

轴承故障的智能诊断方法*

张苗苗

方敏

谢剑英

(上海交通大学自动化系 200030) (合肥工业大学电气工程系) (上海交通大学自动化系)

摘要 总结了轴承故障诊断的模糊规则, 并把这些规则映射到模糊神经网络, 提高了诊断的智能性。提出了部分层学习算法, 并推导出隶属度函数的参数学习算法, 改善了诊断规则和学习性能。所研制的诊断系统在对轴承故障的诊断中取得了满意的结果。

关键词 故障诊断, 模糊神经网络, 学习

分类号 TP 306

Intelligent Diagnosis Method of Bearing Fault

Zhang Miaomiao

Fang Min

Xie Jianying

(Shanghai Jiaotong University) (Hefei University of Technology) (Shanghai Jiaotong University)

Abstract Fuzzy rules of bearing fault diagnosis are summarized and mapped into fuzzy neural network, which improves intelligence of bearing diagnosis. Part-layer learning algorithm is presented. Meanwhile, parameter learning algorithm of the membership function is developed. Both of them improve diagnostic rules as well as learning properties. As to bearing fault, satisfied diagnosis results are obtained by means of the developed diagnostic system.

Key words fault diagnosis, fuzzy neural-network, learning

1 引言

在机械设备中, 一系列运动产生的动态力将导致机械振动和冲击。这些强迫振动可能是线振动, 也可能是角(扭转)振动, 或是线振动和角振动的合成振动。能够产生这些振动的部件很多, 其具体振动形式和故障形式也各不相同。其中轴承类故障在各种故障形式中所占比例很大, 据统计, 旋转机械约 30% 的故障是由滚动轴承的损伤造成的^[1]。因此, 轴承类故障的监测与诊断一向是机械故障诊断中的重要内容之一。

本文将模糊规则和神经网络结合起来应用于轴承的故障诊断, 网络的权值代表一定的意义, 不必通过学习就可把先验知识直接给网络连接权赋值, 并可通过学习故障样本来修改和完善诊断规则, 具有很大的灵活性。由于模糊神经网络的每一层具有一定的物理意义, 因此可根据实际要求进行部分层学习或隶属度函数参数学习, 从而减小了学习时间。

2 轴承故障诊断的知识表示

2.1 诊断参数的选取

由故障机理分析可知, 如果某一故障产生, 则其故障特征频率基频和谐频点能量会有较大增加, 且不同特征频率处的谱值变化对故障影响的程度也不同。因为受监测装置、转速等条件的影响, 尽量不以绝对值作为异常诊断的依据, 而要与初始值或正常值进行比较, 用其比值作为监测参数来进行诊断。为此, 诊断的监测参数定义为^[2]

$$FS(f_i) = \frac{S_T(f_i)}{S_R(f_i)} \quad (1)$$

其中, $S_T(f_i)$ 为相对于 f_i 的待检状态故障谱值, $S_R(f_i)$ 为相应于 f_i 的正常状态功率谱值。二者的比值可消除故障在传播过程中由于经过较多结合面而产生的能量衰减效应。由于某一监测量只能反映某一方面的故障信息, 具有一定的局限性, 所以实际中仅靠一个参数作为判断依据是不够的, 应综合多种参数并赋予不同参数以不同的权值, 这样才合理而可靠。由此产生了诊断知识的模糊规则, 并对各模糊

条件施以不同的权重大小,通过规则的隶属度大小来决定故障的可信度。

2.2 轴承故障诊断的模糊规则

经过分析,我们总结了轴承的外滚道损伤、内滚道损伤、滚动体损伤这3种故障诊断的模糊规则表示,其诊断规则分别如表1~3所示。其中,空格表示无相应的规则或不可能事件, f_o, f_i, f_b 分别表示外圈滚道,内圈滚道和滚动体的故障特征频率。

表1 外滚道损伤诊断规则

轴承外滚道损伤		$2f_o$ 处相对幅值比		
		大	中	小
f_o 处	大	大		中
相对	中		中	
幅值比	小			小

表2 内滚道损伤诊断规则

轴承内滚道损伤		$2f_i$ 处相对幅值比		
		大	中	小
f_i 处	大	大		中
相对	中		中	
幅值比	小			小

表3 滚动体损伤诊断规则

轴承滚动体损伤		$2f_b$ 处相对幅值比		
		大	中	小
f_b 处	大	大		中
相对	中		中	
幅值比	小			小

模糊规则的应用意味着通过专家知识来决定隶属度函数,并实现对故障程度的判决。它可很好地处理系统中的多样性、随机性和非线性。但由于缺乏学习功能,则存在着系统性能受专家知识的影响,确定隶属度函数需大量的仿真实验,规则修改不便等缺点。

当外圈固定时,通过滚动轴承运动学分析,可求出内外圈滚道及滚动体的故障特征频率^[1,3]

$$\begin{cases} f_o = \frac{z}{2} \left[1 - \frac{d}{D} \cos \alpha \right] f_a \\ f_i = \frac{z}{2} \left[1 + \frac{d}{D} \cos \alpha \right] f_a \\ f_b = \frac{D}{2d} \left[1 - \left(\frac{d}{D} \cos \alpha \right)^2 \right] f_a \end{cases} \quad (2)$$

其中, $f_a = 60/n$ 为轴频, n 为轴的转速(rpm), z 为滚动体个数, d 为滚动体直径, D 为轴承节径即滚动体中心所在圆的直径, α 为接触角。

是从理论上推导出来的,而实际轴承的各几何尺寸会有误差,加上轴承安装后的变形,使实际频率与计算所得频率会有某些出入。所以在频谱图上寻找各特征频率时,需在计算频率值的左右寻找其近似值来进行诊断。

2.3 故障诊断的模糊神经网络

根据模糊规则可建立相应的诊断网络。如果事先不能确定模糊规则,则可根据竞争学习算法从训练数据中自动提取模糊规则,并调整节点间的连接。如果某个规则节点输掉竞争,则此连接无效,说明这条规则不存在,其相应的连接应删掉,从而找到存在的模糊规则。通过机理分析或经验知识,还可用竞争聚类方法获得诊断网络。根据前面的模糊诊断规则表,可将这些模糊规则映射到模糊神经网络(FNN)中,从而提高诊断的智能性。模糊规则可用网络的节点对象、连接权对象、连接结构等来翻译解释,它具有知识获取和学习能力。由于该网络可通过知识的表达和学习来记忆设备故障模式,然后用推理方式对故障进行诊断,所以是一种智能诊断网络。

考虑到输入参数的模糊化和输出参数的去模糊化,该模型共有5层,其中第2层为模糊化层,对输入值分别模糊化为大、中、小3种语言变量。各层节点的输入函数和输出函数可选取如下:

$$1) \quad S_i^{(1)} = u_i^{(1)}, x_i^{(1)} = f(S_i^{(1)}) = S_i^{(1)} \quad (3)$$

$$2) \quad S_i^{(2)} = \left\{ \frac{-(w_{ij}^{(2)} x_j^{(1)} - m_i^{(2)})^2}{(\sigma_i^{(2)})^2} \right\}$$

$$x_i^{(2)} = f(S_i^{(2)}) = \exp(-S_i^{(2)}) \quad (4)$$

其中 $m_i^{(2)}$ 和 $\sigma_i^{(2)}$ 表示第2层第 i 个节点的输入隶属度函数的中心值和宽度。

$$3) \quad S_i^{(3)} = \min\{w_{ij}^{(3)} x_j^{(2)}, \dots, w_{ik}^{(3)} x_k^{(2)}\}$$

$$x_i^{(3)} = f(S_i^{(3)}) = S_i^{(3)} \quad (5)$$

$$4) \quad S_i^{(4)} = \min\left[1, 0, \sum_{j=1}^{N_3} w_{ij}^{(4)} x_j^{(3)}\right]$$

$$x_i^{(4)} = f(S_i^{(4)}) = S_i^{(4)} \quad (6)$$

$$5) \quad S_i^{(5)} = \sum_{j=1}^{N_4} w_{ij}^{(5)} x_j^{(4)}$$

$$x_i^{(5)} = f(S_i^{(5)}) = S_i^{(5)} \bigg|_{i=1}^{N_4} x_i^{(4)} \quad (7)$$

其中, S 和 X 分别表示输入和输出函数, W 为权值, N_i 表示第 i 层的节点数。与规则表1相对应的FNN的拓扑结构如图1所示。表2和表3的FNN结构同图1,只是输入分别为 $FS(f_i)$, $FS(2f_i)$ 和 $FS(f_b)$, $FS(2f_b)$ 。




图 1 轴承外滚道损伤的 FNN 结构

这些网络的输入值均为一定特征频率处的相对幅值比的归一化值, 权值一般初始为 1。节点对象、连线对象保存了一定的知识, 这些知识包括隶属度函数的有关参数, 如中心值、宽度, 节点的阈值、输入输出函数, 节点、连线之间的连接信息等。所以该网络可利用自身存贮的诊断知识实现模糊推理。

3 网络的模糊推理

在网络的模糊诊断中, 隶属度函数是一个在 $[0, 1]$ 区间可连续取值的函数, 取值的大小反映了征兆和故障隶属其真值的可能性大小。神经网络进行模糊诊断是通过网络来传递不确定性。首先进行从特征信号到网络输入模式的模糊化, 然后完成输入模式到输出模式之间的模糊映射, 最后实现从输出模式到结论的去模糊转化。其诊断推理过程如图 2 所示, 其中学习算法用来修改和完善诊断规则。




图 2 模糊神经网络诊断推理

4 网络学习

对于 BP 网络, 通常采用梯度下降法调整权值。BP 算法是按某一时刻的负梯度方向, 从输出层逐层反向计算各层的权值, 一直到输入层。这种算法对各层的权值均做修改, 可称为全部层学习, 学习计算量大。对于模糊神经网络, 若启动全部层学习将使权值改变, 失去实际的物理意义, 并有可能使学习不收敛, 发生振荡。为此本文提出部分层学习, 并且针对模糊神经网络的隶属度函数, 给出中心值和宽度学习算法。修正学习参数采用动量项方法, 它实际上相

当于阻尼项, 有利于减小学习过程的振荡, 改善收敛性^[4]。

4.1 部分层学习

该算法可根据实际需要网络的某一层或某几层进行学习。仍采用误差反传的原则, 当前传到某一层时, 如该层需要学习则对该层的权值进行修改; 否则不做修改, 但该层的误差需通过网络的内部连接传送到上一层。对于模糊神经网络, 一般第 4 层的权值是学习的主要参数, 可采用部分层学习算法, 只选择第 4 层的权值进行修正。修正的目的是改善模糊规则间的相对重要性, 使重要规则的作用得以加强。

为保证收敛速率及一定的学习精度, 在引入动量项 η 的基础上, 采用了自适应学习率 α , 其调整方法如下

$$\alpha(k+1) = \begin{cases} 1.05\alpha(k), & E(k+1) < E(k) \\ 0.7\alpha(k), & E(k+1) > 1.04E(k) \\ \alpha(k), & \text{其它} \end{cases} \quad (8)$$

其中 E 为网络输出误差和。也可通过综合绝对误差和相对误差的作用来重新构造误差函数, 以提高样本学习精度^[5]。网络学习前的数据样本处理对网络的学习速度和精度具有明显的作用, 它主要包括评价和提取有效的数据变量、数据变换处理等步骤。

4.2 中心值和宽度的学习

对于模糊神经网络, 第 2 层为模糊化层, 输入隶属度函数有中心值和宽度两个参数, 它们是模糊化的关键。中心值、宽度的学习有利于调整诊断规则, 其算法如下:

设有 q 组学习样本, 期望输出为 $\hat{x}_{pi}^{(5)}$, 实际输出为 $x_{pi}^{(5)}$, $p = 1, 2, \dots, q, i = 1, 2, \dots, N_5, N_5$ 为第 5 层的节点个数。设 q 组样本的误差函数为

$$\begin{cases} E = \frac{1}{2} \sum_{p=1}^q \sum_{i=1}^{N_5} (x_{pi}^{(5)} - \hat{x}_{pi}^{(5)})^2 = \sum_{p=1}^q E_p \\ E_p = \frac{1}{2} \sum_{i=1}^{N_5} (x_{pi}^{(5)} - \hat{x}_{pi}^{(5)})^2 \end{cases} \quad (9)$$

1) 中心值修改

$$\frac{\partial E_p}{\partial m_i^{(2)}} = \frac{\partial E_p}{\partial x_{pi}^{(2)}} \frac{\partial x_{pi}^{(2)}}{\partial m_i^{(2)}} = -\delta_{pi}^{(2)} \frac{\partial x_{pi}^{(2)}}{\partial m_i^{(2)}}$$

$$\frac{\partial x_{pi}^{(2)}}{\partial m_i^{(2)}} = \frac{2(w_{ij}^{(2)} x_{pj}^{(1)} - m_i^{(2)})}{(\sigma^{(2)})^2}$$

$$\text{令 } D_i^{(2)} = \sum_{p=1}^q \delta_{pi}^{(2)} \frac{\partial x_{pi}^{(2)}}{\partial m_i^{(2)}} \quad (10)$$

则

$$m_i^{(2)}(k+1) =$$

$$m_i^{(2)}(k) + \alpha[(1 - \eta)D_i^{(2)}(k+1) + \eta D_i^{(2)}(k)] \quad (11)$$

其中, $i = 1, 2, \dots, N_2$, N_2 为第 2 层的节点个数, α 为学习率, η 为动量项因子。

2) 宽度修改(推导同前)

$$\frac{\partial E_p}{\partial \omega_i^{(2)}} = -\delta_{p_i}^{(2)} \frac{\partial \delta_{p_i}^{(2)}}{\partial \omega_i^{(2)}}$$

$$\frac{\partial \delta_{p_i}^{(2)}}{\partial \omega_i^{(2)}} = \frac{2(w_{ij}^{(2)} x_{pj}^{(1)} - m_i^{(2)})}{(\sigma_i^{(2)})^3}$$

$$\text{令 } D_i^{(2)} = \sum_{p=1}^q \delta_{p_i}^{(2)} \frac{\partial \delta_{p_i}^{(2)}}{\partial \omega_i^{(2)}} \quad (12)$$

则

$$\sigma_i^{(2)}(k+1) = \sigma_i^{(2)}(k) + \alpha[(1 - \eta)D_i^{(2)}(k+1) + \eta D_i^{(2)}(k)] \quad (13)$$

其中 $i = 1, 2, \dots, N_2$ 。

5 应用

根据以上诊断策略,我们研制了“基于模糊神经网络的轴承故障诊断系统”。实验中选取六安汽车齿轮箱总厂生产的 LC5T81 变速箱作为疲劳实验的对象,用轴承座上的加速度传感器测取其从开始到故障的信号。经过一定的谱分析处理,归一化后送入轴承外滚道损伤网络,输入节点值分别为 0.45, 0.95。经诊断推理后,输出节点值为 0.5039,表示隶属“轴承外滚道损伤”的故障程度为 0.5039。诊断结果符合以下规则:

IF f_0 处相对幅值比中 AND $2f_0$ 处相对幅值比大 THEN 轴承外滚道损伤故障程度中。

该结果验证了诊断思想的可行性。

6 结论

本文总结了承轴故障的模糊规则,并将其映射到神经网络中,使许多不确定的知识可以通过网络学习来获取,并能修改和完善已有的诊断规则。在此基础上提出了部分层学习算法,保证了某一层权值的实际物理意义,减少了学习计算量和学习时间。文中提出的诊断策略和学习方法在实际应用中取得了满意的结果。

参考文献

- 1 沈永福,高大勇. 设备故障诊断技术. 北京: 科学出版社, 1990. 108~114
- 2 张苗苗. 基于模糊神经网络的机械故障诊断系统. 合肥工业大学硕士学位论文, 1997. 12~13
- 3 丰田利夫. 设备现场诊断的开展方法. 北京: 机械工业出版社, 1985. 125~127
- 4 孙增圻. 智能控制理论和应用. 北京: 清华大学出版社, 1996. 135~136
- 5 刘增良, 刘有才. 模糊逻辑与神经网络——理论研究与探索. 北京: 北京航空航天大学出版社, 1996. 120~123

作者简介

张苗苗 女, 1971 年生。上海交通大学自动化系博士生。主要研究方向为智能控制, 混合动态系统。

方敏 女, 1950 年生。合肥工业大学电气工程系教授。主要研究方向为自适应控制, 人工智能与智能控制, 故障诊断。

谢剑英 男, 1940 年生。上海交通大学自动化系教授, 博士生导师。研究方向为复杂工业过程控制, 离散事件系统等。