

一种自生成基函数模糊神经元故障诊断模型及其应用*

秦国军 胡萋庆 温熙森

(国防科技大学机械电子工程与仪器系 长沙 410073)

摘要 在分析自生成基函数 (SGRBF) 模糊神经元模型基础上, 提出了一种新的故障诊断网络模型及其学习算法, 并将其应用到轴承、齿轮的故障诊断中, 给出两个应用实例及分析结果。最后, 文章将得出一定的结论。

关键词 基函数, 故障诊断, 模糊模型

分类号 TP206.3

A Self Generating Radial Basis Function Neuro-Fuzzy Fault diagnosis Model and its Application

Qin Guojun Hu Niaoqing Wen Xisen

(Department of Mechtronics Engineering and Instrumentation, NUDT, Changsha, 410073)

Abstract In this paper, we propose a fault diagnosis model and its training algorithm based-on self generating radial basis function (SGRBF) fuzzy neuros. Two examples for the diagnosis of bearing and gear faults using this model are also given. Finally, some conclusion is drawn.

Key words radial basis function, fault diagnosis, fuzzy model

由于以神经网络为代表的典型的数值推理存在知识不能显式表示等缺点, 而以专家系统为代表的典型符号推理学习功能较差, 因此, 包括神经网络与模糊系统集成在内的混合推理技术近年来为众多研究者所重视^[1]。几乎所有的常用神经网络均进行了模糊化^[2~4]。日本学者 Ryu Katayama 等提出一种自生成基函数 (SGRBF) 模糊神经元模型, 并将其应用于混沌时间序列的非线性预测^[5], 取得了较好的效果。本文对该模型进行了一定的改进, 建立了 SGRBF (self generating radial basis function) 模糊神经元故障诊断模型, 使其具有规则自动生成, 解释功能强的特点, 并将其应用于轴承和齿轮的故障诊断中。

1 SGRBF 模糊神经元故障诊断模型

1.1 模型的拓扑结构

自生成基函数模糊神经元故障诊断模型的拓扑结构如图 1 所示。网络有 m 个输入节点, 输入向量 $X = (x_1, x_2, \dots, x_m)$ 为待识别的归一化特征向量; 网络输出

$$z = J | y_j = \max(y_j), j = 1, 2, \dots, s \quad (1)$$

s 为待识别的已知模式数,

$$y_j = \sum_{k=1}^n w_{kj} \cdot \mu_k(x, a_k, b_k), j = 1, 2, \dots, s \quad (2)$$

为第二隐层节点 j 的输出。 n 为第一隐层节点个数, $a_k \in R^m$, $b_k \in R^m$ ($k=1, 2, \dots, n$) 分别为基函数的中心和宽度向量, w_{kj} ($k=1, \dots, n, j=1, \dots, s$) 为第一、二隐层节点之间的权值系数; 而

* 1997 年 3 月 17 日收稿

第一作者: 秦国军, 男, 1970 年生, 博士生

$$\mu_k(x, a_k, b_k) = \prod_{i=1}^m A_{ik}(x_i, a_{ik}, b_{ik}) \quad (3)$$

其中 $A_{ik}(x_i, a_{ik}, b_{ik})$ 为 x_i 对应的基函数, a_{ik}, b_{ik} 为基函数的中心和宽度值, 本文采用高斯型基函数

$$A_{ik}(x_i, a_{ik}, b_{ik}) = \exp(-(x_i - a_{ik})^2/b_{ik}) \quad (4)$$

通过 (1) ~ (4) 式便可动态生成符号推理规则: If $(x_1=a_{1k}$ and $x_2=a_{2k}$ and \dots and $x_m=a_{mk})$ then $(y_1=w_{1k}$ and $y_2=w_{2k}$ and \dots and $y_s=w_{sk})$, 其中, $k=1 \sim n$, n 为第一隐层节点个数 (规则的数目)。

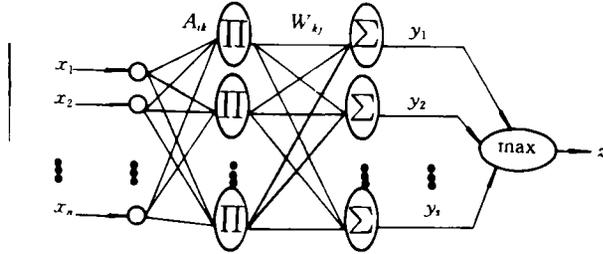


图 1 SGRBF 模糊神经元故障诊断模型

1.2 网络的训练过程

网络训练的目的在于求使准则函数 $E_n(a^n, b^n, w^n) = \frac{1}{2} \sum_{p=1}^N \sum_{j=1}^s (y_j^p - {}^*y_j^p)^2$ (y_j^p 为网络期望输出, ${}^*y_j^p$ 为实际输出值, $p=1, \dots, N$, N 为学习样本数) 最小的如下网络参数:

- (1) 基函数族数目 (第一隐层节点数) n
- (2) 基函数中心向量 $a^n = (a_1, a_2, \dots, a_k, \dots, a_n)$, 其中 $a_k = (a_{1k}, a_{2k}, \dots, a_{ik}, \dots, a_{mk})$
- (3) 基函数宽度向量 $b^n = (b_1, b_2, \dots, b_k, \dots, b_n)$, 其中 $b_k = (b_{1k}, b_{2k}, \dots, b_{ik}, \dots, b_{mk})$
- (4) 隐层连接权值向量 $w^n = (w_1, w_2, \dots, w_k, \dots, w_n)$, $w_k = (w_{k1}, w_{k2}, \dots, w_{k3}, \dots, w_{ks})$

本文采用的网络自生成学习算法如下:

- (1) 设定期望误差限 ϵ 、下降步长 α 、控制基函数生成的最小误差下降率 β 和基函数初始宽度 b_0 ;
- (2) 初始化 $n=1, h=0$, 初始化 a^n, b^n, w^n, E_0 ;
- (3) 计算准则误差函数 E_n , 如果 $E_n < \epsilon$, 到第 (7) 步;
- (4) 如果 $|(E_n - E_{n-1}) / E_n| \geq \beta$, 则 (6);
- (5) 生成第 $n+1$ 个新的第一层隐节点, 并利用 $a_{i,n+1} = x_i^q, w_{n+1,3} = y_j^q - {}^*y_j^q, b_{i,n+1} = b_0, (i=1, \dots, m, j=1, \dots, s)$ 生成新的一组基函数。其中 q 满足

$$\sum_{j=1}^s |y_j^q - {}^*y_j^q| = \max_{1 \leq p \leq N} \sum_{j=1}^s |y_j^p - {}^*y_j^p| \quad (5)$$

式中 N 为学习样本数。到 (3) 步;

- (6) 采用梯度下降算法调整 a^n, b^n, w^n

$$a_{ik}(h+1) = a_{ik}(h) - \alpha \cdot \partial E_n / \partial a_{ik} \quad (6a)$$

$$b_{ik}(h+1) = b_{ik}(h) - \alpha \cdot \partial E_n / \partial b_{ik} \quad (6b)$$

$$w_{kj}(h+1) = w_{kj}(h) - \alpha \cdot \partial E_n / \partial w_{kj} \quad (6c)$$

$h=h+1$; 转 (3)

- (7) 学习结束, 返回学习结果。

2 SGRBF 模糊神经元故障诊断模型的应用

2.1 在轴承故障诊断中的应用

表 1 给出了轴承故障诊断训练样本数据, 该数据来自对轴承振动加速度信号进行对数功率谱分析

获得的 8 维特征。

表 1 轴承故障诊断训练样本数据

对数谱分析 8 维特征								状态模式	
x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8		
1	-0.78167	-0.278616	-0.295448	-0.239439	-0.184172	-0.157152	-0.158352	-0.199817	1 0 0
2	-1.87104	-0.295679	-0.349428	-0.290351	-0.146039	-0.138699	-0.149210	-0.222821	1 0 0
3	-1.83465	-0.281684	-0.356612	-0.347560	-0.181962	-0.143542	-0.177766	-0.184873	1 0 0
4	-1.40865	-0.277331	-0.275869	-0.218132	-0.057534	-0.082920	-0.059231	-0.124043	0 1 0
5	-1.74432	-0.176582	-0.150587	-0.194436	-0.153307	-0.167227	-0.214685	-0.279192	0 1 0
6	-1.80693	-0.240755	-0.149753	-0.208823	-0.196610	-0.172256	-0.193539	-0.250669	0 1 0
7	-1.72593	-0.194280	-0.137345	-0.217209	-0.195213	-0.177607	-0.163184	-0.254998	0 1 0
8	-5.14668	-0.183906	-0.143153	-0.069439	0.0284765	0.0991441	0.132563	0.0591773	0 0 1
9	-0.791452	-0.101805	-0.073727	-0.094528	-0.095540	0.0043814	0.0467290	0.0719261	0 0 1
10	-1.02416	-0.146149	-0.101754	-0.077760	-0.036306	-0.047604	0.0160112	-0.025312	0 0 1

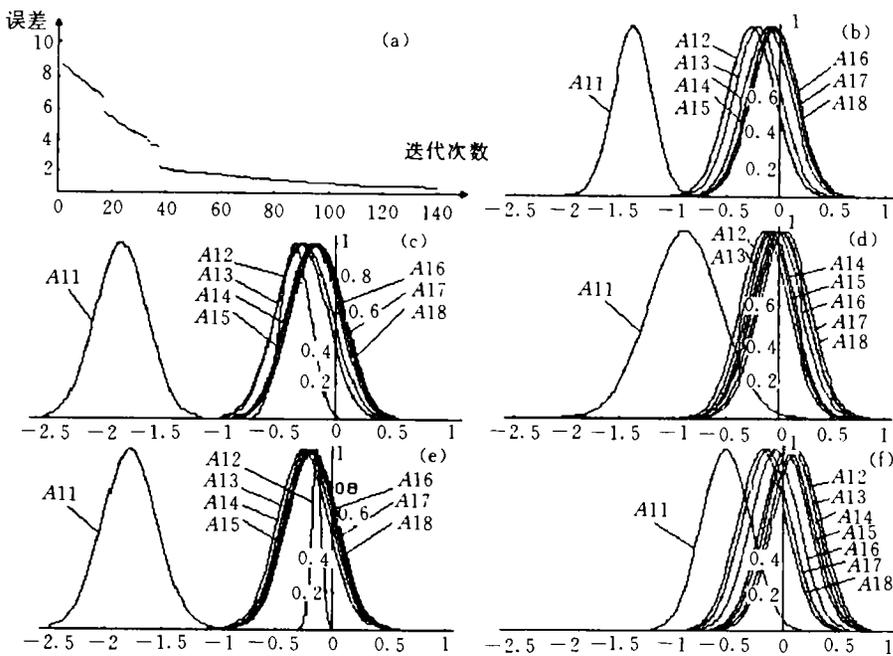


图 2 轴承 8 维特征样本训练误差下降过程曲线与基函数族

选定网络的输入层节点数为 8，第二隐层节点数为 3， $\beta=0.01$ ，应用该样本序列进行网络训练，按照网络基函数自生成算法进行迭代 144 次，结果收敛得到误差为 0.044629，第一隐层节点数为 5。学习过程的误差下降过程如图 2 (a) 所示，训练结果得到的 40 个基函数如图 2 (b) ~ (f) 所示。从图中可以看出，8 维特征之间存在冗余。分析其基函数族的中心和宽度，可知第 2~8 维特征对应的 5 组基函数中心相差较小，第 3~8 维特征对应的 5 组基函数宽度相差也较小。因此，可以考虑对特征空间

进行降维处理,保留差异较大的第 1、2 维特征,在第 3~8 维特征中选择某一特征(不妨选择第 3 维特征)构成新的特征空间。

利用降维处理后得到的 3 维特征空间,取输入层节点数为 3,第二隐层节点数为 3, $\beta=0.025$,按照网络基函数自生成算法进行重新训练。学习过程的误差下降过程如图 3 所示,迭代 18 次便收敛得到误差为 0.166402,第一隐层节点数为 5。可见,训练时间明显缩短。

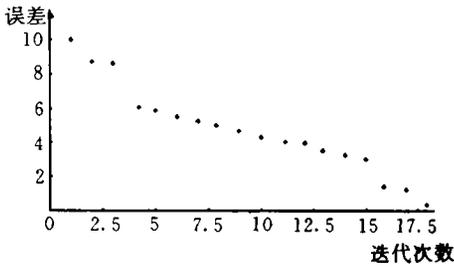


图 3 轴承 3 维特征样本训练误差下降曲线

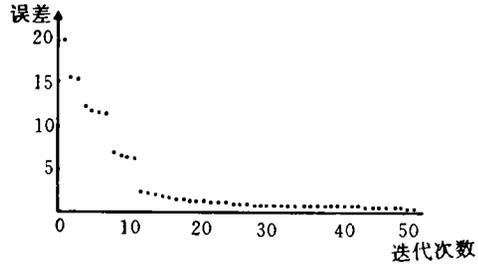


图 4 齿轮特征样本训练误差下降曲线

2.2 在齿轮故障诊断中的应用

表 2 给出一组齿轮故障诊断训练样本数据,该数据来自对齿轮振动加速度信号进行的 Wigner-Ville 时频分析^[6]。

表 2 齿轮故障诊断网络训练特征数据

由时频分析提取的特征								状态 模式	由时频分析提取的特征								状态 模式
x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8		x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	
1452.21	13.83	2.57	0.98	297.15	1628.21	13.48	7.83	1 0 0 0	2929.15	16.47	3.42	2.32	2266.9	8541.91	59.55	27.81	0 0 1 0
1866.71	12.17	2.8	1.33	1755.24	1625.8	20.34	9.23	1 0 0 0	2772.44	16.53	3.99	2.23	3332.52	5459.65	15.29	16.39	0 0 1 0
1504.76	13.99	2.69	1.32	1265.23	1846.7	11.77	7.27	1 0 0 0	2870.24	13.92	3.15	1.67	2440.27	6925.6	26.9	21.98	0 0 1 0
1802.2	14.68	2.66	1.27	1717.46	1517.91	10.46	7.98	1 0 0 0	2987.99	17.56	3.43	2.00	2413.38	7916.22	63.43	26.28	0 0 1 0
1380.07	15.58	3.46	1.26	1359.86	1564.5	21.32	8.47	1 0 0 0	2659.38	17.2	3.43	2.4	1988.88	5974.26	19.94	19.93	0 0 1 0
2261.49	15.41	2.16	2.25	3425.95	3269.00	141.42	199.46	1 0 0 0	2792.02	12.25	2.52	2.43	1037.88	13971.03	165.33	45.36	0 0 0 1
2104.45	13.72	2.29	2.4	2732.28	4334.01	159.46	187.29	1 0 0 0	2973.96	17.07	2.66	2.22	951.74	14537.76	165.64	61.64	0 0 0 1
1982.45	12.62	2.45	2.69	2.08	3214.55	134.59	168.87	1 0 0 0	2283.37	11.79	2.49	2.09	1094.08	17910.8	140.82	55.11	0 0 0 1
2284.77	12.9	2.25	2.03	2988.22	3069.05	168.28	128.02	1 0 0 0	2347.31	13.72	2.19	2.17	1402.72	15866.43	151.13	57.07	0 0 0 1
2354.35	13.42	2.64	2.52	2296.9	3981.52	154.04	181.00	1 0 0 0	2598.43	15.53	2.18	2.3	830.44	17461.76	170.23	65.14	0 0 0 1

取输入层节点数为 8,第二隐层节点数为 4, $\beta=0.025$,应用上述样本,按照网络基函数自生成算法进行网络训练,迭代 51 次可收敛得到误差为 0.391127,第一隐层节点数为 5。其误差下降曲线如图 4 所示。为确定网络的学习效果,用 4 组样本^[6]进行验证,其诊断结果列入表 3 中,与实际相符。

表3 齿轮诊断测试样本数据与结果

序号	由时频分析提取的特征							y1	y2	y3	y4	z 输出	
1	1700.66	11.28	2.58	1.06	791.61	1825.39	13.41	7.14	1.027	0.018	-0.022	-0.01	$z = y1$
2	2408.37	15.21	2.59	2.35	2842.43	3420.03	143.99	149.94	-0.014	1.092	0.0868	-0.014	$z = y2$
3	2885.28	16.06	3.00	1.85	1698.42	7870.09	36.64	20.42	0.1716	0.023	0.8145	0.089	$z = y3$
4	3229.54	11.33	2.4	2.25	91	17302.55	151.1	47.68	-0.014	0.016	-0.0158	0.7674	$z = y4$

3 结论与展望

本文的研究表明,SGRBF 模糊神经元故障诊断模型在故障诊断中是比较有效的。它不仅可以通过改变隐层节点数目自动生成规则,而且经过基函数之间的比较分析,可降低特征维数,从而减少输入节点的个数,大大提高学习和诊断的速度。

为提高学习效率和诊断的精确性,应进一步优化选择基函数类型并改进学习算法。

参考文献

- 1 杨叔子,丁洪等,基于知识的诊断推理,北京清华大学出版社,1993
- 2 Grossberg, G A Reynolds, S. Fuzzy D B. ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural Networks*, 1995, 4(6): 795-771.
- 3 Paland S K Mitra. S. Fuzzy Versions of Kohonen's Net and MLP-Based Classification Performance Evaluation for Certain Nonconvex Decision Regions. *Information Science*, 1994, 76: 297
- 4 Hong Keung Kwan and Yaling Cai. A Fuzzy Neural Network and its Application to Pattern Recognition. *IEEE Trans. on Fuzzy Systems*, 1994, 2(3)
- 5 Katayama, R Kajitani, Y. Kuwata K. Self Generating Radial Basis Function as Neuro-Fuzzy Model and its Application to Nonlinear Prediction of Chaotic Time Series, Second Int. Conf. on Fuzzy Systems (Fuzzy-IEEE'93), San Francisco, California, 1993
- 6 Jones, L. H. Machinery Monitoring and Diagnostics Using Pseudo Wigner-Ville Distribution and Backpropagation Neural Network. Naval Postgraduate School, California, AD-A276219, 1993