型收敛速度较慢、训练时间长、易陷入局部极小值等问题。因此,有必要对权值和阈值进行优化,基于优化的权值及阈值确定 BP 神经网络的初始结构。




图 1 BP 神经网络结构  
Fig. 1 BP neural network structure

2 自适应果蝇优化算法

果蝇优化算法(Fruit Fly Optimization Algorithm, FOA)是潘文超<sup>[13]</sup>基于果蝇觅食行为的仿生学原理提出的一种群体智能全局优化算法。与遗传算法、蚁群算法等优化算法相比,FOA 算法具有结构简单、计算量小、易于理解等优点,在优化问题中得到了广泛应用<sup>[14-15]</sup>。传统 FOA 算法在寻优过程中采用固定步长,难以实现全局搜索能力和局部搜索能

力之间权衡<sup>[16]</sup>。为此,基于进化代数调整迭代步长,提出自适应果蝇优化算法 (Adaptive Fruit Fly Optimization Algorithm, AFOA),如式(1)所示。自适应步长的调整机制在进化前期,为避免陷入局部最优,增加全局寻优速度,采用较大的迭代步长;随着迭代次数的增加,减小迭代步长,提高寻优精度,避免错过最优解。图 2 描述了迭代步长的调整趋势。

$$R_g = \frac{(R_{\max} - R_{\min})}{2} \cdot \sin\left(\frac{g \cdot \pi}{G} + \frac{\pi}{2}\right) + \frac{(R_{\max} + R_{\min})}{2} \tag{1}$$

式中:  $G$ —最大进化代数;  $g$ —当前进化代数;  $R_{\max}$ 、 $R_{\min}$ —迭代步长的最大值及最小值。




图 2 自适应迭代步长  
Fig.2 Adaptive iteration step size

3 基于 AFOA-BP 的燃气轮机研制风险预测

为克服应用 BP 神经网络时出现收敛速度慢和陷入局部极小值等问题,本文结合果蝇优化算法的优势,应用自适应果蝇优化算法优化 BP 神经网络的初始权值和阈值,建立了基于 AFOA-BP 的燃气轮机研制风险预测模型。具体流程如图 3 所示。

步骤 1:通过专家调研、文献分析等方式识别燃气轮机研制过程中的主要风险因素及主要风险事件。假设共识别出  $u$  个风险因素,表示为  $\{RF_1, RF_2, \dots, RF_u\}$ ,  $v$  个风险事件,表示为  $\{RE_1, RE_2, \dots, RE_v\}$ 。

步骤 2:搜集燃气轮机研制过程中风险因素及风险事件权重的历史数据,并对数据进行归一化处理,从而构成预测模型的样本序列。假设有  $N$  组样

本数据,第  $n$  组样本数据为  $Z_n = (d_{n1}, d_{n2}, \dots, d_{nu}, m_{n1}, m_{n2}, \dots, m_{nv})$ ,  $n = 1, 2, \dots, N$ 。其中,  $D_n = (d_{n1}, d_{n2}, \dots, d_{nu})$  为第  $n$  组样本中各风险因素的权重,为预测模型的输入;  $M_n = \{m_{n1}, m_{n2}, \dots, m_{nv}\}$  表示第  $n$  组样本中各风险事件的权重,为预测模型的输出。




图 3 AFOA-BP 预测模型的流程  
Fig.3 The process of AFOA-BP prediction model

步骤 3:初始化参数。基于所识别的燃气轮机研制风险因素及风险事件,设置 BP 神经网络输入层节点数目为  $u$  个风险因素,输出层节点数目为  $v$  个风险条件,隐含层节点数目为  $h$ ;设置 AFOA 算法的最大进化代数  $G$ ,最大步长  $R_{\max}$ ,最小步长  $R_{\min}$ ,种群数量  $S$ ,种群规模  $p$  代表 BP 神经网络所需优化权值及阈值的数目,则  $p = uh + hv + h + v$ 。果蝇种群的个体构成如图 4 所示。

步骤 4:生成初始果蝇种群的位置  $X = (X_1, X_2, \dots, X_s)$ ,其中  $X_i = (x_{i,1}, x_{i,2}, \dots, x_{i,p})$  为第  $i$  个种群的横坐标;  $Y = (Y_1, Y_2, \dots, Y_s)$ ,其中  $Y_i = (y_{i,1}, y_{i,2}, \dots, y_{i,p})$  为第  $i$  个种群的纵坐标,  $i = 1, 2, \dots, S$ 。




图 4 果蝇种群示意图

Fig.4 Schematic diagram of the fruit fly population

步骤 5:赋予其他果蝇种群个体觅食的飞行距离和方向,令当前进化代数  $g = 1$ 。

$$X_i = X_i + R_g \times (2 \times \text{rand}(1, p) - 1) \quad (2)$$

$$Y_i = Y_i + R_g \times (2 \times \text{rand}(1, p) - 1) \quad (3)$$

步骤 6:计算各种群果蝇个体距原点的距离,并确定浓度判断值。

$$\begin{cases} D_i = \sqrt{X_i^2 + Y_i^2} \\ S_i = \frac{1}{D_i} \end{cases} \quad (4)$$

步骤 7:将种群个体的味道浓度判定值  $S_i$  作为 BP 神经网络的权值和阈值,并输入 BP 神经网络进行模型训练、预测。将预测模型的预测误差函数作为味道浓度的判定函数,并计算种群的味道浓度值  $\text{Smell}_i$ 。

$$\text{Smell}_i = F(S_i) \quad (5)$$

$$F = \frac{\sum_{t=1}^T \sum_{f=1}^v \left| \frac{y_{t,f} - y'_{t,f}}{y_{t,f}} \right|}{T} \quad (6)$$

式中: $y_{t,f}$ —第  $t$  组测试样本的第  $f$  项风险事件重要度实际值; $y'_{t,f}$ —第  $t$  组测试样本的第  $f$  项风险事件重要度预测值; $v$ —预测风险事件的数量; $T$ —测试样本的数量。

步骤 8:找出果蝇群体中适应度值最小,即味道浓度最低的种群,记录味道浓度值和相应的位置。

$$[\text{bestSmell}, \text{bestindex}] = \min(\text{Smell}) \quad (7)$$

步骤 9:保留最佳的味道浓度和位置坐标,群体中其他果蝇飞向最佳位置。

$$\text{Smellbest} = \text{bestSmell}$$

$$S_{\text{best}} = S_{\text{bestindex}}$$

$$\begin{cases} X_i = X_{\text{bestindex}} \\ Y_i = Y_{\text{bestindex}} \end{cases}$$

步骤 10:令  $g = g + 1$ ,判断算法  $g$  是否小于  $G$ 。

若  $g < G$ ,则重复步骤 5 ~ 步骤 8,同时判断当前种群的最佳味道是否低于  $\text{Smellbest}$ ,若满足,则执行步骤 9 ~ 步骤 10,否则执行步骤 10;若不满足  $g < G$ ,则结束优化算法,并输出  $\text{Smellbest}$  及  $S_{\text{best}}$ ;

步骤 11:AFOA 算法输出的  $S_{\text{best}}$  为 BP 神经网络的最优权值及阈值,将  $S_{\text{best}}$  代入 BP 神经网络,并基于样本数据进行网络训练。达到训练要求后,固化网络,从而形成燃气轮机研制风险重要度的预测模型。

步骤 12:基于步骤 11 构建的预测模型,结合风险因素的重要度预测燃气轮机研制风险事件重要度。

## 4 案例分析

### 4.1 数据准备

以某燃气轮机研制风险管理为例,构建基于 AFOA-BP 神经网络的风险预测模型。燃气轮机研制风险事件是多个风险因素共同耦合的产物。通过专家调研、文献分析、主成分分析等方法,确定出燃气轮机研制过程中的 12 项主要风险因素:部件性能和总体设计要求不符(RF1),压气机和涡轮匹配性不好(RF2),设计方法或设计软件使用不当(RF3),设计状态和实际存在偏差(RF4),测量不准确(RF5),冷却结构设计不合理(RF6),试验件加工延期(RF7),试验台条件不具备(RF8),试验反复造成延期(RF9),试验台任务安排不当(RF10),生产周期紧张(RF11),压气机试验延期(RF12);8 项风险事件:整机性能指标未完全满足要求(RE1),压气机性能指标未完全满足要求(RE2),间冷器性能指标未完全满足要求(RE3),燃烧室性能指标未完全满足要求(RE4),涡轮冷却叶片性能指标未完全满足要求(RE5),整体项目进展不能按计划完成(RE6),压气机试验不能按计划完成(RE7),燃烧室试验不能按计划完成(RE8)。

基于产品数据管理系统、历史研制文档等提取燃气轮机研制风险因素及风险事件重要度的历史数据,剔除模糊失真数据后,得到 60 组样本数据,随机选取 45 组数据作为训练样本,其余 15 组数据作为测试样本。对样本数据进行归一化处理,部分样本

如表 1 所示。

表 1 样本数据  
Tab.1 Sample data

| 序号  | 输入(风险因素) |        |        |     |        |        |        | 输出(风险事件) |        |     |        |        |
|-----|----------|--------|--------|-----|--------|--------|--------|----------|--------|-----|--------|--------|
|     | RF1      | RF2    | RF3    | ... | RF10   | RF11   | RF12   | RE1      | RE2    | ... | RF7    | RF8    |
| 1   | 0.0274   | 0.0959 | 0.0274 | ... | 0.0685 | 0.0959 | 0.0685 | 0.1359   | 0.1501 | ... | 0.1064 | 0.1242 |
| 2   | 0.1127   | 0.0563 | 0.0986 | ... | 0.0563 | 0.0563 | 0.1127 | 0.1402   | 0.1449 | ... | 0.1093 | 0.1236 |
| 3   | 0.0143   | 0.1286 | 0.1286 | ... | 0.0714 | 0.0571 | 0.1000 | 0.1488   | 0.1098 | ... | 0.1052 | 0.1299 |
| 4   | 0.1143   | 0.0857 | 0.0571 | ... | 0.1000 | 0.0571 | 0.0857 | 0.1497   | 0.1617 | ... | 0.1081 | 0.1322 |
| ... | .....    | .....  | .....  | ... | .....  | .....  | .....  | .....    | .....  | ... | .....  | .....  |
| 60  | 0.1667   | 0.1111 | 0.1667 | ... | 0.0926 | 0.0741 | 0.0741 | 0.1270   | 0.1328 | ... | 0.1247 | 0.1149 |

4.2 基于 AFOA-BP 神经网络的风险预测模型测试结果及分析

根据 AFOA-BP 预测模型构建流程,设置算法的初始化参数。其中 BP 神经网络输入层节点数  $u = 12$ ,输出层节点数  $v = 8$ ,依据式(8)确定隐含层节点数  $h = 9$ ,学习速率  $\gamma = 0.01$ ,训练次数  $m = 600$ ;AFOA 算法最大迭代步数  $G = 200$ ,种群规模由步骤 3 得  $p = 197$ ,最大搜索步长  $R_{\max} = 5$ ,最小搜索步长  $R_{\min} = 0.1$ 。

$$h = \sqrt{u + v} + w, w \in [1, 10]$$
 (8)

首先应用 AFOA 算法优化 BP 神经网络的权重及阈值,同时将 AFOA 算法与传统 FOA 算法进行比较,迭代对比情况如图 5 所示。可以看出,AFOA 算法在第 7 代时收敛,最佳适应度值为 0.065 8。与传统 FOA 算法相比,AFOA 算法的收敛速度更快,寻优精度也有所提高。




图 5 AFOA 及传统 FOA 算法的寻优曲线  
Fig.5 Optimal curves of AFOA and traditional FOA

将 AFOA 算法得到的最优权重和阈值代入到 BP 神经网络模型中,通过训练样本来训练模型,然后应用测试样本检验所构造预测模型的预测精度。为验证 AFOA-BP 神经网络所构造模型的精度,将其与 BP 神经网络预测模型、FOA-BP 神经网络预测模型进行对比。其中 BP 神经网络预测模型的初始权重和阈值随机产生,传统 FOA 算法的步长为 5,其他参数保持一致。3 种预测模型的相对预测误差如表 2 所示,其对比如图 6 所示。可以看出,AFOA-BP 神经网络预测模型的预测误差相对较小且波动较稳定。

表 2 3 种模型的预测误差

Tab.2 Prediction errors of three models

| 模型      | 测试样本误差 |        |     |        |        |
|---------|--------|--------|-----|--------|--------|
|         | 1      | 2      | ... | 14     | 15     |
| AFOA-BP | 0.0850 | 0.0593 | ... | 0.0705 | 0.0701 |
| FOA-BP  | 0.0742 | 0.1499 | ... | 0.1378 | 0.1405 |
| BP      | 0.0574 | 0.1046 | ... | 0.1349 | 0.0573 |




图 6 3 种模型的预测误差对比  
Fig.6 Comparison of prediction errors of the three models

根据式(9)和式(10)分别计算 3 个预测模型的平均相对误差(MRE)和均方根误差(RMSE)。

$$MRE = \frac{1}{T} \sum_{t=1}^T \sum_{f=1}^v \left| \frac{y'_{t,f} - y_{t,f}}{y_{t,f}} \right| \times 100\% \quad (9)$$
$$RMSE = \sqrt{\frac{1}{T} \sum_t^T \sum_{f=1}^v \left( \frac{y'_{t,f} - y_{t,f}}{y_{t,f}} - MRE \right)^2} \quad (10)$$

表 3 为 3 种模型的预测精度对比。相比于其他模型,AFOA-BP 模型具有较低的 RMSE 和 MAE,表明基于 AFOA-BP 的风险预测模型具有较高的预测精度。

表 3 3 种模型的预测精度

Tab.3 Prediction accuracy of the three models

| 预测模型    | 预测精度     |          |
|---------|----------|----------|
|         | RMSE     | MAE/%    |
| AFOA-BP | 0.077 35 | 6.847 48 |
| FOA-BP  | 0.100 04 | 7.626 95 |
| BP      | 0.105 23 | 8.391 46 |

5 结 论

(1) 针对 FOA 及 BP 神经网络的缺陷,将自适应迭代步长引入 FOA,构建 AFOA 以改善其寻优性能。

(2) 采用 AFOA 优化 BP 神经网络的初始权重及阈值,构建了 AFOA-BP 神经网络模型以提高其预测精度,并基于此建立燃气轮机研制风险预测模型,以挖掘风险因素及风险事件之间的关系,并实现风险事件重要度的预测。

(3) 基于 AFOA-BP 神经网络模型的风险预测模型具有更高的预测精度,能够更好地应用于燃气轮机研制风险管理,为燃气轮机研制的顺利进行提供一定的方法支持。

参考文献:

[1] 蒋洪德,任 静,李雪英,等. 重型燃气轮机现状与发展趋势[J]. 中国电机工程学报,2014,34 (29):5096-5102.  
JIANG Hong-de,REN Jing,LI Xue-ying,et al. Status and development trend of the he-vy duty gas turbine[J]. Proceedings of the

CSEE,2014,34(29):5096-5102.  
[2] 高云峰. 高压压气机研制项目风险管理研究[D]. 吉林:吉林大学,2010.  
GAO Yun-feng. Research on the risk management of high pressure compressor deve-iopment project[D]. Jilin:Jilin University,2010.  
[3] 王天婕. 某型商用航空发动机研发项目中的风险管理研究[D]. 上海:上海交通大学,2014.  
WANG Tian-jie. Study on risk mangeme-nt for commercial aero engine development projct[D]. Shanghai:Shanghai Jiaotong University,2014.  
[4] 庄军辉. DB 模式下燃气轮机项目进度风险评价方法研究[D]. 大连:大连理工大学,2015.  
ZHUANG Jun-hui. Research on risk asses-sment of gas turbine project schedule under DB mode[D]. Dalian:Dalian University of Technology,2015.  
[5] 李晓松,王成志,陈庆华. 基于云推理模型的武器装备研制风险评估研究[J]. 运筹与管理,2011,20(3):111-118,145.  
LI Xiao-song, WANG Cheng-zhi, CHEN Qing-hua. Research on weapon equipment risk assessment based on cloud reasoning model [J]. Operation Sresearch and Management Science,2011,20(3):111-118,145.  
[6] Moon S-H, Kim Y-H. An improved forecast of precipitation type using correlation-based feature selection and multinomial logistic regression[J]. Atmospheric Research,2020,240:104928.  
[7] XIANG B,ZENG C,DONG X,et al. The application of a decision tree and stochastic forest model in summer precipitation prediction in chongqing[J]. Atmosphere,2020,11(5):508.  
[8] 位晶晶,刘勤明,叶春明,等. 基于 IPSO-BSVM 的小样本数据不均衡下的设备健康预测研究[J]. 计算机应用研究,2021,38(4):1-5.  
WEI Jing-jing, LIU Qin-ming, YE Chun-ming, et al. Equipment health prognosis based on IPSO-BSVM under small and imbalanced sam-ple data[J]. Application Research of Computers,2021,38(4):1-5.  
[9] FENG J,YUAN B,LI X,et al. Evalua-tion on risks of sustainable supply chain ba-sed on optimized BP neural networks in fres-h grape industry [J]. Computers and Electronics in Agriculture,2021,183,105988.  
[10] 张 霄,钱玉良,邱 正,等. 基于蜻蜓算法优化 BP 神经网络的燃气轮机故障诊断[J]. 热能动力工程,2019,34(3):26-32.  
ZHANG Xiao,QIAN Yu-liang, QIU Zheng,et al. Gas turbine fault diagnosis based on BP neural network optimized by dragonfly algorithm[J]. Journal of Engineering for Thermal Energy and Pow-

er,2019,34(3):26-32.

[11] 周方明,张明媛,袁永博. 基于 PCA-GA-BP 的工程项目工期风险预测研究[J]. 工程管理学报,2011,25(5):534-538.

ZHOU Fang-ming,ZHANG Ming-yuan,YUAN Yong-bo. Risk of project time based on PCA-GA-BP[J]. Journal of Engineering Management,2011,25(5):534-538.

[12] 关淑瑶. 基于 BP 神经网络的可持续供应链风险评估研究[D]. 秦皇岛:燕山大学,2018.

Guan Shu-yao. Research on sustal-nable supply chain risk assessm-ent based on BP neural network[D]. Qinhuangdao:;Yanshan University,2018.

[13] TSAO P W. A new fruit fly optimization algorithm;taking the financial distress model as an example[J]. Knowledge-Based Systems,2012,26:69-74.

[14] 葛晓霞,赵舒莹,肖洪闯,等. 基于改进果蝇算法优化 SVM 的凝汽器真空预测[J]. 热能动力工程,2020,35(11):39-45.

GE Xiao-xia,ZHAO Shu-ying,XIAO Hong-chuang,et al. Prediction of condenser vacuum based on SVM improved by IFOA[J]. Journal of Engineering for Thermal Energy and Power,2020,35(11):39-45.

[15] 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 Qi-qi,et al. Aeroengine exhaust gas temperature prediction model based on IFOA5-GRNN[J]. Journal of Aerospace Power,2019,34(1):8-17.

[16] 程宏伟,高 莲,于 虹,等. 基于改进果蝇算法优化 BP 神经网络的接地网腐蚀速率预测模型[J]. 电测与仪表,2020:1-10.

CHENG Hong-wei,GAO Lian,YU Hong,et al. Corrosion rate prediction model of grounding grid based on BP neural network optimized by updated fruit fly optimization algorithm[J]. Electrical Measurement & Instrumentation,2020:1-10.

(王治红 编辑)

(上接第 196 页)

[2] 陈丹之. 燃气轮机叶片的热腐蚀及其防止[J]. 燃气轮机技术,1992,5(4):9-14.

CHEN Dan-zhi. Hot corrosion and prevention of gas turbine blades[J]. Gas turbine technology,1992,5(4):9-14.

[3] KOSIENIAK E,BIESIADA K,KACZOROWSKI J,et al. Corrosion failures in gas turbine hot components[J]. Journal of failure analysis and prevention,2012(12):330-337.

[4] BHAGI L K,GUPTA P,RASTOGI V,et al. Fractographic investigations of the failure of L-1 low pressure steam turbine blade[J]. Case studies in engineering failure analysis,2013(1):72-78.

[5] ZIEGLER D,PUCCINELLI M,BERGALLO B,et al. Investigation of turbine blade failure in a thermal power plant[J]. Case studies in engineering failure analysis,2013(1):192-199.

(丛 敏 编辑)