

文章编号:1671-6833(2005)04-0089-04

改进的RBF 网络训练方法在故障诊断中的应用

孟雅俊, 黄士涛, 姬中华

(郑州大学机械工程学院, 河南 郑州 450002)

摘 要: 目前已有的几种 RBF 网络训练方法对于含有随机噪声的复杂样本训练速度过慢且分类性能不稳定, 依据相对熵最小原理, 提出了一种改进的 RBF 网络训练方法——输出-输入聚类法. 利用此方法对旋转机械故障样本进行训练, 并与其它方法进行了比较, 结果表明, 此训练方法用时短, 网络结构简单, 受噪声影响小. 将所创建网络应用于故障诊断, 实例表明, 此方法训练的网络诊断结果准确, 在故障诊断中具有良好的应用前景.

关键词: RBF 网络; 正交最小二乘法; 输入聚类法; 输出-输入聚类法

中图分类号: TH 133; TP 183 **文献标识码:** A

0 引言

对于大型旋转机械等复杂设备的运行状态, 很难建立精确的模型来描述, 因此对其故障诊断利用传统的模式分类技术很难奏效. 近年来, 人工神经网络的发展为解决这个问题提供了有效途径, 其中, 最常用的是BP 网络与RBF 网络.

BP 网络的优点是寻优具有精确性, 但同时存在一些缺点, 主要是易陷入局部极小、收敛速度慢和引起振荡效应等. RBF 网络具有唯一最佳逼近点的优点, 从而克服了局部极小问题^[3]. 且权向量可分层独立训练, 从而具有泛化能力强、训练速度快的优点. RBF 网络的训练依据不同的数据处理理论形成了多种方法: 正交最小二乘法、遗传算法、误差反向传播法、Kohonen 自组织映射法、聚类法等. 其中, 聚类训练法始于Ukrainec 等在 1991 年提出的最大数学期望聚类法^[3], 其依据是数理统计理论中参数的最大似然估计法. 后来又提出了硬C-均值聚类法、模糊C-均值聚类法、K-均值聚类法以及最近邻聚类法等多种聚类训练方法. 这些聚类训练方法的共同点是: 只对神经网络的输入样本进行无监督的聚类, 因而对于复杂样本训练速度慢而且分类性能不稳定, 为解决此问题, 我们进行了深入研究.

1 RBF 网络结构

RBF 网络结构如图 1 所示.




图 1 RBF 网络结构
Fig. 1 Structure of RBF network

设网络输入层、隐含层、输出层节点数分别为 n, k, m , 输入向量为 $X=[x_1, x_2, \dots, x_n]^T$, 隐含层的输出向量为 $\Phi=[\phi_1, \phi_2, \dots, \phi_k]^T$, 输出层的输出向量为 $C=[c_1, c_2, \dots, c_m]^T$. W 为输出层至隐含层神经元之间的连接权值, B 为输出层阈值, 则 RBF 网络输出总的数学表达式为

$$c_j(X) = \sum_{i=1}^k w_{ji} \phi_i(X) + b_j, j=1, 2, \dots, m \quad (1)$$

式中: $\phi(\cdot)$ 为 RBF 函数, 一般为高斯函数, 即

$$\phi_i(X) = \exp(-\|X - \mu_i\|^2 / \sigma_i^2) \quad (2)$$

式中: μ_i 与 $\sigma_i(i=1, 2, \dots, k)$ 分别代表隐含层第 i 个中心向量与宽度, 一般称此二者为中心参数.

收稿日期:2005-07-10; 修订日期:2005-10-10
基金项目:河南省重大科技攻关项目(0122022000)
作者简介:孟雅俊(1973-),女,山西文水人,郑州大学硕士研究生,主要研究方向为远程故障诊断.

宽度 σ 主要用来调节 RBF 神经元的作用范围, 它对于网络性能影响极大. 假设在输入向量 \mathbf{X} 中混入噪声向量 $\Delta = [\delta_1, \delta_2, \dots, \delta_n]^T$, 则可得

$$\phi(\mathbf{X} + \Delta) / \phi(\mathbf{X}) = \exp(-\Delta^T(2\mathbf{X} + \Delta - 2\mu_i) / \sigma_i^2) \quad (3)$$

若其余参数确定, 则 σ 取值越大, 式 (3) 的计算结果越接近 1, 即网络隐含层输出受噪声影响越小. 但如果 σ 取值太大则会使相邻神经元产生过大交叠, 使网络无法进行有效的模式分类.

2 RBF 网络训练方法的改进策略

RBF 网络需要训练的参数有两类: 一类为隐含层参数, 共包括神经元个数 k 及其中心参数; 一类为输出层参数, 共包括权值 \mathbf{W} 与阈值 \mathbf{B} . 目前常用的隐含层中心参数的确定方法为输入聚类法和正交算法. 正交算法需要根据经验选择一个宽度作为隐含层各中心的宽度^[4,3], 因而可能会出现宽度选择过大或过小的情况^[9]. 输入聚类法中隐含层中心参数通过对各聚类分析得出^[9], 一般不会出现宽度过大或过小的问题, 但训练时间较长.

网络训练的目的在于网络输出能在某种指标下逼近期望输出, 在输入聚类算法基础上考虑输出样本的作用会对算法带来很大的改进. 据此, 笔者提出了一种输出-输入聚类训练方法.

2.1 输出-输入聚类法原理

设变量 L 有且只有 m 种可能取值, 分别为 l_1, l_2, \dots, l_m , 记 c_i 为 $L = l_i$ 的概率 ($i = 1, 2, \dots, m$), 则可得 $\sum_{i=1}^m c_i = 1$, 令 $\mathbf{C} = [c_1, c_2, \dots, c_m]^T$. 若影响 L 取值的条件有 n 个, 这些条件的取值记为 x_1, x_2, \dots, x_n , 令 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$.

取一定数量 (N 个) 的输入向量组成输入矩阵 \mathbf{P} , 与其相应的输出向量组成输出矩阵 \mathbf{T} . 将输出矩阵 \mathbf{T} 的第 j 列记为 \mathbf{C}_j ($j = 1, 2, \dots, N$), 输入矩阵 \mathbf{P} 的第 j 列记为 \mathbf{X}_j . 如果在 \mathbf{C}_j 向量中第 i 行取值最大, 则可近似地认为当条件为 \mathbf{X}_j 时变量取值为 l_i . 将 $\mathbf{C}_j, \mathbf{X}_j$ 分别归入第 i 类输出与输入样本. 对所有样本进行分类, 则可得输入样本分类 p_1, p_2, \dots, p_m , 及相应的输出样本分类 t_1, t_2, \dots, t_m . t_i 的第 i 行 (记为 y_i) 取值最大, 即当输入为 p_i 时, 变量最有可能取值为 l_i . 根据 p_i 及 y_i 取值可求得变量取值为 l_i 的分布 q_i .

由以上分析可知 RBF 网络训练的目的就是要实现由若干个高斯分布函数线性组合形成的实际分布 r_i 到理想分布 q_i 某种程度的逼近 ($i = 1,$

$2, \dots, m$).

根据 Kullback-Liebler 方程, 两个分布 r_i 与 q_i 的接近程度可用相对熵来衡量^[9]:

$$E(r_i, q_i) = KL(r_i \parallel q_i) = \sum_j i(j) \ln \left(\frac{r_i(j)}{q_i(j)} \right) \quad (4)$$

由上式可知, 只有当 $r_i = q_i$ 时, 相对熵取得最小值 0, 其它所有情况下, 相对熵均为正值并随着两个分布之间重合部分的减小而增大.

为了得到满足设计要求的网络, 可以先对各类输入样本 p_i 进行聚类, 求得隐含层中心向量及宽度, 再通过求解线性方程求得输出层参数, 就可以得出实际分布与理想分布间的相对熵 E_i ($i = 1, 2, \dots, m$), 当相对熵取值小于某一值时, 即可认为网络训练成功.

2.2 具体步骤

利用归一化后输入数据 \mathbf{P} (n 维) 及相应理想输出 \mathbf{T} (m 维), 构造满足设定精度的 RBF 神经网络具体步骤如下:

(1) 给定允许误差 ϵ 与隐含层最大神经元数量 m_n ;

(2) 将 \mathbf{T} 按各列最大值所在行取值分为 m 类;

(3) 将 \mathbf{P} 按相应 \mathbf{T} 的类别分成 m 类;

(4) 对 \mathbf{P} 按其所属类别求平均值与平方差, 得到其初始中心 o_1, o_2, \dots, o_m , 方差 v_1, v_2, \dots, v_m , 将初始中心作为隐含层的中心向量 $\mu_1, \mu_2, \dots, \mu_m$;

(5) 计算隐含层中心宽度 $\sigma = fv$ ($i = 1, 2, \dots, n$), 其中 f 为一系数, 用以调节各聚类中心的作用宽度;

(6) 将 μ 与 σ 代入式 (1) 求得隐含层输出 Φ ;

(7) 利用最小二乘算法求输出层参数 \mathbf{W}, \mathbf{B} ;

(8) 将 \mathbf{W}, \mathbf{B} 代入 (2) 式求得实际输出 \mathbf{Y} ;

(9) 求实际输出 \mathbf{Y} 与理想输出 \mathbf{T} 之间的误差, 若小于允许误差 ϵ , 或达到最大神经元数量 m_n , 则训练结束, 否则, 计算各类输出的绝对误差平均值, 得到绝对误差平均值最大的输出所属的分类, 对其相应类别的输入增加中心数量进行聚类, 将新产生的聚类中心与此前其它各类相应的中心一起作为隐含层的中心向量 μ , 计算属于新聚类的输入样本的方差并与此前其它各类的方差一起组成方差向量, 而后转至第 (5) 步进行新一轮的计算.

为验证此方法的有效性及其优越性, 本文将其应用于旋转机械故障诊断, 并与其它训练方法进行了比较.

3 在旋转机械故障诊断中的应用

3.1 标准样本的建立

对于大型旋转机械,通常取其振动信号,通过时域、频域分析来识别故障.参考文献[5],建立标

准样本如表 1 所示,其中输入样本 6 种常见故障振动信号在 9 个频段上的能量比值,网络输出值第 n 维的取值为相应第 n 种故障发生的概率($n = 1, 2, \dots, 6$).

表 1 旋转机械 6 种典型故障的学习样本

Tab.1 Standard study samples consist of 6 typical rotary faults

故障样本	输入									输出					
	$0.0f \sim 0.3f$	$0.4f \sim 0.49f$	$0.5f$	$0.5f \sim 0.99f$	$1.f$	$2.f$	$3.f \sim 5.f$	奇数倍 f	$>5f$						
不平衡	0	0	0	0	0.9	0.05	0.05	0	0	1	0	0	0	0	0
不对中	0	0	0	0	0.4	0.5	0.1	0	0	0	1	0	0	0	0
油膜涡动	0.1	0.8	0	0.1	0	0	0	0	0	0	0	1	0	0	0
油膜振荡	0	0	0.9	0	0	0	0	0	0.1	0	0	0	1	0	0
转子横向裂纹	0	0	0	0	0.2	0.4	0.2	0.2	0	0	0	0	0	1	0
轴承座松动	0.9	0	0	0	0	0	0	0.1	0	0	0	0	0	0	1

说明 f 为转子的工作频率.

3.2 网络的训练及性能验证

从表 1 中对 6 种标准样本各取 100 个,在其输入样本中混入一定比例的噪声作为网络输入样本三次实验分别为 27.691, 21.609, 18.167dB, 标准输出样本不做变化作为网络的输出样本,从而构造出网络的训练样本集.用同样的方法构造出 600 个样本用于网络性能验证.利用 MATLAB 编程,分别建立 BP 网络与三种采用不同训练方法的 RBF 网络,其中对 BP 网络训练采取有动量和自适应学习率的梯度下降法.设定最多神经元数为 50,误差平方和为 3,3 种信噪比下的误差收敛情况见图 2.

将验证样本输入训练好的网络,根据各网络对验证样本的诊断结果统计得出误诊率.各网络性能对比见表 2.

表 2 各网络在不同信噪比下的性能比较

Tab.2 Comparison of different networks under different SNR

性能参数	信噪比/dB	BP 网络	RBF 网络		
			正交训练	输入聚类	输出-输入聚类
训练时间/s	27.691	5.087	1.722	1.280	0.730
	21.608	14.201	2.413	11.174	0.763
	18.167	20.381	8.272	15.616	0.851
神经元数量	27.691	6	6	6	6
	21.608	6	11	9	6
	18.167	6	46	10	6
误诊率/%	27.691	1.117	0.500	0.167	0.167
	21.608	4.833	1.833	0.500	0.333
	18.167	15.667	13.333	3.167	2.833






图 2 不同信噪比下各网络的误差收敛曲线
Fig.2 Error convergence curve of different networks under different SNR

可以看出,随着信噪比的减小,各网络所需训练时间都有所延长,误诊率也逐渐加大.其中,BP 网络所需训练时间最长.正交方法训练 RBF 网络时间较短,但神经元数量最多,当信噪比为 18.167 dB 时,神经元达到 46 个.后两种网络,诊断精度大致相当,后者所需神经元少于前者,而且后者所需训练时间受噪声的影响远远小于前者及

其它网络.

3.3 故障诊断实例

从故障实例库中取一转子不平衡实例,提取其表 1 要求的 9 个频带上能量比为 $P=[0.066\ 1\ 0.006\ 5\ 0.010\ 7\ 0.043\ 6\ 0.672\ 1\ 0.047\ 2\ 0.069\ 9\ 0.067\ 0\ 0.016\ 8]^T$,将 P 输入已建立的网络,输出结果见表 3.

表 3 各网络的分类情况比较

Tab. 3 classification result d compared of different networks

分类	网络输出值	误差
BP 网络	[1.051 -0.028 -0.015 4 -0.024 0.007 9 0.005 4 0.005 4] ^T	0.004 2
正交法	[1.065 2 -0.041 9 -0.017 8 -0.007 1 -0.008 7 0.010 3] ^T	0.006 6
输入聚类	[0.994 5 -0.004 1 0.001 3 0.001 6 0.005 0 0.001 6] ^T	7.9e-5
输出一输入聚类	[0.995 1 -0.004 1 0.001 0 0.001 8 0.004 8 0.001 4] ^T	7.9e-5

从表 3 可知,各网络都做出了较为准确的判断,其中输出一输入聚类法训练的网络诊断效果最佳.

4 结束语

笔者提出了一种对输出一输入样本聚类确定 RBF 隐含层中心向量,进而自组织确定中心宽度的隐含层参数训练方法.以旋转机械故障样本作为试验数据,用本方法对 RBF 网络进行训练及性能验证,与 BP 网络及其它方法训练的网络进行比较,结果表明,此方法训练时间短,网络结构简单,受噪声影响小,故障诊断实例也显示了其优越性,此方法在故障诊断领域有良好的应用前景.

参考文献:

[1] BROOMHEAD D S , LOWE D . Multivariate functional interpolation and adaptive networks [J] . Complex Systems , 1988 , (2) : 321~355 .

[2] BIANCHINI M , FRANCONI P , GORI M . Learning without local minima in radial basis function networks [J] . IEEE Transactions on Neural Networks , 1995 , (3) : 749~755 .

[3] UKRAINEC M , HAYKIN . Signal processing with radial basis function networks using expectation-maximization algorithm clustering [A] . SPIE . The International Society for Optical Engineering [C] . Bellingham SPIE , 1991 . 529~539 .

[4] POGGIO T , GROSSI F . Network for approximation and learning [J] . Proceedings of the IEEE , 1990 , 78 (9) : 1481~1497 .

[5] 王志鹏 . RBF 网络的旋转机械故障诊断方法 [J] . 大连理工大学报 , 2001 , 41 (6) : 696~699 .

[6] MASHOR M . Improving the performance of K-means clustering algorithm to position the centres of RBF network [J] . International Journal of the Computer , the Internet and Management , 1998 , (2) : 23~31 .

[7] DUMTRESCU D , SIMON KAROLY . A new dynamic evolutionary clustering technique application in designing RBF network [J] . INFORMATICA , 2003 , (8) : 45~52 .

An Improved Training Method of RBF Network and its Application to Fault Diagnosis

MENG Ya-jun , HUANG Shi-tao , JI Zhong-hua

(School of Mechanical Engineering , Zhengzhou University , Zhengzhou 450002 , China)

Abstract : The key to the training of a radial basis function (RBF) network will determine the parameters of hidden layers of the network . There are a number of training methods of RBF networks , but they have the shortcomings in that the training speeds are too slow and the ability to classify is unstable , particularly for such complicated sampling data as with random noise . To overcome these shortcomings , an improved training method of RBF networks , the method of output-input cluster based on the minimum entropy theory is presented in the paper . The sample data of a rotary machine indicates that the training time by using the method is shorter ; the network structure is simpler and the influence of random noise is less than that by using other methods . A fault diagnosis example illustrates the excellent performance of the algorithms .

Key words : RBF network ; orthogonal least square ; input cluster ; output-input cluster