

基于 CAFOA-GRNN 的包装机热封温度传感器的故障检测

陈小康¹, 涂焯², 许维东¹

(1.上海理工大学, 上海 200093; 2.上海工业自动化仪表研究院有限公司, 上海 200233)

摘要: **目的** 为了实现自动包装机热封工艺中温度传感器的故障实时故障检测。**方法** 使用广义回归神经网络 (General Regression Neural Network, GRNN) 构建了热封温度传感器状态自动检测网络, 再采用混沌加速果蝇优化算法 (Chaos Accelerated Fruit Fly Optimization Algorithm, CAFOA) 进行广义回归神经网络的学习因子优化选取, 求解出最优学习因子。通过建立 CAFOA-GRNN 自动检测模型, 再结合统计学中置信区间的方法, 对故障进行诊断分类。**结果** 在传感器故障实验中, 将理想故障函数与历史运行数据叠加, 产生故障数据集, 并将其用于验证建立的模型, 获得了较好的检测效果, 准确率较高。**结论** 该方法实现了传感器故障的实时检测, 可以用于提高生产的可靠性, 具有一定的工程实用价值。

关键词: 广义回归神经网络; 混沌加速果蝇优化算法; 学习因子; 置信区间

中图分类号: TB486 文献标识码: A 文章编号: 1001-3563(2019)13-0207-07

DOI: 10.19554/j.cnki.1001-3563.2019.13.030

Packaging Machine Heat Sealing Temperature Sensor Fault Detection Based on CAFOA-GRNN

CHEN Xiao-kang¹, TU Xuan², XU Wei-dong¹

(1.University of Shanghai for Science and Technology, Shanghai 200093, China;

2.Shanghai Institute of Process Automation and Instrumentation, Shanghai 200233, China)

ABSTRACT: The paper aims to realize the fault real-time fault detection of the temperature sensor in the heat sealing process of the automatic packaging machine. The generalized regression neural network (GRNN) was used to construct a state automatic detection network of heat-sealed temperature sensor, and then the Chaos Accelerated Fruit Fly Optimization Algorithm (CAFOA) was used to study the generalized regression neural network. Factor optimization was selected to solve the optimal learning factor. By establishing a CAFOA-GRNN automatic detection model, combined with the statistical confidence interval method, the faults were classified and diagnosed. In the sensor failure experiment, the ideal fault function was superimposed with the historical operation data to generate the fault data set, to verify the established model. Good detection effect was obtained, and the accuracy was high. The method realizes the real-time detection of sensor failure, and can be used to improve the reliability of production, and has certain engineering practical significance.

KEY WORDS: general regression neural network; chaos accelerated fruit fly optimization algorithm; learning factor; confidence interval

目前包装机的热封控制系统, 温度控制主要采用闭环的 PID 控制, 热封温度和热封时间为主要的控制

变量。自动包装机温度控制系统采用响应速度快的热电偶传感器作为温度传感器, 实时检测热封头的温

收稿日期: 2018-12-11

作者简介: 陈小康 (1994—), 男, 上海理工大学硕士生, 主攻故障诊断、机器学习、神经网络。

通信作者: 涂焯 (1974—), 男, 教授级高级工程师, 主要研究方向为智能制造、人工智能。

度,因而温度传感器的工作状态和精确度直接关系到温度控制的效果。随着温度传感器工作时间延长,传感器的性能将会下降,而且工业现场环境较为恶劣,传感器易发生各种故障,所以传感器的状态检测就显得尤为重要。

传统的传感器检测方法是基于精确的物理模型和数学模型^[1-2],获取正常信号和故障信号之间的联系,从而进行故障的检测,主要包括状态估计法、参数估计法、等价空间法、分析冗余法等,但是实际的工业现场往往较为复杂,因此获得精确的物理和数学模型较为困难,所以该类故障检测方法具有一定的局限性。随着人工智能的发展,出现了基于人工智能算法的故障检测方法^[3-5]。包括支持向量(SVM)^[6]、人工神经网络(ANN)^[7-12]、模糊数学、证据理论等。目前在传感器故障检测方面的研究有:管毅^[13]等人提出将支持向量机运用到无线传感器故障检测中,但由于支持向量在解决二类问题中具有较好的运用效果,在多类问题中需要多个分类器,使得分类具有一定的局限性;由于人工神经网络在处理非线性问题时有很大优势,具有良好的泛化能力和鲁棒性,陈娇^[14]等运用 GRNN 网络进行了燃气轮机温度传感器故障检测,但是 GRNN 模型具有一定的缺陷,学习因子的选取采用人工设置的方式,这样得出的结果未必是全局最优的学习因子。为了克服 GRNN 模型的缺陷,减少人工参数对实验结果的影响,文中提出运用混沌加速果蝇优化算法^[15]优化 GRNN 的学习因子,获得最佳的 CAFOA- GRNN 模型,实验显示具有更好的检测效果。

1 GRNN 神经网络结构

广义回归神经网络具有良好的非线性映射能力和学习速度,比 RBF 更有优势,网络收敛速度快,样本数据少时,预测效果好,而且可以处理不稳定数据,比较适合处理传感器正常数据较多、故障数据较少的情况。GRNN 由 4 层构成,见图 1,分别为输入层、模式层、求和层和输出层。




图 1 GRNN 网络结构
Fig.1 GRNN's network structure

1) 输入层:神经元的数目等于输入样本中向量的维数 m ,各神经元与下一层全连接,将输入变量传递给模式层。

$$\bar{x}_0 = (x_{01}, x_{02} \dots x_{0m}) \tag{1}$$

2) 模式层:模式层神经元的个数和学习样本数目 n 相等,各个神经元对应不同的样本,神经元的传递函数为:

$$p_i = \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \quad i = 1, 2, 3 \dots n \tag{2}$$

式中: n 为样本个数; σ 为学习因子; X 为网络输入变量; X_i 为第 i 个神经元对应的样本。

3) 求和层:使用 2 种不同的神经元进行求和。一类的计算公式为:

$$\sum_{i=1}^n \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \tag{3}$$

它对所有模式层神经元的输出进行求和,其模式层与各神经元的连接权值为 1,传递函数为:

$$S_D = \sum_{i=1}^n p_i \tag{4}$$

另一类神经元的计算公式为:

$$\sum_{i=1}^n Y_i \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \tag{5}$$

它对所有模式层的神经元进行加权求和,模式层中第 i 个神经元与求和层中第 j 个分子求和,神经元之间的连接权值为第 i 个输出样本 Y_i 中的第 j 个元素:

$$S_{Zj} = \sum_{i=1}^n y_{ij} p_i \quad j = 1, 2, 3 \dots k \tag{6}$$

式中: j 为输出变量的维数。

4) 输出层:输出层中的神经元数目等于学习样本中输出向量的维数 k ,各神经元将求和层的输出相除,得到相应的输出预测结果的第 j 个元素,即:

$$y_j = \frac{S_{Zj}}{S_n} \quad j = 1, 2, 3 \dots k \tag{7}$$

2 CAFOA-GRNN 算法模型

果蝇算法^[16](FOA)是一种全局寻优的群智能算法,与粒子群算法、蚁群算法相似,但是比粒子群、蚁群算法具有更多优势,如设置参数少、收敛速度快、精度高、算法结构简单等。利用 FOA 算法优化选取 GRNN 网络的学习因子 σ ,能够提高网络的性能,提高预测的精度。传统的果蝇算法的搜索步长固定,使得搜索速率下降,且容易早熟陷入局部最优,文中运用加速搜索算法和混沌算法结合改进 FOA 算法,提高果蝇算法的搜索效率和准确率。

2.1 自适应加速搜索算法 (SAAS)

传统的 FOA 算法搜索的步长固定, 在搜索开始情况下, 按照固定的步长进行搜索, 将增加搜索的时间, 在靠近最优值时, 由于步长固定可能飞过最优值, 这样将大大增加搜索的时间, 降低搜索效率。文中运用 SAAS 算法, 使得搜索步长动态变化, 从而更新果蝇的位置, 提高搜索效率。

定义步长变量为 step:

$$\text{step} = \frac{(g_{\max} - g)^2 + 1}{\lambda g_{\max}^2} \quad (8)$$

$$A_l^{g+1} = A_{l_{\text{best}}}^g + \text{step} \cdot \min\{|A_{l_{\text{best}}}^g - A_{l_{\max}}^g|, |A_{l_{\text{best}}}^g - A_{l_{\min}}^g|\} + \text{step} \cdot \text{rand}() \quad (9)$$

式中: l 为果蝇种群中个体数量, $l=1,2,\dots,N$; g 为当前果蝇处于的代数; g_{\max} 为种群最大进化代数; λ 为步长调节系数, 结合优化过程中问题进行调节; A_l^{g+1} 为第 l 个果蝇在下一代中的位置; $A_{l_{\text{best}}}^g$ 为第 l 个果蝇在当前代中的最佳位置; $A_{l_{\max}}^g$, $A_{l_{\min}}^g$ 为第 l 个果蝇在 g 代中的最大和最小位置; $\text{rand}()$ 为 $(0, 1)$ 之间的随机数。

2.2 全局混沌扰动算法 (GCPA)

由于果蝇算法后期, 果蝇个体朝果蝇适应度值最大的地方聚集, 容易陷入局部最优。混沌理论是一种全局优化技术, 可以有效地防止算法进入局部最优。运用混沌映射理论改进 FOA 算法, 加入全局混沌扰动算法^[17] (GCPA), 增加果蝇种群的多样性, 避免陷入局部最优。目前的研究大多数采用 Logistics 映射、Tent 映射和 An 映射等。运用 Chebyshev 映射来产生全局的混沌扰动, Chebyshev 相对于其他映射具有更好的混沌特性。其函数表达式为:

$$x_{p+1} = \cos(4 \cdot \arccos x_p) \quad x_p \in [-1, 1] \quad (10)$$

基于 Chebyshev 映射函数的 GCPA 具体步骤如下所述。

1) 假设混沌遍历次数为 M 。

2) 设置 $P=1$ 。

3) 根据映射函数, 随机初始化生成混沌向量 $(a_{11}, a_{12}, \dots, a_{1N})$ 。

4) 通过式 (9) 利用混沌变量将的区间 $(A_{l_{\min}}^g, A_{l_{\max}}^g)$ 变换到 $A_l^{g+1(p)}$, 即第 k 个果蝇个体在 $g+1$ 代的第 p 次映射变换后的位置:

$$A_l^{g+1(p)} = A_{l_{\min}}^g + (A_{l_{\max}}^g - A_{l_{\min}}^g) \cdot a_{lp} \quad (11)$$

5) 若 $p < M$ 转至步骤 6), 否则转到步骤 7)。

6) $p = p+1$ 转至步骤 4)。

7) 将映射种群所有果蝇的位置的适应值大小排序得到最优解:

$$A_l^{g+1} = \min\{A_l^{g+1(1)}, A_l^{g+1(2)}, \dots, A_l^{g+1(p)}, A_{l_{\text{best}}}^g\} \quad (12)$$

2.3 混沌加速果蝇优化算法 (CAFOA)

该算法具体步骤如下所述。

1) 设置果蝇种群中个体的数量 $\text{sizepop} = N$ 和最大迭代次数 g_{\max} , 初始化种群的位置为 (X_0, Y_0) 以及初始种群代数 $g=0$ 。

$$X_0 = R_0 \times \text{rand}() \quad (13)$$

$$Y_0 = R_0 \times \text{rand}() \quad (14)$$

2) 设置果蝇种群的搜索方向和半径:

$$X_{(i)} = X_0 + \text{step} \cdot \text{rand}() \quad (15)$$

$$Y_{(i)} = Y_0 + \text{step} \cdot \text{rand}() \quad (16)$$

3) 计算果蝇位置距离原点的距离 $D_{(i)}$, 计算出距离的倒数作为味道浓度判别式的自变量值。

$$D_{(i)} = \sqrt{(X^2(i) + Y^2(i))} \quad (17)$$

$$S_{(i)} = \frac{1}{D_{(i)}} \quad (18)$$

4) 将自变量 $S_{(i)}$ 代入味道浓度函数 Smell , $S_{(i)}$ 作为 GRNN 网络的学习因子, 代入网络, 将网络的预测输出值与实际值的均方根误差值作为果蝇的味道浓度判别函数 $\text{Smell}_{(i)}$:

$$\text{Smell}_{(i)} = \sqrt{\frac{\sum_{i=1}^n (y_i - t_i)^2}{n}} \quad (19)$$

式中: y_i 为 GRNN 网络预测输出值; t_i 为实际值。

5) 当每代种群果蝇个体找到最佳的浓度值, 将果蝇的位置信息进行保留:

$$[\text{bestSmell}, \text{bestIndex}] = \min(\text{Smell}) \quad (20)$$

6) 将种群中所有的果蝇个体飞向该位置。

$$\text{Smell}_{\text{best}} = \text{bestSmell} \quad (21)$$

$$X_n = X(\text{bestIndex}) \quad (22)$$

$$Y_n = Y(\text{bestIndex}) \quad (23)$$

7) 计算果蝇群体的平均味道浓度 $\text{Smell}_{\text{avg}}$ 和浓度的方差 σ^2 :

$$\text{Smell}_{\text{avg}} = \sum_{i=1}^{\text{Sizepop}} \text{Smell}_i / \text{Sizepop} \quad (24)$$

$$\sigma^2 = \sum_{i=1}^{\text{Sizepop}} (\text{Smell}_i - \text{Smell}_{\text{avg}})^2 \quad (25)$$

8) 如果 $\sigma^2 < \delta, 0 < M$, 果蝇的下一代位置由混沌映射产生, 防止进入局部最优。混沌遍历 M 次, 产生下一代果蝇群体位置, 再进行味道浓度计算。

3 仿真与实验

3.1 CAFOA-GRNN 网络训练及测试

以某加工厂颗粒自动包装机系统 1 个月的温度

传感器历史数据为基础,其热封对象为热封低密度聚乙烯。将数据按时间分为30组,前15组数据作为训练数据集,10组数据用于检验模型预测精度,最后5组运行数据,用于叠加理想故障函数产生故障数据集,验证故障诊断分类的可行性。实验在 Matlab 2015b 下构建广义回归神经网络,网络输入为连续的历史温度数据,且初始化学因子为0.4,进行GRNN训练。当GRNN各个网络节点间的权值固定,对于优化GRNN网络就成了寻找单一变量最优学习因子 σ ,使得神经网络预测的相对误差最小的问题。

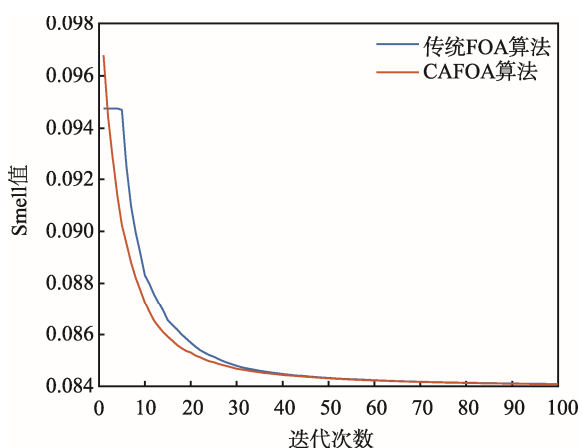


图2 CAFOA与FOA算法收敛对比
Fig.2 Comparison between CAFOA and FOA algorithm convergence

FOA及CAFOA算法设置种群个体数量 l 为120,最大迭代次数为100,收敛对比见图2。可知CAFOA算法相对于传统的FOA算法下降速度更快,而且加入混沌映射寻找的范围更广,且不易陷入局部最优。Smell(均方根误差值)收敛于0.084,最优学习因子 σ 的值为0.372。

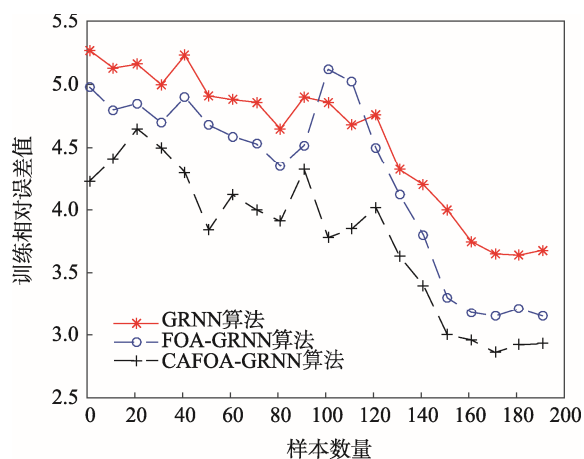


图3 优化前后训练相对误差对比
Fig.3 Comparison on relative error of training before and after optimization

传统 GRNN 算法、FOA-GRNN 算法以及

CAFOA-GRNN 算法的对比见图3,从图3可知,传统的GRNN和FOA-GRNN算法的训练最大相对误差分别5.27%和5.12%,平均相对误差分别为4.57%和4.27%。相比之下,运用CAFOA算法优化后的GRNN网络训练,最大相对误差为4.65%,平均相对误差为3.78%,具有更高的预测精度及稳定性。

3.2 传感器故障实验设计与检测

考虑到现场工业数据准确数据量大、故障数据量少的特点,设计传感器故障实验,获得故障数据集,该数据集用于验证所构建模型实时检测传感器故障类型的可行性与准确性。

对于传统的传感器故障类型,根据相关资料总结分析,得到的数学函数见表1,再利用MATLAB 2015b将数学函数离散化,叠加自动包装机该月最后5d的5组正常运行温度监控数据,形成故障检测数据集。测试故障数据集见图4。

表1 传感器理想故障数学模型
Tab.1 Ideal sensor mathematical model with fault

故障类型	数学表达式
理想阶跃故障	$f(t) + \delta(t), \delta(t) = \begin{cases} A & t \geq t_0 \\ 0 & t < t_0 \end{cases}$
理想开路故障	$ f(t) = \max f(t) \quad t \geq t_0$
理想短路故障	$ f(t) = \min f(t) = 0 \quad t \geq t_0$
理想脉冲故障	$f(t) + \delta(t), \delta(t) = \begin{cases} +\infty & t = t_0 \\ 0 & t \neq t_0 \end{cases}$
理想零漂故障	$\begin{cases} f(t) & t \geq t_0 \\ f(t) + at + b & t < t_0 \end{cases}$

从故障数据集中随机抽取的一组零漂故障数据,网络模型输出的实验结果见图5。该次测试运用训练好的CAFOA-GRNN网络来进行故障检测。分析总结多组故障种类预测输出与实际测量之间的相对误差,求解出每组故障数据的平均误差值,用于故障的诊断分类,得到每种故障类型预测值与实际值之间的平均相对误差值,见图6。

3.3 故障类型检测置信区间设计

由于工况的变化以及传感器使用时间的延长,会出现老化等现象,因此网络的预测输出和实际值之间的误差 $e_{(i)}$ 会产生波动,一般这种随机的波动符合正态随机分布 $N(\mu, \sigma^2)$ 。为了克服这种波动对于故障判别的影响,采用统计学中置信区间的方法,得出故障检测判别表,可以更加准确地对故障进行检测诊断分类。概率统计学上置信区间的步骤如下所述。

1) 确定待估参数估计量函数的分布:

$$\bar{e}_{(i)} = \frac{\sum_{i=1}^n e_{(i)}}{n} \tag{26}$$

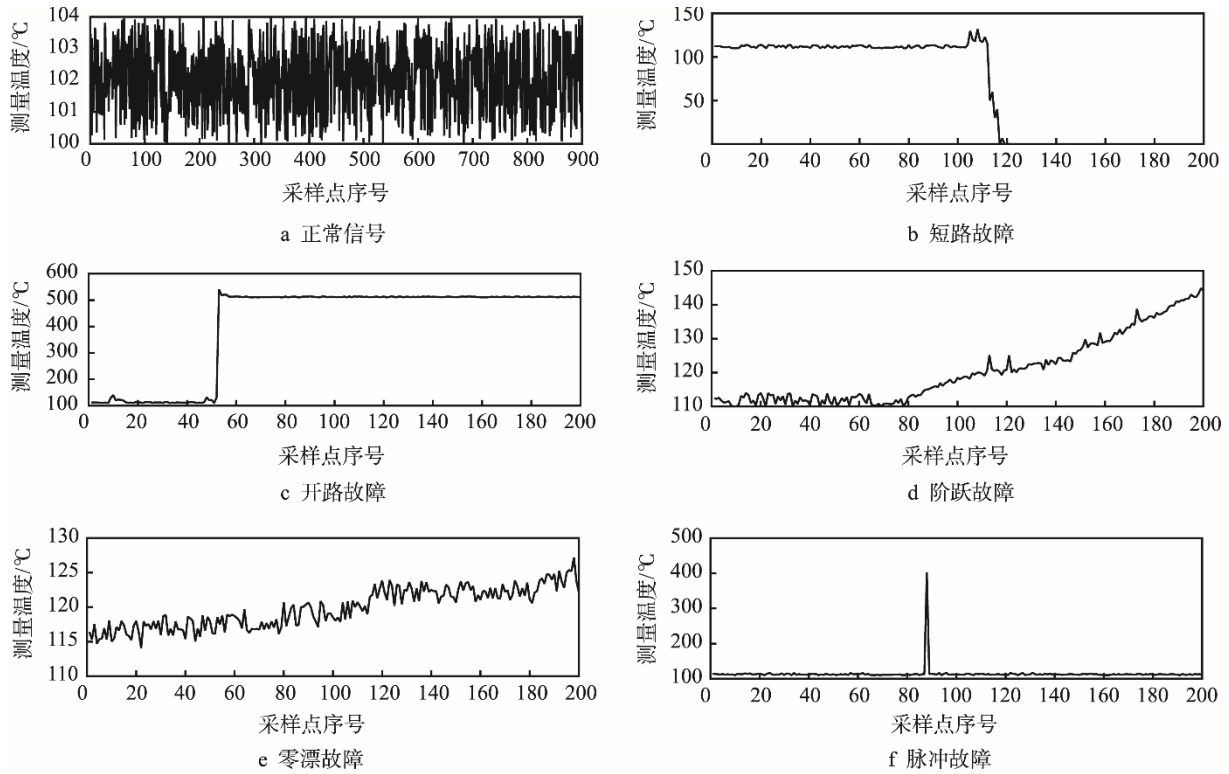


图 4 故障数据集
Fig.4 Fault data set




图 5 CAFOA-GRNN 模型预测结果
Fig.5 Prediction result of CAFOA-GRNN model




图 6 故障类型检测结果
Fig.6 Detection result of fault type

式中： $\bar{e}_{(i)}$ 为误差的平均值的求解公式。标准差求解公式为：

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (e_{(i)} - \bar{e}_{(i)})^2}{n-1}} \quad (27)$$

将相对误差参数转化为标准正态分布的公式为：

$$U = \frac{\bar{e}_{(i)} - \mu}{\sigma / \sqrt{n}} \sim N(0,1) \quad (28)$$

2) 对于给定的置信水平为 $1-\alpha$ ，由概率查表求出分布的分位数 $u_{(\alpha/2)}$ 。

3) 由分位数 $|U| \geq e_{(\alpha)}$ 确定置信区 $(\bar{\theta}, \underline{\theta})$ 就是 θ 的 $100(1-\alpha)\%$ 置信区间。

置信区间为：

$$\bar{e}_{(i)} - \frac{\sigma}{\sqrt{n}} u_{\alpha/2} < \mu < \bar{e}_{(i)} + \frac{\sigma}{\sqrt{n}} u_{\alpha/2} \quad (29)$$

在统计学中一般取 $\alpha = 0.025$ ，使得区间的置信度为 97.5%，查表得 $u_{\alpha/2} = 1.96$ ，则各类故障数据若有 97.5% 的可能性落入该置信区间，则认定为某类故障。通过计算结合上述置信区间求解方法和图 6 可得到故障判别表，见表 2。经多组数据实验得出，正常状态下，平均相对误差的阈值为 6.23%，当相对误差大于该数值，可由表 2 判断出传感器所发生的故障类型。

传感器故障分为随机性故障和部件老化故障。其中脉冲故障、开路故障、短路故障属于随机性故障，零漂和阶跃故障属于缓慢过程的部件老化故障。置信

区间能够在保证一定的准确率下,解决随机性故障检测中的随机性和不确定性问题,针对老化故障,置信区间的设计能够降低数据缺失和错误数据对故障诊断的影响,总体上提高了网络的故障诊断精度。

表2 故障类型判别
Tab.2 Fault type discrimination

故障类型	相对误差值置信区间/%
阶跃故障	(15.6%, 30.4%)
脉冲故障	(103.43%, 207.36%)
开路故障	(209.63%, 412.3%)
零漂故障	(6.23%, 15.4%)
短路故障	(30.53%, 102.3%)

4 结语

运用 GRNN 网络在故障样本较少时,同样具有优越的非线性处理能力和良好的鲁棒性和泛化能力的优势,来进行传感器的故障检测诊断。提出了一种 CAFOA 与 GRNN 结合的新型算法模型,克服 GRNN 网络在学习因子选取上存在的缺陷,从而提高了模型的预测效果。使用现场历史温度数据训练网络,进行数学建模并检验其精度,最后结合统计学中置信区间的方法,去除实际工业环境中不确定因素导致的波动。通过实验数据分析总结,得出了准确可靠的故障检测诊断分类表,可用于实时检测传感器工作状态,减少温度传感器故障带来的损失,具有一定的实际意义。

参考文献:

- [1] JAWORSKI A, WIKIEL H, WIKIEL K. Automated AC Voltammetric Sensor for Early Fault Detection and Diagnosis in Monitoring of Electroplating Processes[J]. *Electroanalysis*, 2013, 25(1): 278—288.
- [2] LAROIYA C, AGGARWAL V B. At Sensor Diagnosis for Smart Healthcare: Probability or Conditional Probability Based Approach vs. k-Nearest Neighbour[J]. *International Journal of Advanced Pervasive and Ubiquitous Computing (IJAPUC)*, 2018: 4—10.
- [3] 徐卓飞. 基于纹理识别的胶印机墨杠故障检测方法[C]//中国印刷科学技术研究所、北京印刷学院. 颜色科学与技术——2012第二届中国印刷与包装学术会议论文摘要集. 中国印刷科学技术研究所、北京印刷学院: 中国印刷与包装研究编辑部, 2012.
XU Zhuo-fei. Detection Method of Ink Stick Failure of Offset Printing Machine Based on Texture Recognition[C]//China Institute of Printing Science and Technology, Beijing Institute of Printing. *Color Science and Technology - 2012 Second China Printing and Pack-*

aging Conference Conference Abstracts. China Institute of Printing Science and Technology, Beijing Institute of Printing: China Printing and Packaging Research Editorial Department, 2012.

- [4] 第十三届全国包装工程学术会议纪要[J]. *包装工程*, 2010, 31(17): 192.
Minutes of the 13th National Packaging Engineering Conference[J]. *Packaging Engineering*, 2010, 31(17): 192.
- [5] 张谦, 舒悦, 王乐, 等. 往复压缩机故障诊断方法研究概述[J]. *流体机械*, 2018, 46(3): 37—41.
ZHANG Qian, SHU Yue, WANG Le, et al. Overview of Research on Fault Diagnosis Method of Reciprocating Compressor[J]. *Fluid Machinery*, 2018, 46(3): 37—41.
- [6] 何大伟, 彭靖波, 胡金海, 等. 基于改进FOA优化的CS-SVM轴承故障诊断研究[J]. *振动与冲击*, 2018, 37(18): 108—114.
HE Da-wei, PENG Jing-bo, HU Jin-hai, et al. Fault Diagnosis of CS-SVM Bearing Based on Improved FOA Optimization[J]. *Journal of Vibration and Shock*, 2018, 37(18): 108—114.
- [7] GUO Ya-bin, LI Guan-nan, CHEN Huan-xin, et al. Optimized Neural Network-based Fault Diagnosis Strategy for VRF System in Heating Mode Using Data Mining[J]. *Applied Thermal Engineering*, 2017: 125—130.
- [8] SHI Shu-biao, LI Guan-nan, Chen Huan-xin, et al. Refrigerant Charge Fault Diagnosis in the VRF System Using Bayesian Artificial Neural Network Combined with Relief Filter[J]. *Applied Thermal Engineering*, 2017: 112—115.
- [9] 李浩平, 欧阳俊, 谢雪媛. 基AGA-GRNN神经网络的刀具寿命预测研究[J]. *三峡大学学报(自然科学版)*, 2018(6): 1—3.
LI Hao-ping, OUYANG Jun, XIE Xue-yuan. Research on Tool Life Prediction Based on AGA-GRNN Neural Network[J]. *Journal of China Three Gorges University (Natural Science Edition)*, 2018(6): 1—3
- [10] 肖洪闯, 葛晓霞, 李扬. 基于广义回归神经网络的凝汽器故障诊断[J]. *电站辅机*, 2018, 39(2): 15—18.
XIAO Hong-chuang, GE Xiao-xia, LI Yang. Condenser Fault Diagnosis Based on Generalized Regression Neural Network[J]. *Power Plant Auxiliary*, 2018, 39(2): 15—18.
- [11] 陈明霞, 张寒, 郑谊峰. 基于RBF神经网络的自动包装机温度控制算法研究[J]. *包装工程*, 2018, 39(19): 160—166.
CHEN Ming-xia, ZHANG Han, ZHENG Yi-feng, et al. Design of Temperature Control System for Automatic Packaging Machine Based on BRF Neural Network[J]. *Packaging Engineering*, 2018, 39(19): 160—166.
- [12] 洪亮, 楚高利, 邓倩, 等. 广义回归神经网络在显示器颜色空间转换中的应用[J]. *包装工程*, 2015,

- 36(15): 145—148.
- HONG Liang, CHU Gao-li, DENG Qian, et al. Application of Generalized Regression Neural Network in Display Color Space Conversion[J]. Packaging Engineering, 2015, 36(15): 145—148.
- [13] 管毅, 罗文兴. 一种基于支持向量机的无线传感器故障检测的研究[J]. 科技通报, 2018, 34(4): 113—117.
- GUAN Yi, LUO Wen-xing. A Study of Wireless Sensor Fault Detection Based on Support Vector Machine[J]. Bulletin of Science and Technology, 2018, 34(4): 113—117.
- [14] 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 Yong-hong, WENG Shi-lie. Application of Generalized Regression Neural Network in Fault Detection of Gas Turbine Exhaust Gas Temperature Sensor[J]. Chinese Journal of Electrical Engineering, 2009, 29(32): 92—97.
- [15] 耿敬, 张洋, 李明伟, 等. 基于混沌加速果蝇算法的航电枢纽施工进度优化[J]. 重庆交通大学学报(自然科学版), 2019, 38(1): 62—68.
- GENG Jing, ZHANG Yang, LI Ming-wei, et al. Optimization of Construction Progress of Avionics Hub Based on Chaotic Accelerated Fruit Fly Algorithm[J]. Journal of Chongqing Jiaotong University (Natural Science Edition), 2019, 38(1): 62—68.
- [16] PAN Wen-chao. A New Fruit Fly Optimization Algorithm: Taking the Financial Distress Mold as an Example[J]. Knowledge-Based Systems, 2012, 26(2): 69—74.
- [17] 石军. 基于 Chebyshev 映射的混沌特性及其性能分析[J]. 电脑硬件: 现代电子技术, 2008, 31(23): 93—96.
- SHI Jun. Chaotic and Its Performance Analysis Based on Chebyshev Mapping[J]. Modern Electronic Technique, 2008, 31(23): 93—96.