

文章编号:1000-8055(2017)12-3031-08

doi:10.13224/j.cnki.jasp.2017.12.028

基于 IPSO-Elman 神经网络的 航空发动机故障诊断

皮 骏¹, 黄江博²

(1. 中国民航大学 中欧航空工程师学院, 天津 300300;

2. 中国民航大学 航空工程学院, 天津 300300)

摘 要: 为提高航空发动机故障诊断的精度, 提出改进粒子群优化的 Elman 神经网络对航空发动机故障诊断的方法。利用 MIV(平均影响值)对神经网络的输入端自变量进行筛选, 降低输入维度; 采用改进粒子群优化算法对 Elman 神经网络的权值和阈值进行优化, 并对优化的神经网络进行训练; 用训练好的神经网络对航空发动机故障进行诊断并与常规的 BP(back propagation)、Elman 神经网络、GM(1, n)、SVM (support vector machines) 进行对比。仿真结果表明: IPSO-Elman(improved particle swarm optimization Elman neural network)神经网络的诊断误差在不同数量训练样本时都小于其他方法, 并且在参选故障诊断的性能参数不同时, 其诊断误差相近, 展现出较强的适应能力。

关 键 词: 航空发动机; Elman 神经网络; 平均影响值; 改进粒子群优化算法; 故障诊断

中图分类号: V231

文献标志码: A

Aero-engine fault diagnosis based on IPSO-Elman neural network

PI Jun¹, HUANG Jiangbo²

(1. Sino-European Institute of Aviation Engineering,
Civil Aviation University of China, Tianjin 300300, China;

2. College of Aeronautical Engineering,
Civil Aviation University of China, Tianjin 300300, China)

Abstract: An Elman neural network optimized by improved particle swarm optimization algorithm was proposed to improve the accuracy of aero-engine fault diagnosis. The input variables of the neural network were selected by MIV (mean impact value) to reduce the dimension. The improved particle swarm optimization algorithm was used to optimize the weights and thresholds of the Elman neural network, and the optimized neural network was trained. The trained neural network was used to diagnose the aero-engine fault and compared with the conventional BP (back propagation), Elman neural networks, GM(1, n), SVM (support vector machines). The simulation results show that the diagnostic error of IPSO-Elman (improved particle swarm optimization Elman neural network) is smaller than other methods, and it has a good diagnosis ability and strong adaptability when the selection fault diagnosis performance parameters have changed.

收稿日期: 2017-03-03

基金项目: 中央高校基本科研业务费中国民航大学专项资金(3122013H001)

作者简介: 皮骏(1976—), 男, 副教授, 博士, 主要从事航空发动机振动故障分析方面研究。

通讯作者: 黄江博(1991—), 男, 硕士生, 主要从事航空发动机故障预测研究。E-mail: 1634401546@qq.com

引用格式: 皮骏, 黄江博. 基于 IPSO-Elman 神经网络的航空发动机故障诊断[J]. 航空动力学报, 2017, 32(12): 3031-3038. PI Jun, HUANG Jiangbo. Aero-engine fault diagnosis based on IPSO-Elman neural network[J]. Journal of Aerospace Power, 2017, 32(12): 3031-3038.

Key words: aero-engine; Elman neural network; mean impact value; improved particle swarm optimization algorithm; fault diagnosis

对航空发动机的故障诊断,主要是对故障模式准确与快速地辨识。航空发动机的故障严重影响飞机的安全飞行^[1-3],因此对其准确而快速的辨识确保了飞机的安全运行以及有利于航空公司维修方案制定。目前常用的航空发动机故障诊断方法^[4-6]包括专家系统^[7]、模糊推理^[8]、模式识别^[9]、智能计算、神经网络^[10]等。

近几年来,智能计算方法,特别是神经网络算法在图像处理、控制等领域得到迅速发展,文献[11-13]成功地将 BP 神经网络引入故障诊断中,但是 BP 神经网络属于静态网络,这种静态网络把原有的航空发动状态监控时间上的动态网络变为空间上的静态模型,故存在很多问题。Elman 神经网络作为一种动态递归网络,是一种极具潜力的预测方法。与 BP 神经网络相比,具有训练速度快,结构简单,预测精度高等特点,然而依然存在陷入局部极小值的问题,在处理小样本、高维度等问题时,其收敛速度也会变慢,网络性能变差。另外,如果初始权值和阈值选取不合适,则收敛难度加大,无法获得理想的预测效果。

粒子群优化算法 (particle swarm optimization, PSO) 是一种智能优化算法。其具有收敛速度快、寻优精度高的特点,在多种领域有所应用。然而 PSO 也存在极易陷入局部极小值的问题,从而导致经过 PSO 优化后的 Elman 神经网络在解决小样本问题时,还不如普通的 Elman 神经网络。

为了解决 PSO 极易陷入极小值的问题,本文对 PSO 进行改进,首先由于惯性权值 ω 直接影响 PSO 的收敛与收敛能力,因此对其进行改进,同时引入变异操作,以此建立改进粒子群优化 Elman 神经网络 (improved PSO-Elman neural network, IPSO-Elman),运用粒子个体代表 Elman 神经网络的权值和阈值,以网络预测与期望值的差值作为粒子的目标,经过 IPSO 的寻优,得到最优权值和阈值,以此构建 Elman 神经网络,最后,把优化后的 Elman 神经网络应用于航空发动机故障诊断,用以减小航空发动机的故障诊断误差。

1 Elman 神经网络及 MIV 原理

1.1 Elman 神经网络

Elman 神经网络是一个具有局部反馈连接和局部记忆的前向神经网络,它的主要结构是前馈

连接^[14],如图 1 所示,其由输入层、隐含层、承接层和输出层组成。输入层主要作用为把信号传入神经网络。隐含层主要由普通隐含层和关联层组成。其次是特殊的承接层,又被称为上下单元层或状态层,隐含层把反馈信号传给承接层,承接层用此反馈信号来记忆上一时刻隐含层的输出值,因此,承接层的神经元输出输入到隐含层经历延迟与存储。这种对历史数据的敏感性,使 Elman 神经网络对动态信息以及复杂信息得处理能力得到提升。




图 1 Elman 神经网络原理图

Fig. 1 Elman neural network schematic

在 Elman 神经网络模型中, $u(k)$ 神经网络的外端输入, $x(k)$ 为网络隐含层输出, $x_c(k)$ 结构单元输出, $y(k)$ 为网络的输出, W_1 、 W_2 、 W_3 分别为承接层到隐含层、输入层到隐含层、隐含层到输出层的权值。 α 为固定收益, Elman 神经网络的模型如下:

$$x_c(k) = \alpha x_c(k - 1) - x(k - 1) \tag{1}$$

$$x(k) = g[W_2 x_c(k) + W_2 u(k)] \tag{2}$$

$$y(k) = f[x(k) \cdot W_3] \tag{3}$$

式中 $f(\ast)$ 为输出神经元的激励函数, $g(\ast)$ 为中间层神经元传递函数, 常采用 S 函数, Elman 神经网络判断算法是否结束的误差函数为

$$E(k) = \sum_{k=1}^m [y(k) - y_c(k)]^2 \tag{4}$$

式中 $y_c(k)$ 为期望输出。

1.2 MIV

MIV(记为 M_{iv}) 是评价各个自变量对因变量影响的重要程度指标,同时也是神经网络输入神经元对输出神经元影响大小的指标,其正负代表其方向,绝对值的大小为自变量对因变量的影响

程度大小。

在神经网络中,当网络训练停止后,仿真输入神经元的数据 $\mathbf{x}_{in} = [x_1, x_2, x_3, \dots, x_n]^T$, 仿真输出神经元的数据 $\mathbf{y}_{out} = [y_1, y_2, y_3, \dots, y_m]^T$ 。

输入神经元变量分别增加 10% 或减少 10% (本文统一按增加 10% 计算), 其次分别应用训练好的网络进行仿真, 得仿真结果 $\mathbf{Y} = [Y_1, Y_2, Y_3, \dots, Y_m]$, 则 M_{iv} 值为

$$M_{iv} = |\mathbf{Y} - \mathbf{y}_{out}| \quad (5)$$

按照上述步骤, 分别计算出各个输入因素对应的 M_{iv} 值, 在对 M_{iv} 值的大小进行排序, 得到各个输入因素对神经网络仿真结果影响的重要程度位次表, 从大到小对网络输入端进行合理的选择, 即实现了变量筛选^[15]。

2 IPSO-Elman 算法

2.1 基本粒子群算法

PSO 是由美国的 Kenney 和 Eberhart 提出的一种源于对鸟群捕食行为研究的进化计算方法^[16], 采用速度-位置搜索模型, 将每个微粒比做一个没有质量和体积但具有速度和位置的点, 粒子在搜索空间以一定的速度飞行, 飞行速度根据飞行经验进行动态调整。

假设在 N 维搜索空间中, 粒子以一定速度飞行, $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{iN})$ 认为是第 i 个粒子的位置, $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{iN})$ 为第 i 个粒子当前的飞行速度, $\mathbf{p}_{besti} = (p_{besti1}, p_{besti2}, \dots, p_{bestiN})$ 是第 i 个粒子所经历过最优位置, 可认为个体最优位置。

设 $f_{ob}(x)$ 为最小化的目标函数, 则第 i 个粒子目前的最优位置由下式确定:

$$\mathbf{P}_{besti} =$$

$$\begin{cases} \mathbf{P}_{besti}(t), & \text{if } f_{ob}[\mathbf{X}_i(t+1)] \geq f_{ob}[\mathbf{p}_{besti}(t)] \\ \mathbf{X}_i(t+1), & \text{if } f_{ob}[\mathbf{X}_i(t+1)] < f_{ob}[\mathbf{p}_{besti}(t)] \end{cases} \quad (6)$$

设群体中粒子数为 M 个, 迭代次数为 t , 群体中所有粒子经历过的最好位置 $\mathbf{g}_{best}(t)$ 为全局最优位置, 那么则有

$$\mathbf{G}_{best}(t) = \min\{f[\mathbf{p}_{best1}(t)], f[\mathbf{p}_{best2}(t)], \dots, f[\mathbf{p}_{bestM}(t)]\} \quad (7)$$

粒子的位置和飞行速度可以根据每个粒子的经验和整个群体的飞行经验自行学习、调整, 速度和位置的更新方程为

$$\begin{aligned} V_{ij}(t+1) &= v_{ij}(t) + c_1 r_1 [p_{best1}(t) - x_{ij}(t)] + \\ &c_2 r_2 [g_{bestj}(t) - x_{ij}(t)] \end{aligned} \quad (8)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (9)$$

式中 $i=1, 2, \dots, M, j=1, 2, \dots, N$ 。 i 代表第 i 个粒子; j 代表粒子的维数; $v_{ij}(t)$ 代表第 i 个粒子进化到 t 代时的第 j 维位置分量; $p_{bestij}(t)$ 表示粒子 i 在进化到 t 代时的第 j 维个体最优位置 $\mathbf{p}_{besti}$ 分量; $g_{bestj}(t)$ 表示进化到 t 代时整个粒子群的最优位置 $\mathbf{g}_{best}$ 的第 j 维分量; c_1, c_2 为加速因子或称为学习因子; r_1, r_2 为 $[0, 1]$ 的随机数。程序运行到设置的精度或迭代次数后停止运算。

基本 PSO 使用简单, 有着较快的寻优速度, 但同时也存在如下问题:

1) 局部极值问题。在迭代过程中, 每一个例子都以当前最优值为目标, 向此运动, 搜索空间随着不断缩小, 这样形成了粒子种群的快速趋同效应^[13], 但是此时的最优位置可能只是某一局部搜索空间里的最优位置, 搜索陷入了局部极值之中, 导致了早熟收敛, 失去了粒子之间所需要保持的多样性。

2) 收敛精度问题。粒子在搜索移动时, 受惯性行为的影响, 当惯性因子较大时, 粒子的收敛速度会很快, 但当粒子靠近最优解时又会受到高惯性权重的影响而不能精细地搜索, 使得收敛精度不高。尤其当训练样本较少时, 基本 PSO 的这个问题更严重, 因此, 需要对基本 PSO 进行改进, 使得在小样本训练中取得较好的结果。

2.2 动态参数调节

PSO 在迭代更新过程中, 由于粒子对本身与全局环境的认知分配不均, 因此在粒子迭代更新过程中, 要对粒子的自身认知能力与全局环境的认知进行动态分配, 在此基础上, 对 PSO 做如下改进。

提出如下式的动态权值及参数的方法, 即

$$\begin{cases} w = w_{\max} - (w_{\max} - w_{\min}) \tan\left(\frac{t}{t_{\max}} \cdot \frac{\pi}{4}\right) \\ c_1 = c_{1\min} + (c_{1\max} - c_{1\min}) \frac{t}{t_{\max}} \\ c_2 = c_{2\min} + (c_{2\max} - c_{2\min}) \frac{t}{t_{\max}} \end{cases} \quad (10)$$

式中 w 为惯性权值, $w_{\max}$ 为权值最大值, $w_{\min}$ 为权值最小值, c_1, c_2 为速度调节参数, $c_{1\min}$ 与 $c_{1\max}$ 分别为 c_1 的最小值与最大值, $c_{2\min}$ 与 $c_{2\max}$ 分别为 c_2 的最小值与最大值。

在迭代次数较少时, w 与 $w_{\max}$ 大小相近, 确保了算法的全局收索能力; 随着迭代次数增大, 权

值以非线性递减,确保了局部的搜索能力,另外对速度参数的合理控制,使得局部搜索与全局搜索能力的动态平衡更易建立。

2.3 变异判断准则

针对粒子趋同效应的问题,为了使粒子能够跳出以前而搜索到最优位置,并且在迭代过程中不断地拓展连续缩小的搜索空间,同时保证了粒子在更大的搜索空间中具有种群多样性。应用概率统计中的方差思想对粒子过早收敛进行判定,由于粒子迭代次数到达后期后,其适应度值都趋于全局最优值,因此对粒子适应度方差进行计算,判定粒子是否达到过早收敛。

$$s^2 = \frac{1}{M} \sum_{i=1}^M (f_{a,i} - f_{a,ave})^2 \tag{11}$$

式中 $f_{a,i}$ 为粒子 i 的适应度值, $f_{a,ave}$ 为粒子的平均适应度值, M 为种群规模, s^2 设定为 0.01。当适应度方差小于 0.01 时,则应用遗传算法的变异思想,对粒子的位置与速度进行初始化操作。

2.4 IPSO-Elman 神经网络

IPSO-Elman 神经网络如图 2 所示,主要分为两部分:一是左侧的 IPSO 部分;二是右侧的 Elman 部分,运用 IPSO 的粒子代表 Elman 神经网络的权值和阈值,又以右侧 Elman 神经网络的预测误差作为 IPSO 的适应度,以适应度值按照

IPSO 的步骤对粒子寻优,找到最有位置,作为 Elman 神经网络的权值和阈值。

IPSO-Elman 神经网络算法步骤

- 1) 将网络的权值和阈值作为参变量,进行实数编码。
- 2) 在编码的解空间中,随机生成初始种群,种群中每一个位串表示一个神经网络的一种权值分布。
- 3) 对群体中每个个体进行适应度评价,适应度值定义为将故障诊断误差作为 IPSO 的适应度,即

$$F_{a,k} = \sum_{k=1}^m (y_k - y_{ck})^2 \tag{12}$$

式中 y_k 表示神经网络实际输出值, y_{ck} 表示神经网络期望输出值, m 为网络输出层的的结点数。

- 4) 根据适应度,更新个体最优位置 P_{besti} 和群体最优位置 G_{best} 。
- 5) 根据式(10)对参数进行更新,并对粒子的适应度方差进行计算,判断是否进行变异操作。
- 6) 判断粒子适应度是否满足收敛条件或者是否达到最大进化代数,是则退出,否则返回步骤 3)。
- 7) 将 IPSO 算法寻找出来的最佳神经网络的权值和阈值作为 Elman 神经网络的初始值,对神经网络进行初始化。
- 8) 对重新设定的 Elman 网络进行训练,直到误差收敛到设定的精度,训练结束。

3 基于 IPSO-Elman 神经网络的航空发动机故障诊断

3.1 参数选择

本文以 PW4000 为例,根据某航空公司的指印图中的故障参数建立航空发动机故障诊断模型,以下为需要诊断的参数^[17]:低压压气机转速 N_1 、高压压气机转速 N_2 、发动机排气温度 T_{eg} 、燃油流量 $\dot{m}_f$ 。选取三种故障模式,记为 Y ,分别为: Y_1 为 2.5,引气活门打开; Y_2 为 2.9,引气活门打开; Y_3 为 3.0,引气活门打开。由于各个航空公司的状态监控系统所监测参数的个数不一致,多则 20~30,少则 3~6 个,因此为了满足各个航空公司的状态监控的要求(主要是 RD(remote diagnosis)状态监控系统,其监测参数只有 T_{eg} 、 $\dot{m}_f$ 、 N_2),采用 MIV 方法对相关参数进行筛选,得当 T_{eg} 、 $\dot{m}_f$ 、 N_1 、 N_2 各增加 10%时,MIV 值(无量纲)如表 1 所示。




图 2 IPSO-Elman 流程图

Fig. 2 Flow chart of IPSO-Elman

表 1 平均影响值
Table 1 Mean impact value

编号	M_{iv}			
	T_{eg}	$\dot{m}_f$	N_1	N_2
1	0.0310	0.0407	0.0269	0.0811
2	0.1331	0.1212	0.1442	0.0330
3	0.0039	0.0199	0.0024	0.0431
4	0.0382	0.0645	0.0181	0.0219
总和	0.2062	0.2463	0.1916	0.1791

通过表 1,可以看出, N_2 对仿真结果影响最小,可以考虑略去 N_2 ,选三个参数作为输入网络神输出端。故建立起故障诊断模型为

$$Y = F(N_1, \dot{m}_f, T_{eg}) \tag{13}$$

根据故障模型,将低压压气机转速等相关参数 $X(N_1, \dot{m}_f, T_{eg})$ 作为神经网络的输入量,发动机的故障模式 $Y(Y_1 \sim Y_3)$ 作为神经网络的输出量,并用二进制表示,如表 2。

表 2 故障模式与输出对应关系表
Table 2 Failure mode and output correspondence

故障模式	输出模式
$Y_1=2.5$,引气活门打开	1 0 0
$Y_2=2.9$,引气活门打开	0 1 0
$Y_3=3.0$,引气活门打开	0 0 1

3.2 归一化处理

在数据注入神经网络时,为使方程满足物理意义,同时适应神经网络训练,因此对数据首先进行归一化处理,即

$$x = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \tag{14}$$

式中 $x_{\max}$ 、 $x_{\min}$ 分别为输入样本 X_i 的最大值、最小值, x 为归一化处理后得到的数值。

3.3 网络结构

根据 M_{iv} 对发动机故障影响因素筛选,则确定输入层神经元节点数为 3,输出层神经元节点数为 3,即对航空发动机故障进行诊断。但是,隐层神经元个数仍没有准确的公式进行确定,目前主要采取经验公式与试验相结合的方法。依据文献[18]给出的经验公式,中间层神经元数目先分别取 5、6、7、8,最终经过试验验证,发现中间层神经元为 7 时,网络的诊断准确率最高,诊断性能最

好。因此,本例中所建立的 Elman 神经网络结构确定为(3,7,3)型。

粒子维度计算如下:

$$S = S_{in}S_h + S_h + S_hS_{out} + S_{out} \tag{15}$$

式中 S_{in} 为神经网络输出端神经元结点数, S_h 为神经网络隐含层神经元结点数, S_{out} 为神经网络输出层神经元结点数。

由于 Elman 网络结构为 3-7-4,即输入层有 3 个节点,隐含层有 7 个节点,输出层有 3 个节点,共有 $3 \times 7 + 7 \times 3 = 42$ 个权值, $7 + 3 = 10$ 个阈值,所以 IPSO 算法的粒子维数为 $42 + 10 = 52$ 。

4 IPSO-Elman 算法验证

4.1 参数设置

本文运用 MATLAB R2012a 软件编程实现 IPSO-Elman 神经网络的故障诊断模型。网络训练中共选取 150 组数据, $Y_1=2.5$ 引气活门打开、 $Y_2=2.9$ 引气活门打开、 $Y_3=3.0$ 引气活门打开各 50 组数据,每组故障的前 40 组数据作为测试集,后 10 组作为验证集。由于数据较多,则不作展示,如表 3 所示,原始数据需在归一化处理后注入 IPSO-Elman 中,表中 ϵ 为发生故障后各参数发生变化的百分比。设置种群规模为 52 个,算法迭代进化次数为 100, $c_{1\min}=1.49$, $c_{1\max}=2.05$, $c_{2\min}=1.49$, $c_{2\max}=2.05$, $V_{\max}=1$, $V_{\min}=-1$, $w_{\max}=0.9$, $w_{\min}=0.4$ 。训练 Elman 神经网络时,设定 IPSO-Elman 算法最大训练步数设为 1000,训练目标精度设为 0.001。为验证 IPSO-Elman 神经网络在航空发动机故障诊断的有效性,同时另采用 BP、Elman、SVM 以及 GM(1, n)来进行诊断,与其对比,由于 SVM 选用辨识模式,又因故障数据较少,则在绘制误差曲线时,不予考虑。

表 3 部分原始故障数据
Table 3 Part of original fault data

故障 编号	$\epsilon/\%$			
	T_{eg}	$\dot{m}_f$	N_2	N_1
Y_1	44.73	7.31	2.70	0.72
	42.19	7.46	3.11	0.67
Y_2	35.23	7.10	1.51	0.41
	30.32	7.05	0.89	0.38
Y_3	25.52	4.62	1.08	0.01
	26.98	4.58	0.69	0.04

4.2 仿真结果

经过全部训练集数据训练后的三种方法对全部测试数据集进行测试,图 3 为三种网络在训练 120 组时,达到目标误差所需的时间,从图中可以得到 IPSO-Elman 神经网络的训练速度最快,相比其他两种方法能更快地达到收敛目标。因此 IPSO-Elman 神经网络在发动机故障诊断的实际过程中为维修方案制订与决策提供更多的时间。




图 3 训练样本为 120 组时绝对误差收敛步数图
Fig. 3 Error convergence step of 120 training samples

图 4 为三种神经网络与灰色理论 GM(1, n) 模型对三种故障模式诊断的绝对误差,从图中可以看出,四种方法都能可以较好地 对 30 组故障数据进行故障诊断,四种方法对航空发动机故障诊断的误差都在 9% 以下,满足实际需求,其中 IPSO-Elman 诊断误差要小于另外三种方法。其中灰色理论模型在三种故障模式诊断中,诊断误差波动较大,诊断效果相对神经网络比较差。

从 120 组训练集数据中按照故障模式类别 1 : 1 : 1 的比例随机抽取 90、60、30 组,同样再对




图 4 训练样本为 120 组时绝对误差图
Fig. 4 Errors with 120 training samples

四种方法进行训练,采用训练好的网络与灰色理论模型对同样的测试集进行航空发动机故障诊断,诊断绝对误差如图 5、图 6、图 7 所示。




图 5 训练样本为 90 组时绝对误差图
Fig. 5 Errors with 90 training samples




图 6 训练样本为 60 组时绝对误差图
Fig. 6 Errors with 60 training samples




图 7 训练样本为 30 组时绝对误差图
Fig. 7 Errors with 30 training samples

图 4~图 7 中显示,随训练故障样本减少,Elman 与 BP 神经网络的预测误差不再稳定,误差波动随之大,而 IPSO-Elman 神经网络变化相对

稳定,误差主要集中在 5% 以下,展现出较强的预测能力,而灰色理论模型诊断效果是先减小在增大,因此在实际应用灰色 GM(1,n)模型时必须考虑训练样本数量。

表 4 与表 5 分别为训练样本数量在不同数量的训练样本的情况下网络输入参数分别为三个(情况一)与四个(情况二)时 IPSO-BP 网络、BP、Elman、SVM 以及 GM(1,n)对于 30 组航空发动机故障诊断结果的绝对误差的平均值。

从表 4 与表 5 中可得,在不同数量的训练样本条件下,IPSO-Elman 神经网络诊断误差最小。随训练样本的数量减少,IPSO-Elman、BP、Elman、SVM 的诊断精度都增大,而 GM(1,n)模型的诊断误差先减小后增大。另外,IPSO-Elman 神经网络在输入不同诊断参数时,其诊断结果差异不大。

表 4 情况一时诊断结果

Table 4 Diagnosis results in condition 1

样本 数量	诊断误差/%				
	IPSO-Elman	BP	Elman	GM	SVM
120	1.89	3.29	3.14	8.64	0
90	2.06	3.48	3.31	6.79	3.33
60	2.31	3.70	3.73	5.63	3.33
30	2.47	4.93	4.85	6.87	3.33

表 5 情况二时诊断结果

Table 5 Diagnosis results in condition 2

样本 数量	诊断误差/%				
	IPSO-Elman	BP	Elman	GM	SVM
120	1.56	2.95	2.81	8.50	0
90	2.04	3.10	3.22	6.76	3.33
60	2.11	3.34	3.37	5.58	3.33
30	2.23	4.74	4.83	6.45	3.33

5 结 论

本文结合航空发动机的结构与工作环境复杂的特点,综合考虑多种影响因素,提出了基于 IPSO-Elman 的航空发动机故障诊断方法。选取了三种相似的故障模式,在不同数量的训练样本下分别对 Elman、BP、IPSO-Elman、SVM、GM(1,n)进行仿真试验。结果表明:

1) IPSO-Elman 神经网络在不同数量的航空

发动机故障数据的诊断中,都具有较高的准确度和快速的收敛能力,为维修工程师提供充足的准备时间与决策时间。

2) IPSO 与 MIV 方法相结合,使诊断因素由常规四个减少为三个,增加了其在航空发动机故障诊断中的适应能力,为应用 RD 状态监控系统的航空公司在智能故障诊断中提供了理论依据。

参考文献:

[1] 曲建岭,唐昌盛,肖辉雄. 人工神经网络融合诊断航空发动机气路故障[J]. 航空动力学报,2008,23(11):2124-2127.
QU Jianling, TANG Changsheng, XIAO Huixiong. Integrated diagnosis of aeroengines' gas path faults using artificial neural network[J]. Journal of Aerospace Power, 2008, 23(11):2124-2127. (in Chinese)

[2] 陈括,孙建国. 粗糙集与神经网络在航空发动机气路故障诊断中的应用[J]. 航空动力学报,2006,21(1):207-212.
CHEN Tian, SUN Jianguo. Aeroengine gas path fault diagnosis using rough sets and neural networks[J]. Journal of Aerospace Power, 2006, 21(1):207-212. (in Chinese)

[3] 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)

[4] VOLPONI A J, DE POLD H, GANGULI R. The use of kalman filter and neural network methodologies in gas turbine performance diagnostics: a comparative study[J]. Journal of Engineering for Gas Turbines and Power, 2003, 125(4):917-924.

[5] LEE S M, CHOI W J, ROH T S. A study on separate learning algorithm using support vector machine for defect diagnostics of gas turbine engine[J]. Journal of Mechanical Science and Technology, 2008, 22(12):2489-2497.

[6] CHANG Xiaodong, HUANG Jinquan, LU Feng. Robust in-flight sensor fault diagnostics for aircraft engine based on sliding mode observers[J]. Sensors, 2017, 17(4):835.1-835.15.

[7] JOESPH C G, GARY D R. 专家系统原理与编程[M]. 印鉴,刘星成,汤庸,等译. 北京:科学出版社,2007.

[8] 温熙森. 模式识别与状态监控[M]. 北京:科学出版社,2007.

[9] 肖建华. 智能模式识别方法[M]. 广州:华南理工大学出版社,2007.

[10] 钟诗胜,李洋. 基于小波过程神经网络的飞机发动机状态监视[J]. 航空学报,2007,28(1):68-71.
ZHONG Shisheng, LI Yang. Condition monitoring of aero-engine based on wavelet process neural networks[J]. Acta Aeronautica et Astronautica Sinica, 2007, 28(1):68-71. (in Chinese)

[11] 单晓明,宋云峰,黄金泉,等. 基于神经网络和模糊逻辑的航空发动机监视[J]. 航空动力学报,2009,24(10):2356-

2361.

SHAN Xiaoming, SONG Yunfeng, HUANG Jinquan, et al. Condition monitoring of aero-engine based on neural network and fuzzy logic[J]. Journal of Aerospace Power, 2009,24(10):2356-2361. (in Chinese)

[12] 陈果. 用结构自适应神经网络预测航空发动机性能趋势[J]. 航空学报, 2007,28(3):535-539.

CHEN Guo. Forecasting engine performance trend by using structure self-adaptive neural network[J]. Acta Aeronautica et Astronautica sinica, 2007, 28(3): 535-539. (in Chinese)

[13] 傅荟璇, 赵红, 王宇超, 等. MATLAB 神经网络应用设计[M]. 北京: 机械工业出版社, 2010.

[14] 史峰, 王小川 郁磊 等 MATLAB神经网络 30个案例分析[M]. 北京: 北京航空航天大学出版社, 2010.

[15] 李东年, 周以齐. 采用改进粒子群优化粒子滤波的三维人手跟踪[J]. 光学精密工程, 2014,22(10):2870-2878.

LI Dongnian, ZHOU Yiqi. Three dimensional hand tracking by improved particle swarm optimized particle filter [J]. Optics and Precision Engineering, 2014,22(10):2870-2878. (in Chinese)

[16] LING S H, IU H, LEUNG F H, et al. Improved hybrid particle swarm optimized wavelet neural network for modeling the development of fluid dispensing for electronic packaging[J]. IEEE Transactions on Industrial Electronics, 2008,55(9):3447-3460.

[17] 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.

[18] 陈法法, 汤宝平, 黄庆卿. 免疫遗传优化 Elman 神经网络的旋转机械故障诊断[J]. 重庆大学学报, 2012,35(5):7-13.

CHEN Fafa, TANG Baoping, HUANG Qingqing. Rotating machinery fault diagnosis based on Elman neural network optimized by immune genetic algorithm [J]. Journal of Chongqing University, 2012,35(5):7-13. (in Chinese)

(编辑: 陈 越)