

模糊基函数神经网络在线跟踪自学习算法研究

许飞云,钟秉林,黄 仁

(东南大学机械工程学院,南京 210096)

[摘要] 提出了一种用于分类的模糊基函数(FBF)神经网络在线跟踪自学习算法,通过带有遗忘因子的样本均值和样本协方差矩阵,保存了原始样本所包含的类可能性分布信息,并在此基础上产生新增样本的目标输出用于训练 FBF 网络,以实现分类边界的在线跟踪;给出了带有遗忘因子的样本均值和样本协方差矩阵的递推算法,以克服传统方法需要保存大量以往训练样本带来的困难。所提出的方法用于旋转机械的故障识别,结果表明是可行的和有效的。

[关键词] 模糊基函数;自学习;故障诊断

[中图分类号] TP183;TP277 [文献标识码] A [文章编号] 1009-1742(2007)11-0048-06

1 引言

在神经网络(NN)理论中,学习包括两个方面的含义,一是通常意义上的学习训练,通过给定的样本,对初步设计的网络权参数进行调节,使之满足问题求解的需要,如文献[1]通过神经模糊系统的自学习,从实际数据中提取直流电机的模糊诊断规则;文献[2]通过模块化径向基函数网络,对新故障的自学习提高诊断系统的诊断能力。二是自学习,即对已经得到良好训练的网络,通过新增样本的学习,使之适应了变化的环境,如在自动控制领域经常采用的在线训练算法。对于用于分类的有指导训练网络,由于学习过程和工作过程通常是分离的,为了避免再次学习时出现“突然遗忘”现象^[3],训练样本集需要包含过去所有的样本及新增的样本,从而导致随着时间推移,样本规模越来越大,训练也越来越困难。

为了解决上述问题,笔者针对用于分类的模糊基函数(FBF)神经网络的自学习问题进行了研究^[4],详细介绍了一种通过带有遗忘因子的样本均值和样本协方差矩阵,保存样本所包含的类可能性分布信息,并在此基础上产生新增样本的目标输出用于训练 FBF 网络,以实现在线跟踪分类边界的自学习算法。

2 模糊基函数神经网络

2.1 FBF 神经网络结构

考虑由模糊规则

$$R_{i_1, i_2, \dots, i_n}: \text{如果 } x_1 = A_{i_1}^1, x_2 = A_{i_2}^1, \dots, x_n = A_{i_n}^n, \text{那么 } y B_{i_1, i_2, \dots, i_n} \quad (1)$$

所构成的单输出模糊系统,其中 $A_{i_j}^j \subset U_j, B_{i_1, i_2, \dots, i_n} \subset V$ 分别表示论域 U_j 和 V 上的语义项模糊集, $i_j = 1, 2, \dots, N_j; j = 1, 2, \dots, n; N_j$ 为 x_j 所属论域 U_j 上的基本语义项模糊集的数目。

若采用单点模糊化算子、代数积蕴含、Sup-Product 合成和重心非模糊化方法,且模糊隶属函数 $A_{i_j}^j(x_j)$ 均为 Gaussian 隶属函数,则 FBF 具有如下形式^[5]:

$$p_{i_1, i_2, \dots, i_n}(\mathbf{x}) = \frac{\prod_{j=1}^n A_{i_j}^j(x_j)}{\sum_{i_1, i_2, \dots, i_n \in I} \prod_{j=1}^n A_{i_j}^j(x_j) \exp\left[-\frac{1}{2} \sum_{j=1}^n \left[\frac{x_j - \bar{x}_{i_j}^j}{\sigma_{i_j}^j}\right]^2\right]} \exp\left[-\frac{1}{2} \sum_{j=1}^n \left[\frac{x_j - \bar{x}_{i_j}^j}{\sigma_{i_j}^j}\right]^2\right]} \quad (2)$$

[收稿日期] 2006-06-16;修回日期 2007-03-09

[基金项目] “八六三”高技术研究发展计划资助项目(2001AA423240)

[作者简介] 许飞云(1969-),男,江苏如东县人,工学博士,东南大学机械工程学院副教授

其中, $\mathbf{x} = (x_1, x_2, \dots, x_n)^T \in R^n$; I 为指标集, $I = \{i_1, i_2, \dots, i_n \mid i_j = 1, 2, \dots, N_j; j = 1, 2, \dots, n\}$; $\bar{x}_{i_j}^j$ 为 Gaussian 隶属函数 $A_{i_j}^j(x_j)$ 的中心; $\sigma_{i_j}^j$ 为其半径。

模糊系统可以表示成一系列 FBF 的线性组合, 即模糊系统的输出为

$$y = \sum_{i=1}^H p_i(x) w_i \quad (3)$$

式中 H 为模糊基函数的个数, 即模糊系统的规则总数。

单输出模糊系统可以通过图 1 所示的 FBF 网络实现。FBF 网络具有良好的非线性函数逼近特性^[4,5], 能够直接根据系统的输入输出逼近系统的动态行为。对于复杂的系统, 由于 FBF 网络可以根据系统操作者和专家的知识弥补实际测量数据的不足, 使它比传统的基于实测数据的 NN 能更好地反映系统的特性。

FBF 网络的输出反映了给定样本属于输出类的可能性(隶属度), 由于 FBF 网络中模糊隶属函数隐含的距离特性, 当给定样本接近所对应的类别时, 网络输出的可能性高, 反之, 当给定样本远离该类时, 网络输出的可能性较小或接近于 0, 这样对于未知的不属于该类的样本, FBF 网络能够正确地做出拒绝决策, 满足分类系统的要求。

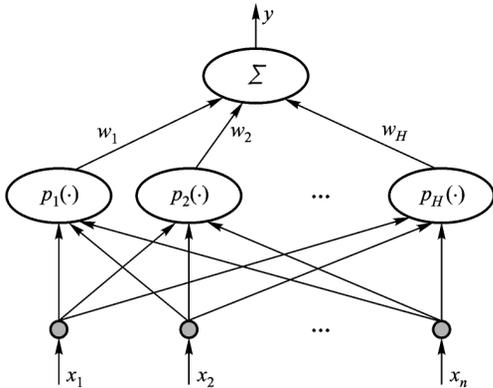


图 1 单输出 FBF 网络

Fig. 1 Fuzzy basis function network with single output

对于多输出情形, 一般通过直接增加输出层节点个数的方法处理, 但此时由于对某一类别的输入样本, 只有对应于该类别的隐 FBF 单元存在输出, 其他 FBF 单元输出很小或为零, 导致输出层权重学习困难。为此采用了对隐 FBF 单元进一步归类, 构建模块化 FBF 网络以消除不必要的输出层权重, 降低输出层权重学习的难度。实际的网络结构如图 2 所示。

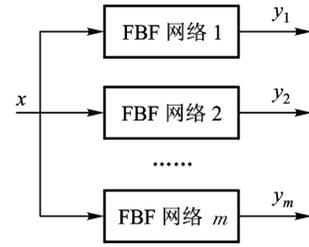


图 2 模块化多输出 FBF 网络

Fig. 2 Modularized fuzzy basis function network for multiple outputs

2.3 模糊基函数网络的学习算法

FBF 网络需要学习的参数包括 $\mathbf{w} = (w_1, w_2, \dots, w_H)^T$, $\bar{\mathbf{x}}_i = (\bar{x}_{i_1}^1, \bar{x}_{i_2}^2, \dots, \bar{x}_{i_n}^n)^T$ 以及 $\boldsymbol{\sigma}_i = (\sigma_{i_1}^1, \sigma_{i_2}^2, \dots, \sigma_{i_n}^n)^T$, ($i = 1, 2, \dots, H$)。为了方便, 简记 $\bar{\mathbf{x}}_i = (\bar{x}_{i_1}, \bar{x}_{i_2}, \dots, \bar{x}_{i_n})^T$, $\boldsymbol{\sigma}_i = (\sigma_{i_1}, \sigma_{i_2}, \dots, \sigma_{i_n})^T$ 。FBF 网络的学习可采用正交最小二乘算法^[4]或梯度优化算法^[6], 笔者采用了类似于 RBF 网络学习的两步算法^[6], 即:

1) 应用聚类算法获取 FBF 的中心并确定 Gaussian 隶属函数的半径。本文聚类算法采用了广义学习向量量化算法 (generalized learning vector quantization, GLVQ)^[7], 以消除 C-均值聚类算法对初始条件的敏感性。

2) 应用梯度优化算法调节 FBF 网络的输出层权重。由于输出单元为隐 FBF 单元输出的线性组合, 此处采用梯度优化算法不仅没有局部极小的问题, 而且可以有效地避免采用最小二乘求解权重时由于矩阵病态所造成的学习失败。

上述学习算法仅考虑了从实际的输入-输出数据对决定 FBF 网络的方法, 尽管如此, 它也能用于具有预先确定规则的 FBF 网络, 此时先可以固定由语义规则所确定的 FBF 单元, 再通过上述算法获取由输入数据所产生的 FBF, 并对所有 FBF 的输出权重参数应用梯度优化算法同时学习。注意到, 由语义规则决定的 FBF 单元与由数值数据所产生的 FBF 单元可能表达了同一条规则, 为了优化网络结构, 可以通过规则相似性度量和重要性度量, 删除冗余的或不必要的 FBF 单元^[8]。

3 FBF 网络在线跟踪自学习算法

3.1 FBF 网络的在线跟踪自学习策略

实现 NN 自学习的关键是对当前网络重新训练

时,如何确保网络不丢失已经得到学习的知识。解决该问题的一个自然的思路是对相似样本进行压缩,仅保留最具代表性的样本作为过去的事例用于当前网络的训练。注意到,FBF 网络训练过程中的聚类实质是将相似性更高的样本聚为一个子类,因此,可以认为 FBF 单元的中心自然地相应于训练样本中最具代表性的样本,即 FBF 网络参数已经对训练样本进行了有效的压缩。基于此,FBF 网络的在线跟踪自学习可以采取如下策略:

1) FBF 的中心及半径的学习:以原 FBF 中心为初始中心,只对每个新增样本进行一步迭代以减缓旧中心的遗忘速度。第 i 个 FBF 单元的新中心由式

$$c_{N_{i+1},ij} = \begin{cases} c_{N_i,ij} + \alpha(x_{N_{i+1},j} - c_{N_i,ij}) & x_{N_{i+1}} \in C_i \\ c_{N_i,ij} + \beta(x_{N_{i+1},j} - c_{N_i,ij}) & x_{N_{i+1}} \notin C_i \end{cases} \quad (4)$$

递推求取,式中 $0 < \alpha, \beta < 1$ 分别为 GLVQ 算法的获胜单元和非获胜单元的学习率, N_i 为第 i 个 FBF 单元所拥有的样本数。FBF 单元的新半径取为

$$\sigma_{N_{i+1},ij}^2 = \max_{i \neq k} (c_{N_{i+1},ij} - c_{N_{i+1},kj})^2 / H \quad (5)$$

式中 H 为 FBF 单元的数量。

2) 通过新样本的期望输出来体现网络已学习到的类可能性分布信息,即新增训练样本的期望输出依赖于过去的训练样本。为此,采用了具有遗忘因子的加权平均技术。

考虑某一类别 C , 设其过去 P 个样本的加权平均中心为

$$v_p = \frac{\sum_{i=1}^P \lambda^{P-i} \mathbf{x}_i}{\sum_{i=1}^P \lambda^{P-i}} = \frac{1-\lambda}{1-\lambda^P} \left[\sum_{i=1}^P \lambda^{P-i} \mathbf{x}_i \right] \quad (6)$$

式中 $\mathbf{x}_i (i=1, 2, \dots, P)$ 为样本向量, P 为样本数, λ 为遗忘因子,一般 $\lambda \in (0.95, 1)$ 。

加权协方差矩阵为

$$\Sigma_p = \frac{\sum_{i=1}^P \lambda^{P-i} (\mathbf{x}_i - v_p) (\mathbf{x}_i - v_p)^T}{\sum_{i=1}^P \lambda^{P-i}} = \frac{1-\lambda}{1-\lambda^P} \left[\sum_{i=1}^P \lambda^{P-i} (\mathbf{x}_i - v_p) (\mathbf{x}_i - v_p)^T \right] \quad (7)$$

对于给定的样本 \mathbf{x}_j , 其期望的可能性输出由正态型多元模糊分布

$$\mu_j = \exp \left[-\frac{1}{k} d_j^2 \right] = \exp \left[-\frac{1}{k} (\mathbf{x}_j - v_p)^T \Sigma_p^{-1} (\mathbf{x}_j - v_p) \right] \quad (8)$$

求得,其中 $d_j = \sqrt{(\mathbf{x}_j - v_p)^T \Sigma_p^{-1} (\mathbf{x}_j - v_p)}$, 为 \mathbf{x}_j 与类中心 v_p 间的 Mahalanobis 距离。常数 $k > 0$, 用于调整样本的期望可能性输出。通常应使得距离类中心 v_p 最远的样本的可能性输出 ≥ 0.5 。

3.2 带有遗忘因子的样本均值和协方差矩阵的递推运算

直接求取带有遗忘因子的样本均值及协方差矩阵,需要保留所有的样本。此外,计算 Mahalanobis 距离需要求样本协方差矩阵的逆,计算量很大,为此,笔者进一步提出了带有遗忘因子的样本均值、样本协方差阵及其逆矩阵的迭代计算方法。

设 P 个初始样本的加权均值和协方差阵分别为 v_p 及 Σ_p 。新增样本 \mathbf{x}_{P+1} 后,有

$$v_{P+1} = \frac{1-\lambda}{1-\lambda^{P+1}} \left[\sum_{i=1}^{P+1} \lambda^{P+1-i} \mathbf{x}_i \right] = (1-\alpha_{P+1}) v_p + \alpha_{P+1} \mathbf{x}_{P+1} \quad (9)$$

$$\text{式中} \quad \alpha_{P+1} = \frac{1-\lambda}{1-\lambda^{P+1}} \quad (10)$$

$$\Sigma_{P+1} = \frac{1-\lambda}{1-\lambda^{P+1}} \left[\sum_{i=1}^{P+1} \lambda^{P+1-i} (\mathbf{x}_i - v_{P+1}) (\mathbf{x}_i - v_{P+1})^T \right] = (1-\alpha_{P+1}) \left[\Sigma_p + \alpha_{P+1} (v_p - \mathbf{x}_{P+1}) (v_p - \mathbf{x}_{P+1})^T \right] \quad (11)$$

利用矩阵反演公式 $(A + BC)^{-1} = A^{-1} - A^{-1} B (I + C A^{-1} B)^{-1} C A^{-1}$, 取 $A = \Sigma_p$, $B = \alpha_{P+1} (v_p - \mathbf{x}_{P+1})$, $C = (v_p - \mathbf{x}_{P+1})^T$, 则

$$\Sigma_{P+1}^{-1} = \frac{1}{1-\alpha_{P+1}} \left[\Sigma_p^{-1} - \frac{\Sigma_p^{-1} (v_p - \mathbf{x}_{P+1}) (v_p - \mathbf{x}_{P+1})^T \Sigma_p^{-1}}{\frac{1}{\alpha_{P+1}} + (v_p - \mathbf{x}_{P+1})^T \Sigma_p^{-1} (v_p - \mathbf{x}_{P+1})} \right]。$$

为了在计算过程中保证 Σ_{P+1}^{-1} 的对称性,实际运算时采用式

$$\Sigma_{P+1}^{-1} = \frac{1}{1-\alpha_{P+1}} \left\{ \Sigma_p^{-1} - \mathbf{K}_{P+1} \mathbf{K}_{P+1}^T \left[\frac{1}{\alpha_{P+1}} + (v_p - \mathbf{x}_{P+1})^T \Sigma_p^{-1} (v_p - \mathbf{x}_{P+1}) \right] \right\} \quad (12)$$

式中

$$\mathbf{K}_{P+1} = \frac{\Sigma_p^{-1} (v_p - \mathbf{x}_{P+1})}{\frac{1}{\alpha_{P+1}} + (v_p - \mathbf{x}_{P+1})^T \Sigma_p^{-1} (v_p - \mathbf{x}_{P+1})} \quad (13)$$

由式(9)至式(13)即可实现带有遗忘因子的样本均值 v_{P+1} 和协方差阵 Σ_{P+1} 及其逆阵的递推计算。

4 FBF 网络在线跟踪自学习算法的仿真和应用

4.1 在线跟踪自学习算法的仿真

为了显示自学习算法在线跟踪分类边界的能力,对二维分类过程进行了仿真,设初始聚类中心为 $v_p = (2, 2)^T$,协方差矩阵为

$$\Sigma_p = \begin{bmatrix} 0.4 & 0.2 \\ 0.2 & 0.8 \end{bmatrix}$$

当前用于学习的样本中心为 $(4, 4)^T$ 。按照样本均值由 $(2, 2)^T \rightarrow (2.5, 2.5)^T \rightarrow (3, 3)^T \rightarrow (3.5, 3.5)^T \rightarrow (4, 4)^T$ 的顺序以协方差矩阵 Σ_p 分别产生 5 组数量为 400 的二维正态分布的训练样本集。按照正态分布 $\pm 3\sigma$ 的原则确定出式(8)中的常数 $k = 6.5$ 。图 3(a) 所示为初始样本集和当前样本集

可能性分布图。

从初始样本集出发,对 FBF 网络进行训练,应用训练后的 FBF 网络对随后的样本集进行分类,舍弃分类失败的样本(即 FBF 网络输出小于 0.5 的样本),将分类成功的样本作为 FBF 网络新的训练样本用于 FBF 的自学习,自学习后的网络再用于下一组样本的分类。重复上述自学习过程,直至到对所有 5 组样本均学习完。

图 3(b)、(c) 分别给出了遗忘因子 λ 为 0.998 时,自学习过程中期望的样本分类边界及样本聚类中心的变化图。为了对比方便,图中同时给出了只根据当前样本集进行非在线学习时,最后一组样本集的聚类边界以及 5 组样本聚类中心变化曲线。图 2(d) 给出了在线和非在线学习时 FBF 网络的实际分类边界与期望分类边界的对比。

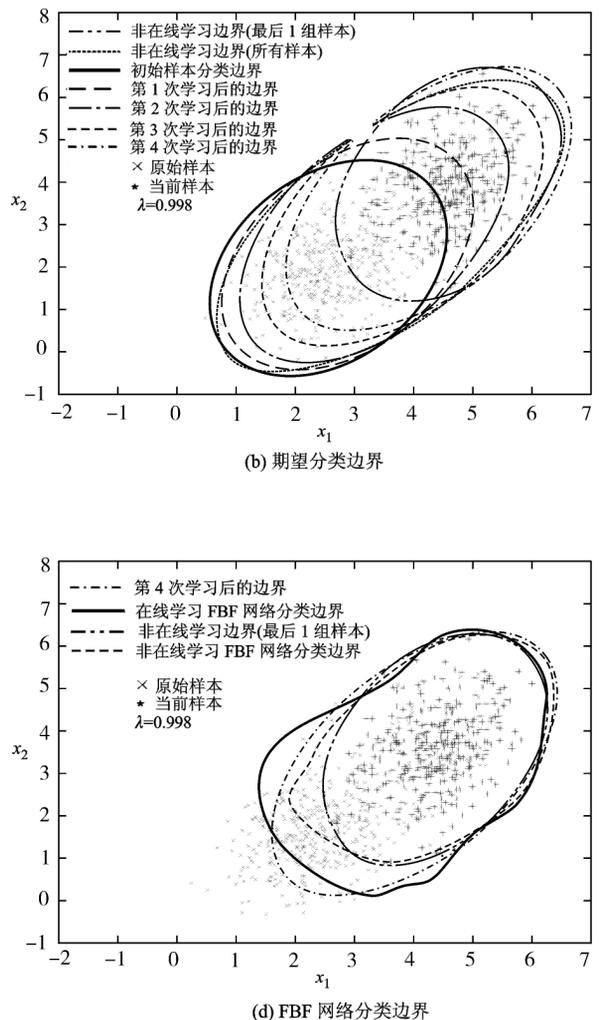
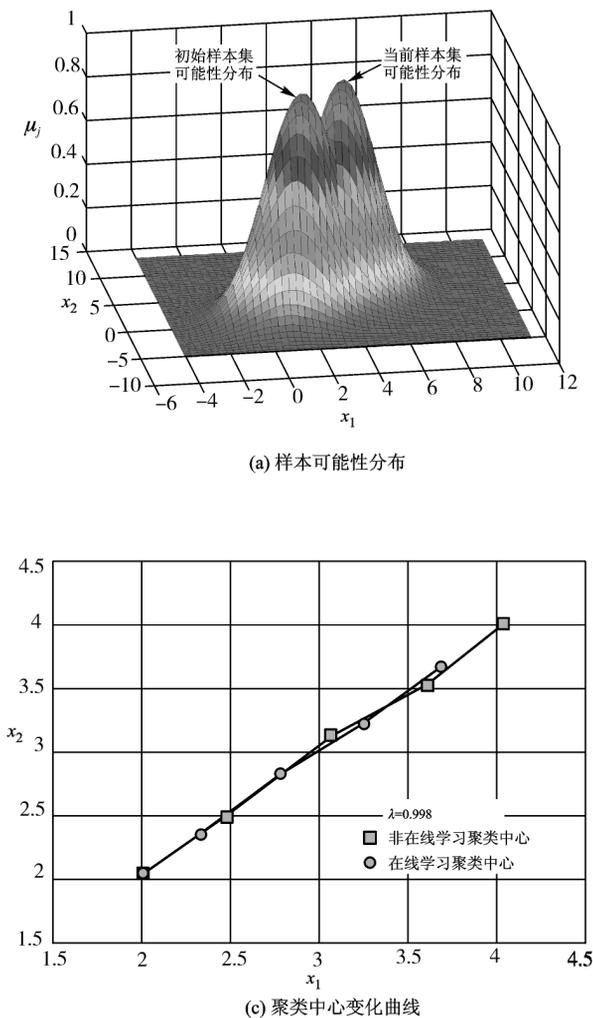


图 3 FBF 网络分类边界及聚类中心的变化图

Fig. 3 The cluster boundary and center of the fuzzy basis function network

由图 3 可见:

1) 随着新样本分组的逐步加入, FBF 网络的分类边界及聚类中心逐渐根据新样本集的分布向当前样本集靠近。

2) 通过在线跟踪自学习获得的当前分类边界(图中第 4 次学习后的边界)明显地比非在线跟踪学习涵括了更多的过去样本, 同时, 在线跟踪自学习方法可以逐步遗忘距离新聚类中心最远的样本, 这种可控的遗忘正是所期望的。

3) 若不采用在线跟踪学习, 仅根据当前的样本集进行训练, 将存在“突然遗忘”现象, 如图 3(d) 中最后一组样本集的非在线学习边界只包含了当前用于学习的样本集中的样本, 以往的类分布信息被遗忘; 而直接将 5 组样本集融合于一体用于网络的训练, 尽管无突然遗忘, 但新的分类边界过大(图 3(b) 中点虚线围成的边界), 影响分类的精确性。

4) 遗忘因子 λ 可用于控制遗忘的速度, 即 FBF 网络跟踪新分类边界的快慢。

试验结果表明, 在线跟踪自学习很好地解决了传统 NN 在自学习过程中存在的困难, 确保了 FBF 网络可以跟踪实际系统的变化过程, 始终维持较好的分类性能。

4.2 在线跟踪自学习算法的应用

将采用在线跟踪自学习算法的模块化 FBF 网络应用于某公司一台“H”型空压机组的故障诊断, 该机组收集到不平衡故障样本 148 个、油膜涡动样本 86 个、紧固件松动样本 76 个。取故障征兆为 9 个频段(表 1)的振幅分布特征和轴心轨迹特征(椭圆、内 8 形、紊乱等), 各故障样本的轴心轨迹特征根据文献[9]提出的基于 Zernike 不变矩的轴心轨迹识别方法获得。

表 1 基于频谱和轴心轨迹特征的初始故障聚类中心

Table 1 Initial fault cluster center with the spectrum and shaft orbit features

故障类别	聚类中心											
	(0.01 ~ 0.39)f	(0.40 ~ 0.49)f	0.50f	(0.51 ~ 0.99)f	1f	2f	(3 ~ 5)f	奇数倍 f	>5f	椭圆	内 8	紊乱
平衡	0.016 1	0.036 0	0.072 9	0.062 9	0.656 4	0.007 2	0.068 2	0.044 5	0.035 9	0.951 8	0.139 8	0.144 3
油膜涡动	0.013 9	0.054 3	0.225 7	0.061 2	0.566 7	0.004 2	0.037 8	0.021 3	0.014 7	0.145 4	0.956 3	0.137 9
松动	0.224 7	0.151 2	0.128 8	0.079 6	0.190 2	0.014 4	0.097 1	0.065 3	0.048 7	0.120 8	0.145 9	0.948 0

采用图 3 所示的模块化 FBF 网络结构, 每类故障分别通过一个 FBF 网络实现其分类边界的逼近, 每个 FBF 网络仅根据属于自己所识别故障类型的样本进行训练。将故障样本按照时间顺序一分为二, 前者作为训练样本, 后者用于 FBF 网络的自学习。表 1 和表 2 分别给出了各故障的初始聚类中心和经过在线跟踪自学习后的聚类中心。表 3 给出了

FBF 网络的识别结果, 可以看出每类网络对不属于所对应故障类别的样本都能正确拒绝接受, 而对属于所对应故障类别的样本, 被拒绝的样本数很少(分别为 3, 4 和 1), 识别成功率均达到 90% 以上。将经自学习后的 FBF 网络用于识别, 成功率均达到 100% (表略), 从一个侧面验证了所提方法的可行性和有效性。

表 2 基于频谱和轴心轨迹特征的故障自学习后的聚类中心

Table 2 Fault cluster center with the spectrum and shaft orbit features after self-learning

故障类别	聚类中心											
	(0.01 ~ 0.39)f	(0.40 ~ 0.49)f	0.50f	(0.51 ~ 0.99)f	1f	2f	(3 ~ 5)f	奇数倍 f	>5f	椭圆	内 8	紊乱
不平衡	0.019 9	0.044 3	0.062 6	0.054 5	0.656 9	0.005 7	0.069 8	0.054 3	0.032 1	0.949 4	0.142 4	0.146 7
油膜涡动	0.013 9	0.067 6	0.223 7	0.062 4	0.555 6	0.003 9	0.036 8	0.021 4	0.014 7	0.146 1	0.957 6	0.136 6
松动	0.214 9	0.156 1	0.122 0	0.087 8	0.224 3	0.011 1	0.080 7	0.058 3	0.044 7	0.134 0	0.147 9	0.941 0

表3 FBF网络诊断结果

Table 3 Diagnosis result of the FBF network

网络类别	被拒绝的测试样本数目			诊断成功率/%	正确拒绝率/%
	不平衡(74)*	油膜涡动(43)	紧固件松动(38)		
不平衡	3	43	38	95.9	96.3
油膜涡动	74	4	38	90.7	96.4
紧固件松动	74	43	1	97.4	99.1

* 括号内为各个故障的测试样本数目

5 结论

从分析 NN 的自学习功能入手,指出现有的 NN 自学习过程在实际应用中所存在的缺陷,诸如“突然遗忘”现象、训练样本的保存等。然后提出了解决这些缺陷的有效方法,即通过样本的协方差阵保存过去样本的信息及所包含故障的可能性分布信息,同时,产生新训练样本的期望输出时考虑到过去样本对之造成的影响,解决了 NN 训练过程中的“突然遗忘”问题。此外,为了克服计算样本均值和协方差矩阵需要保存所有故障样本的困难,提出了一种递推计算样本协方差阵的有效方法。数值仿真和在故障识别中的应用结果表明,所提出的方法是有效的。

参考文献

- [1] Fuessel D, Isermann R. Hierarchical motor diagnosis utilizing structural knowledge and a self-learning neuro-fuzzy scheme [J]. IEEE Trans on Industrial Electronics, 2000, 47(5): 1070 ~ 1077
- [2] 戈志华,牛玉广,李如翔,等. 汽轮发电机组振动故障诊断系统自学习的研究[J]. 中国电机工程学报,2000,20(5):76~79
- [3] French R M. Catastrophic forgetting in connectionist networks [J]. Trends Cognitive Sci, 1999, 3(4): 128 ~ 135
- [4] Wang L X, Mendel J M. Fuzzy basis functions, universal approximation, and orthogonal least-squares learning [J]. IEEE Trans on NNs, 1992, 3(5): 807 ~ 814
- [5] 刘慧林,冯汝鹏,胡瑞栋,等. 模糊系统作为通用逼近器的 10 年历程[J]. 控制与决策,2004,19(4): 367 ~ 371
- [6] Haykin S. Neural Networks: A Comprehensive Foundation (second edition, 影印版)[M]. 北京:清华大学出版社,2001. 256 ~ 317
- [7] Karayiannis N B, Bezdek J C, Pal N R, et al. Repairs to GLVQ: a new family of competitive learning schemes [J]. IEEE Trans on Neural Networks, 1996, 7(5): 1062 ~ 1071
- [8] 钟秉林,黄仁,贾民平,等. 机械故障诊断学(第2版)[M]. 北京:机械工业出版社,2002
- [9] 许飞云. 基于行为的智能化故障诊断理论和方法的研究[D]. 南京:东南大学博士学位论文,1996

Research on An On-line Tracking Self-learning Algorithm for Fuzzy Basis Function Neural Network

Xu Feiyun, Zhong Binglin, Huang Ren

(School of Mechanical Engineering, Southeast University, Nanjing 210096, China)

[Abstract] An on-line tracking self-learning algorithm for fuzzy basis function (FBF) neural network classifier is proposed in this paper. Based on the previous possibility distribution of the clusters, which is kept within the sample mean and covariance matrix with forgetting factor, a strategy for constructing the target output of the new training sample set is given. With the new sample set the FBF network can be trained to track the variable clustering boundary. Meanwhile, a recursive algorithm for computing the sample mean and covariance matrix with forgetting factor is also proposed to overcome the difficult of storing the vast old training samples. The proposed method is used for fault recognition of the rotating machinery, and the results show that it is feasible and effective.

[Key words] fuzzy basis function; self-learning; fault diagnosis