

改进的 Kohonen 网络在航空发动机分类故障 诊断中的应用

郑波¹, 马昕²

(中国民用航空飞行学院 教务处¹, 空中交通管理学院²; 四川广汉 618307)

摘要: 针对传统 Kohonen 网络对未知样本识别时的不可辨识性和分类结果不惟一性问题, 利用改进的 Kohonen 网络对航空发动机进行分类故障诊断, 并利用混合粒子群优化算法对网络连接权值进行优化, 以提高 Kohonen 网络在分类故障诊断中的通用性和容错能力。对 GE90 发动机的孔探图像纹理特征识别进行对比。结果表明: 改进的 Kohonen 网络在分类故障诊断中有较强的实用性, 分类准确率高于常用神经网络模型和支持向量机的。

关键词: Kohonen 网络; PSO 算法; 自适应继承; 自适应检测响应; 故障诊断; 航空发动机

中图分类号: V263.6

文献标识码: A

doi: 10.13477/j.cnki.aeroengine.2020.02.004

Application of Improved Kohonen Network in Aeroengine Classification Fault Diagnosis

ZHENG Bo¹, MA Xin²

(Academic Affairs Office¹; Air Traffic Management College², Civil Aviation Flight University of China; Guanghan Sichuan 618307, China)

Abstract: In order to overcome the problems of inidentify and inunique classification results of unknown samples identified by Traditional Kohonen (T-Kohonen) network, the classification fault diagnosis of aeroengine was carried out by using Improved Kohonen (I-Kohonen) network. The Hybrid Particle Swarm Optimization (H-PSO) algorithm was used to optimize the network connection weights to improve the generality and fault tolerance of Kohonen network in classification fault diagnosis. Borescope image texture feature identification of GE90 engine was compared. The results show that the I-Kohonen network is more practical in classification fault diagnosis, and the classification accuracy is higher than that of common neural network models and Support Vector Machines (SVM).

Key words: Kohonen network; PSO algorithm; adaptive inheritance; adaptive detecting response; fault diagnosis; aeroengine

0 引言

航空发动机长期在高温、高压、强振动等恶劣工作环境下, 受到腐蚀、磨损、疲劳、积污等侵害, 不可避免地发生性能衰退、振动加剧、磨损严重等故障征兆^[1]。开展航空发动机故障诊断研究对提高排故效率、缩短维修周期、降低维护成本、保障飞行安全具有重要意义。自 20 世纪 60 年代以来, 航空发动机生产厂商和用户对发动机的故障监测、诊断方法进行了大量研究, 逐渐形成了基于发动机气路性能监控、滑油系

统监控、振动监控和无损检测的发动机故障诊断技术, 使得航空发动机的维修保障水平得到显著提高。美国联合西方国家开发的联合攻击战斗机 (Joint Strike Fighter, JSF) 项目, 通过状态监控与健康管理技术, 使得 JSF 与 F-16 战斗机相比, 在人力费用方面降低约 30%, 设备保障费用方面降低约 50%, 而架次生成率却提高了约 25%^[2]。国内自 80 年代开始逐渐开展航空发动机的故障诊断技术研究, 有效提升了中国航空发动机的维修保障水平。1988 年, 北京飞机维修工程公司等 4 家单位联合开发了发动机监控和诊断 (Engine Monitoring and Diagnosis, EMD) 系统, 实现

收稿日期: 2019-02-24 **基金项目:** 四川省科技计划项目 (2019YJ0720)、中国民用航空局发展基金教育人才类项目 (14002600100018J034)、中国民用航空飞行学院面上项目 (2019-053) 资助

作者简介: 郑波 (1984), 男, 博士, 副教授, 研究方向为智能故障诊断; E-mail: b_zheng1@126.com。

引用格式: 郑波, 马昕. 改进的 Kohonen 网络在航空发动机分类故障诊断中的应用[J]. 航空发动机, 2020, 46(2): 23-29. ZHENG Bo, MA Xin. Application of improved kohonen network in aeroengine classification fault diagnosis [J]. Aeroengine, 2020, 46(2): 23-29.

了航空发动机的趋势预测和故障诊断的功能^[3];国内学者在总结航空燃气涡轮发动机故障诊断中的各类数学模型方法的基础上,出版了航空燃气涡轮发动机故障诊断理论专著《航空发动机故障诊断导论》^[4],提高了中国航空发动机故障诊断的理论水平。

随着传感器技术的快速发展,基于数据驱动的故障诊断技术得到了广泛应用。传统 Kohonen (Traditional Kohonen, T-Kohonen)网络作为基于数据驱动的智能数据处理方法,在样本分类、模式识别中有广泛应用^[5]。范作民、白杰等利用 Kohonen 网络的自组织特效,提取航空发动机的运行特征,进而识别航空发动机的运行状态^[6]。基于 Kohonen 网络的数据聚类特性,Kohonen 网络在航空发动机滑油系统健康状态评估中得到了广泛应用^[7],同时也被广泛地应用于电力^[8]、机械^[9]、网络^[10]等其他工业系统的故障诊断中。T-Kohonen 网络采用无导师竞争学习策略调整权值,使不同的神经元对不同的输入类别敏感,从而特定的神经元在分类诊断中可以充当某一输入类别的判别器。研究表明:针对大样本数据聚类问题,存在聚类结果不惟一性和不可辨识性的问题,限制了 T-Kohonen 网络的应用效果。

本文提出 1 种带监督策略的改进的 Kohonen (Improved Kohonen, I-Kohonen)网络,该网络利用混合粒子群优化 (Hybrid Particle Swarm Optimization, H-PSO) 算法优化网络初始权值,克服 T-Kohonen 网络存在的缺陷,以确保识别结果的惟一性和可辨识性。

1 T-Kohonen 网络

1.1 T-Kohonen 网络学习算法

T-Kohonen 网络的拓扑结构如图 1 所示。输入层神经元为 1 维阵列,神经元数等于输入向量的维数 m ,竞争层神经元按 2 维阵列形式排列,取神经元数为 n ,输入层和输出层神经元之间由可变权值 ω_{ij} 输入层 x_i 竞争层 ω_{ij} 输出层 x_m 连接。

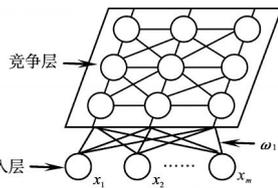


图 1 T-Kohonen 网络拓扑结构

T-Kohonen 网络采用基于 winner-take-all 规则的竞争学习策略^[11],具体学习过程如下:

(1)网络初始化。随机设定 $m \times n$ 维权值 ω_i 的初始值,设定领域范围 $R \in (r_{\min}, r_{\max})$,学习效率 $\eta \in (\eta_{\min},$

$\eta_{\max})$ 以及网络学习次数 g_{\max} 的初始值。

(2)计算并确定获胜神经元。第 t 次学习的输入样本 $\mathbf{x}(t)=(x_1, x_2, \dots, x_m)$ 与竞争层神经元 j 之间的距离为欧式距离。把与输入样本 \mathbf{x} 距离最小的竞争层神经元 $c(t)$ 作为 t 次学习获胜神经元,并令 P 为神经元的位置,其中 $P_c(t)$ 为获胜神经元 c 在第 t 次学习时的位置, P_k 为神经元 k 的位置。

(3)产生优胜领域。以获胜神经元 $c(t)$ 为中心的优胜领域为

$$N_{c(t)}(k)=(k \text{ find}(\text{norm})(P_c(t), P_k)) < R(t) \quad (1)$$

式中: $k=1, 2, \dots, n$;函数 $\text{norm}(\cdot)$ 用于计算 2 神经元间的欧氏距离;函数 $\text{find}(\cdot)$ 用于确定符合要求的神经元;按下式自适应更新 R 和 η

$$\begin{cases} R(t)=r_{\max}-t/g_{\max} \cdot (r_{\max}-r_{\min}) \\ \eta(t)=\eta_{\max}-t/g_{\max} \cdot (\eta_{\max}-\eta_{\min}) \end{cases} \quad (2)$$

(4)更新神经元 $c(t)$ 及其优胜领域 $N_{c(t)}(k)$ 的权值

$$\omega_{ij}(t+1)=\omega_{ij}(t)+\eta(t) \cdot (x_i-\omega_{ij}(t)) \quad (3)$$

(5)若 $t+1 < g_{\max}$,则返回步骤(2),否则结束学习过程。

1.2 T-Kohonen 网络存在的问题

通过研究文献[12]中的大样本数据聚类问题,发现 T-Kohonen 网络存在聚类结果不惟一性和不可辨识性问题。文献[12]中的网络入侵数据见表 1,因入侵数据有 38 维,则输入神经元数为 38,入侵数据来自 5 个类别,竞争层神经元往往要大于实际类别数,这是为了避免竞争所产生的死神经元对聚类的影响^[13],故竞争层采用 6×6 的 2 维阵列。

表 1 网络入侵数据^[12]

项目	类别					样本总量
	1	2	3	4	5	
训练	1399	1862	115	580	44	4000
测试	164	235	15	78	8	500

1.2.1 未知样本识别的不可辨识性

对于一些分属不同类别,但差异性较小的训练数据,可能会出现映射同一神经元的情况,导致未知样本识别时的不可辨识性。对 4000 组训练数据聚类后的获胜神经元分布如图 2 所示。

对于位置为(1,1)的神经元而言,映射该神经元的是 100 个类别为 2 的数据。但注意位置为(3,3)、(4,4)、(6,4)、(6,5)的神经元,2 种类别的数据被映

射到同一神经元。在未知样本被划分到 (3,3)、(6,5) 这 2 个神经元时,其为小数据类别的概率分别只有 8.3%、4.6%,这一概率相对较小,可将未知样本判入大数据类别;在未知样本被划分到(4,4)、(6,4)这 2 个神经元时,其为小数据类别的概率分布是 10.2%、38.4%,这一概率相对较大,则不宜再判入大数据类别。这就造成了对未知样本识别时的不可分辨性。

1.2.2 分类结果的不惟一性

网络连接权值随机设定,导致在划分未知样本类别时,用不同初始权值可能得到不同分类结果,使得分类结果具有随机性,不利于工程应用。如分别利用 T-Kohonen 网络对文献[12]中的数据进行 5 次识别试验,就能得出 5 个不同的准确率数据,这正是由于初始权值随机设定而造成的。

针对 T-Kohonen 网络存在的 2 大问题,本文提出基于监督的 Kohonen (Supervised Kohonen, S-Kohonen)网络,使最终输出结果为确定的类别,同时,利用 H-PSO 算法对初始权值进行优化,并将交叉验证(Cross Validation, CV)产生的分类精度的平均值作为适应度值,既能保证获得分类的准确率最高,又能保证分类的结果惟一。

2 S-Kohonen 网络

2.1 S-Kohonen 网络算法

S-Kohonen 网络拓扑结构如图 3 所示。通过在竞争层后加入输出层,将无导师的学习策略变为有导师监督的网络,输出层神经元数与数据类别数相同,设为 l ,当表征某一类别时,令该类对应的神经元为 1,其余神经元全为 0。输出层和竞争层通过 $n \cdot l$ 维权值矩阵 ω_2 连接。

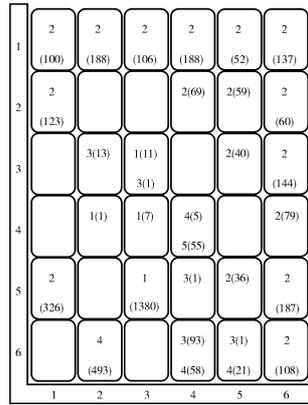


图 2 获胜神经元分布

元与输出层之间的权值

$$\omega_{2j}(t+1) = \omega_{2j}(t) + \eta_1(t) \cdot (Y_L - \omega_{2j}(t)) \quad (4)$$

式中: $j=1, 2, \dots, n; s=1, 2, \dots, l; \eta_1(t)$ 为学习效率; Y_L 为训练样本所属类别标签向量。

从输入层到竞争层,为使同类神经元逐渐集中,学习效率 η 随学习次数逐渐减小,但从竞争层到输出层,为使代表数据类别的输出层神经元获得较大的权重值,从而清晰地表征未知样本类别,学习效率 η_1 随学习次数逐渐增大,其自适应更新为

$$\eta_1(t) = \eta_{1min} + t/g_{max} \cdot (\eta_{1max} - \eta_{1min}) \quad (5)$$

对测试样本 t_{test} 的识别通过如下 2 步实现:

(1) 令 P_{ik} 为与 t_{test} 欧氏距离最短的第 k 个神经元在分布图中的位置,则 P_{ik} 为

$$P_{ik} = (k \text{ lmin}(\text{norm}(t_{test}, \omega_{1ik}))) \quad (6)$$

T-Kohonen 网络正是通过位置为 P_{ik} 的神经元所代表的训练数据类别来表征 t_{test} 的所属类别。

(2) t_{test} 的类别标签为

$$(t_{test})_{label} = (l_0 \text{ lmax}(\omega_2(P_{ik}, l_0))) \quad (7)$$

式(7)表明权值矩阵 ω_2 的 P_{ik} 行最大值元素所对应的列位置 l_0 就是测试样本 t_{test} 惟一的类别标签输出。因用 $Y_L - \omega_{2js}(t)$ 来更新 $\omega_{2js}(t+1)$,则 ω_2 的初始值应设为 $n \cdot l$ 维 0 值矩阵,使得在同一标准下权值逐渐累加,实现判别 t_{test} 类别的效果。

S-Kohonen 网络由于网络连接权值 ω_1 和 ω_2 都是随机设定的,利用文献[12]中的 4000 组训练数据训练网络,并分别利用 4000 组训练数据和 500 组测试数据检验网络的分类能力,共进行 5 次试验,结果见表 2。虽然 S-Kohonen 网络很好地解决了对未知样本识别时的不可分辨性,但表 2 也直观地反映了其分类结果不惟一性的问题依然存在。

表 2 分类准确率结果比较

序号	数据准确率 /%			
	S-Kohonen 网络		I-Kohonen 网络	
	训练	测试	训练	测试
1	97.6	97.8	98.5	99
2	98.35	98.8	98.5	99
3	97.45	97.4	98.5	99
4	97.88	98.4	98.5	99
5	96.75	96.6	98.5	99

注:存在分类结果不惟一性。

2.2 H-PSO 算法

普通 PSO (General Particle Swarm Optimization ,

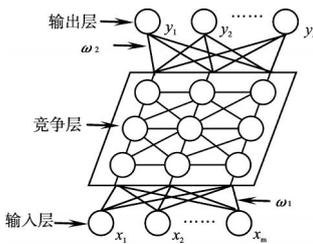


图 3 S-Kohonen 网络拓扑结构

权值调整时,在调整输入层和竞争层优胜领域内神经元权值的同时,还要调整竞争层优胜领域内神经

G-PSO)算法见文献[14],本文提出 H-PSO 算法采用基于最优个体策略的粒子自适应继承方式(Adaptive Inheritance Mode Based on the Best Individuals Strategy, AIM)策略来拓展整个解空间,同时引入自适应检测响应机制(Adaptive Detecting Response Mechanism, ADRM)引导粒子群跳出局部最优空间,确保获得全局最优解。

2.2.1 AIM 策略

每个粒子代表 1 个潜在解,因对连接权值寻优,则单个粒子可表示为 $p_i=(p_1, \dots, p_{m \cdot n})$,设群体极值为 p_g ,通过随机设定继承系数 s_1, s_2 ,其中 $1 \leq s_1 < s_2 \leq m \cdot n$,将群体极值 $p_g=(p_{g1}, \dots, p_{gm \cdot n})$ 的 $s_1 \sim s_2$ 位间的值复制到粒子 p_i 的 $s_1 \sim s_2$ 位间,通过继承产生 1 个保留群体极值信息的新粒子 p_{new} 。

对 p_{new} 是否具有进化下去的价值,则采用优秀个体策略判断,判断方式为:若 $\text{fitness}(p_i) < \text{fitness}(p_{new})$,则继承有效,用 p_{new} 替换 p_i ,否则继承无效,放弃 p_{new} ,其中 $\text{fitness}(\cdot)$ 为适应度函数,用于表征 PSO 算法的寻优效果。

2.2.2 ADRM 策略

ADRM 策略的原理为:每间隔 α 代进化作 1 次适应度值检测,若当前进化到第 $\alpha+i$ 代,则检测适应度值 $\text{fitness}_{\text{curr}}(p_g) < \text{fitness}(p_g)$ 的变化是否超过规定阈值 e 。若超过,表明粒子群还在继续搜索最优解;若没超过,则可能陷入局部最优解,算法保存当前最优解,并触发响应:随机更新粒子群中一定比例粒子(本文选取 50% 的粒子更新)的 $s_3 \sim s_4$ 位间的值, s_3 和 s_4 也是随机设定的,其中 $1 \leq s_3 < s_4 \leq m \cdot n$,使部分粒子自动跳出该搜索区域,转入其他区域继续搜索。以后每隔 α 代继续检查,根据检查结果作出是否响应的判断,直到满足终止条件。

2.2.3 适应度函数的确定

文献[15]将 k -CV (k -Cross Validation) 的交叉验证精度作为适应度函数值,其具体算法为:将原始数据随机分成 k 组,将每组数据分别作 1 次测试数据,相应的 $(k-1)$ 组数据作为训练数据,则可得 k 个分类准确率,将 k 个分类准确率的平均值作为适应度值。本文同样采用基于 k -CV 算法的适应度函数来计算粒子 P_i 的适应度值,以保障样本训练时的分类准确率。

利用 I-Kohonen 网络对文献[12]中的数据进行处理(表 2),通过对比可得:

(1) I-Kohonen 网络不仅避免了对未知样本识别时的不可辨识性,还增强了 Kohonen 网络在实际应用中的通用性和容错能力。

(2) AIM 策略能保证群体极值信息被保留,并拓展了粒子搜索能力,确保对整个解空间的搜索。

(3) ADRM 策略确保在长期进化过程中引导粒子主动跳出局部最优空间,避免了因连接权值随机设定而导致的分类结果不惟一性问题,同时只随机更改部分粒子 $s_3 \sim s_4$ 位间的值,保证了对粒子群“社会信息”的良好继承,使得转入其他区域搜索时,避免重复搜索,加快了收敛速度。

3 航空发动机损伤数据分类

利用孔探图像可识别航空发动机内部因过热、振动、磨损、侵蚀、撞击等形成的裂纹、撕裂、腐蚀、卷边、烧伤、凹槽等各类损伤,这些损伤往往发生在发动机特定部件上,直接威胁发动机运行安全。利用基于内容的图像检索(Content-Based Image Retrieval, CBIR) 技术从颜色、纹理、形状等提取图像特征,建立图像数据知识库,有利于对未知图像特征进行识别^[16]。

文献[17]利用孔探 GE90 发动机获得关于叶尖卷边、腐蚀、裂纹和撕裂 4 类损伤的图像,如图 4 所示。提取 4 张图像的 10 个纹理特征分别建立 4 类损伤图像数据库,共 112 组数据(见表 3),其中特征 f_1 为角 2 阶矩均值, f_2 为角 2 阶矩方差, f_3 为对比度均值, f_4 为

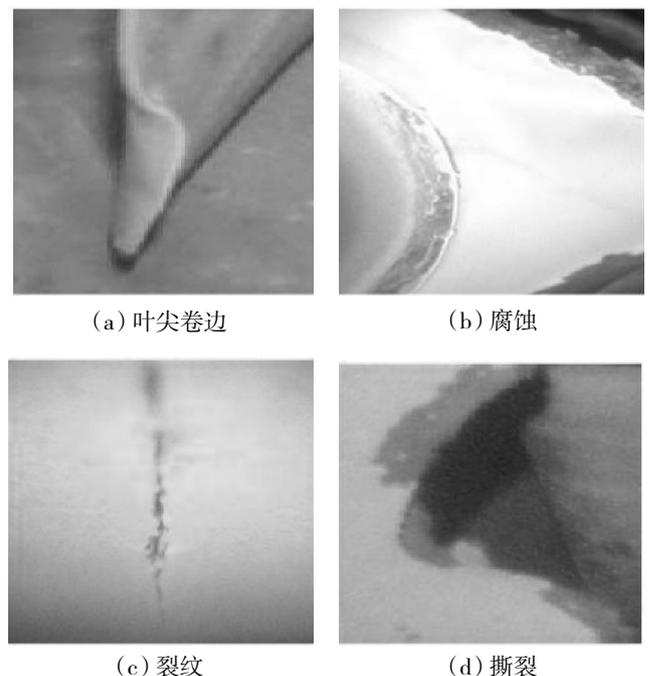


图 4 GE90 发动机 4 种损伤

表 3 GE90 发动机孔探图像特征数据

序号	f_1	f_2	f_3	f_4	f_5	f_6	f_7	f_8	f_9	f_{10}	类别标签
1	0.1337	0.0064	0.1461	0.0482	0.9841	0.0052	1.0928	0.0394	0.9484	0.0149	1
2	0.1478	0.0073	0.1429	0.0478	0.9819	0.0060	1.0608	0.0410	0.9453	0.0160	1
						⋮					
111	0.1043	0.0022	0.0624	0.0176	0.9880	0.0005	1.1708	0.0240	0.9694	0.0084	4
112	0.0979	0.0022	0.0617	0.0175	0.9975	0.0006	1.1590	0.0236	0.9708	0.0080	4

对比度方差, f_5 为相关性均值, f_6 为相关性方差, f_7 为方差均值, f_8 为方差方差, f_9 为逆差矩均值, f_{10} 为逆差矩方差, D 为损伤类型, 1 为叶尖卷边, 2 为裂纹, 3 为撕裂, 4 为腐蚀。

为便于与文献[17]进行比较, 将第 1~42 号数据作为训练数据, 第 43~84 号数据作为测试数据 1, 第 85~112 号数据作为测试数据 2, 分别验证网络的分类能力。

设 I-Kohonen 网络的最大学习次数 g_{max} 为 1000, 优胜领域范围 $R \in (0.4, 1.5)$, 学习效率 $\eta \in (0.01, 0.1)$, $\eta_1 \in (0.1, 1)$, 输入层神经元数 $m=10$, 因类别数为 4, 采用 6×6 的竞争层分布, 竞争层神经元数 $n=36$, 输出层神经元数 $l=4$ 。

3.1 验证 H-PSO 算法寻优效果

H-PSO 算法采用非线性惯性权重

$$\omega = \frac{\omega_s - \omega_e}{2} \cdot \sin\left(\frac{\pi}{T_{max} - 1} \cdot (t - 1) + \frac{\pi}{2}\right) + \frac{\omega_s + \omega_e}{2} \quad (8)$$

式中: ω_s 为初始值; ω_e 为最终值; T_{max} 为最大进化代数; t 为当前进化代数。

设粒子种群数量为 50, $T_{max}=200$, $k-CV$ 为 10, 响应阈值 $e=10^{-3}$, $\omega_s=0.9$, $\omega_e=0.4$, 加速因子 $c_1=1.2$, $c_2=1.7$ 。为验证 H-PSO 算法较 G-PSO 算法在寻优方面的优势, 分别对 I-Kohonen 网络寻优 5 次, 得到 5 组共 10 个 10×36 维的最优连接权值 ω_1 , 具体数值见表 4。

第 1 组 2 种寻优算法的最佳适应度值和平均适应度值比较如图 5 所示。从图中可见, H-PSO 算法的最佳适应度值在进化到 127 代时再次发生改变, 达到最大值 82.91%, 而 G-PSO 算法在第 33 代时达到 81.57%, 最终适应度值再无变化。验证了 H-PSO 算法具备尽可能地搜索整个解空间, 且可自适应跳出局部最优空间的特性。

利用 H-PSO 和 G-PSO 优化的分类结果比较见表 4。从表中 5 组最优连接权值训练 I-Kohonen 网络

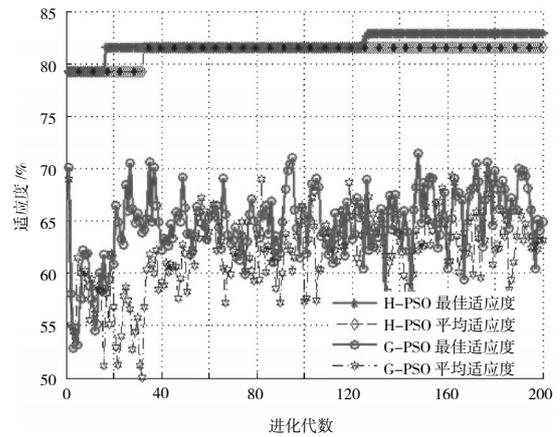


图 5 适应度值变化的比较

后所得分类准确率比较可见, H-PSO 算法能够获得全局最优解, 使 I-Kohonen 网络分类准确率最高, 且确保分类结果具有唯一性。

3.2 验证 I-Kohonen 网络性能

为验证 I-Kohonen 网络的性能, 分别从分类准确率和时间开销 2 方面对网络性能进行评价, 并与 T-Kohonen 网络、LVQ 网络^[18]、BP 网络^[19]、SVM^[20]进行比较, 同样为了验证分类结果的唯一性, 任意选择每个网络的 3 组试验数据, 分类结果比较见表 5。其中在试验基础上, 确定 LVQ 网络采用 10×36 的网络结构。BP 网络采用 $10 \times 36 \times 4$ 的网络结构, 训练目标为 0.001, 网络权值随机确定。且各网络迭代次数均为 1000 次。SVM 采用高斯核函数, 并利用遗传算法对惩罚因子和核函数参数进行优化。

从表中可见, 因有 H-PSO 对连接权值寻优, I-Kohonen 网络分类准确率最高, 同时时间开销也要高于 T-Kohonen、BP、SVM 的。而 T-Kohonen 依然存在不可辨识性。LVQ 网络同样作为有导师监督的竞争型网络, 时间开销最大, 这与其学习过程中权值更新方式有关, 同时也反映出 I-Kohonen 网络结构在学

表 4 利用 H-PSO 和 G-PSO 优化的分类结果比较

		试验 1	试验 2	试验 3	试验 4	试验 5
H-PSO 优化的准确率	最优权值 (10 × 36)	$\begin{bmatrix} 0.4409 & \cdots & 0.0262 \\ \vdots & \ddots & \vdots \\ 0.7139 & \cdots & 0.4226 \end{bmatrix}$			$\begin{bmatrix} 0.3926 & \cdots & 0.0728 \\ \vdots & \ddots & \vdots \\ 0.7779 & \cdots & 0.3223 \end{bmatrix}$
	适应度值 /%	82.91	82.12	82.91	82.91	82.91
	训练样本	100	100	100	100	100
	识别准确率 /%					
	测试样本 1 准确率 /%	95.24	95.24	95.24	95.24	95.24
	测试样本 2 准确率 /%	85.71	85.71	85.71	85.71	85.71
G-PSO 优化的准确率	最优权值 (10 × 36)	$\begin{bmatrix} 0.7278 & \cdots & 0.6175 \\ \vdots & \ddots & \vdots \\ 0.1367 & \cdots & 0.8608 \end{bmatrix}$			$\begin{bmatrix} 0.8608 & \cdots & 0.7105 \\ \vdots & \ddots & \vdots \\ 0.4522 & \cdots & 0.4025 \end{bmatrix}$
	适应度值 /%	81.75	81.75	80.34	82.61	81.75
	训练样本	100	100	97.62	100	100
	识别准确率 /%					
	测试样本 1 准确率 /%	92.86	90.48	90.48	95.24	92.86
	测试样本 2 准确率 /%	82.14	82.14	78.57	85.71	82.14

表 5 基于不同算法的分类结果比较

试验序号		T-kohonen	LVQ	BP	SVM	I-Kohonen
1	训练样本	92.86	100	85.71	100	100
	识别准确率 /% 测试样本 1	90.48	92.86	83.33	71.43	97.24
	识别准确率 /% 测试样本 2	78.57	78.57	71.43	85.71	85.71
	时间开销 /s	29	189	11	57	72
2	训练样本	90.48	100	85.71	100	100
	识别准确率 /% 测试样本 1	88.10	88.10	80.95	71.43	97.24
	识别准确率 /% 测试样本 2	78.57	78.57	67.86	85.71	85.71
	时间开销 /s	30	190	11	53	74
3	训练样本	90.48	100	78.57	100	100
	识别准确率 /% 测试样本 1	83.33	92.86	78.57	71.43	97.24
	识别准确率 /% 测试样本 2	75.00	78.57	67.86	82.14	85.71
	时间开销 /s	28	193	12	56	71

习过程中的简洁高效。BP 网络采用梯度下降的误差反传算法更新权值,收敛速度快,由于对数据进行非线性映射,对相关性的样本识别率较差^[2],导致其分类准确性最差。SVM 对测试样本 1 的分类准确率较差,这与遗传算法对其参数寻优的效果有关系。除了 I-Kohonen 网络,其他算法都存在分类结果不惟一

性的问题。

4 结论

(1)本文在结构上对 T-Kohonen 网络进行改进,通过在竞争层后加入输出层,将无导师的学习策略变为有导师监督的网络,有效避免了不可辨识性问题,

同时网络结构简洁,学习过程较快,增强了 Kohonen 网络在分类故障诊断中的通用性和容错能力。

(2)本文提出基于 AIM 和 ADRM 策略的 H-PSO 算法,拓展了粒子搜索整个解空间的能力,同时能自适应地引导粒子跳出局部最优空间,确保获得全局最优解。

(3)利用 H-PSO 算法优化 Kohonen 网络的连接权值,有效避免了 T-Kohonen 网络因连接权值初始值随机设定而导致的分类结果不惟一性的问题,并确保获得最高分类准确率,使得 I-Kohonen 网络能够满足工程需求。

参考文献:

- [1] Li C Z, Lei Y. Aircraft engine gas path fault diagnosis based on neural network[J]. Applied Mechanics and Materials, 2012, 148: 144-148.
- [2] Hess A, Fila L. The joint strike fighter (JSF)PHM concept: potential impact on aging aircraft problem [C]//Proceedings of IEEE Aerospace Conference Piscataway: IEEE Press, 2002: 3021-3026.
- [3] Jaw L C. Recent advancements in aircraft Engine Health Management (EHM) technologies and recommendations for the next step[R]. ASME 2005-GT-68625.
- [4] 范作民, 孙春林, 白杰. 航空发动机故障诊断导论[M]. 北京: 科学出版社, 2004: 1-13.
FAN Zuomin, SUN Chunlin, BAI Jie. Introduction to aeroengine fault diagnosis[M]. Beijing: Science Press, 2004: 1-13. (in Chinese)
- [5] Wang L, Fu K. Artificial neural networks [M]. Hoboken: Wiley Online Library, 2009: 78-121.
- [6] 范作民, 白杰, 阎国华. Kohonen 网络在发动机故障诊断中的应用[J]. 航空动力学报, 2000, 15(1): 90-93.
FAN Zuomin, BAI Jie, YAN Guohua. Application of Kohonen network to aeroengine fault diagnosis [J]. Journal of Aerospace Power, 2000, 15(1): 90-93. (in Chinese)
- [7] 曹惠玲, 黄乐腾, 李志伟, 等. 基于 SOM 神经网络的航空发动机滑油系统健康评估[J]. 中国民航大学学报, 2014, 32(6): 19-22.
CAO Huiling, HUANG Leteng, LI Zhiwei, et al. Health assessment study of aeroengine oil system based on SOM neural network[J]. Journal of Civil Aviation University of China, 2014, 32(6): 19-22. (in Chinese)
- [8] 徐艳, 马宏忠, 刘勇业, 等. 基于 Kohonen 网络的高压断路器机械故障识别方法[J]. 智慧电力, 2018, 46(3): 101-106.
XU Yan, MA Hongzhong, LIU Yongye, et al. Detecting method for mechanical fault in high voltage circuit breaker based on Kohonen network[J]. Smart Power, 2018, 46(3): 101-106. (in Chinese)
- [9] 谢长贵, 谢志江. 模糊 Kohonen 神经网络的旋转机械故障诊断[J]. 现代科学仪器, 2012, (5): 98-101.
XIE Changgui, XIE Zhijiang. Fuzzy fault diagnosis for rotating machinery based on Kohonen neural network [J]. Modern Scientific Instruments, 2012, (5): 98-101. (in Chinese)
- [10] 卢鹏, 唐超. 基于 S-Kohonen 的 DoS 攻击检测算法研究[J]. 计算机测量与控制, 2018, 26(10): 171-175.
LU Peng, TANG Chao. Research on DoS attack detection algorithm based on S-Kohonen[J]. Computer Measurement & Control, 2018, 26(10): 171-175. (in Chinese)
- [11] Tayfur G. Soft computing in water resources engineering: artificial neural networks, fuzzy logic and genetic algorithms[M]. Southampton, England: WIT Press, 2011: 51-73.
- [12] 李钢. 基于神经网络的入侵检测研究与实现[D]. 上海: 华东师范大学, 2008.
LI Gang. Research and implementation of intrusion detection based on neural network[D]. Shanghai: East China Normal University, 2008. (in Chinese)
- [13] Huang W L, Chen D H, Yang J H. Weighting variables in Kohonen competitive learning algorithms[J]. Journal of Applied Statistics, 2017, 44(2): 212-232.
- [14] Li A G, Qin Z, Bao F M. Particle swarm optimization algorithms[J]. Computer Engineering and Applications, 2017, 186(3): 454-458.
- [15] 郑波, 高峰. 基于 S-PSO 分类算法的故障诊断方法[J]. 航空学报, 2015, 36(11): 3640-3651.
ZHENG Bo, GAO Feng. Fault diagnosis method based on S-PSO classification algorithm [J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(11), 3640-3651. (in Chinese)
- [16] Henning M, Wolfgang M, Squire D M, et al. Performance evaluation in context-based image retrieval: overview and proposals [J]. Pattern Recognition Letters, 2001, 22 : 593-601.
- [17] 汤洋. 基于 Internet 的民航发动机内部损伤评估与维修决策研究[D]. 南京: 南京航空航天大学, 2007.
TANG Yang. Research on aero-engine interior damage evaluation and maintenance decisions based on internet [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2007. (in Chinese)
- [18] Biswal B, Biswal M, Hasan S, et al. Nonstationary power signal time series data classification using LVQ classifier [J]. Applied Soft Computing, 2014, 18(1): 158-166.
- [19] Ali J B, Fnaiech N, Saidi L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals [J]. Applied Acoustics, 2015, 89(3): 16-27.
- [20] 郑波. 基于 PSO-SVM 的民航发动机送修等级决策研究[J]. 推进技术, 2013, 34(5): 687-692.
ZHENG Bo. Investigation on aeroengine maintenance level decision on PSO-SVM [J]. Journal of Propulsion Technology, 2013, 34(5): 687-692. (in Chinese)
- [21] Liu Z, Meng X. Integration of improved BPNN algorithm and multistage dynamic fuzzy judgement and its application on ESMF evaluation[J]. Journal of Computers, 2009, 4(1): 69-76.

(编辑: 刘 静)