

一种利用神经网络的故障模糊诊断系统*

吴蒙 贡璧 何振亚

(东南大学无线电工程系 南京 210018)

摘要 本文提出一种神经网络与模糊逻辑相结合的故障诊断系统,该系统包括2个方面:模糊推理模块和规则学习模块。模糊推理规则记忆在网络的记忆层中,记忆节点的激活水平则反映了输入矢量与已记忆规则的匹配程度;规则学习模块通过自组织聚类过程自动生成规则。作为该诊断系统的一个应用实例,模拟了旋转主轴的故障诊断试验。

关键词 故障诊断,神经网络,模糊推理,专家知识

1 引言

在故障诊断中,故障与征兆之间的关系往往是模糊的。这种模糊性既来自故障与征兆之间关系的不确定性,又来自故障与征兆在概念描述上的不精确性。因而诊断结果也必然是模糊的,故障存在或不存在往往没有明确的界限,而是服从某种隶属度函数分布。

解决模糊诊断问题的传统方法一般是根据专家经验在故障征兆空间与故障原因空间之间建立模糊关系矩阵,即把各征兆与各故障原因之间的因果联接强度表示于该模糊关系矩阵的各元中。目前常用的方法是各条模糊推理规则(以下简称规则)产生的模糊关系矩阵进行组合,或“与”或“并”,然而当经验规则较多时,这种组合倾向于使模糊关系矩阵中的各元的值趋于1,造成信息的较大损失。

人工神经网络技术目前已成为解决故障诊断问题的一种新的方法。然而在目前已提出的诊断模型中,或者通过前馈感知器网络的映射功能表征故障与征兆之间的某种非线性关系^[1],或者将因果型的诊断知识,存贮于一双层联想记忆网络中^[2],通过网络的状态演化(前馈或竞争),以0或1的水平激活表征故障的神经元,并没有考虑诊断结果客观存在的模糊性。即使在每个神经元上以[0,1]之间的值表示各征兆或各故障发生的程度大小(烈度),从本质上说这种诊断方法也仅是在做模式匹配,并没有有效地实现专家在诊断时的模糊推理思维,而且网络需要大量数值型的输入输出样本对来训练神经元间的联接强度。我们不知道网络究竟学习了什么,也不知道网络通过怎样的传输途径来达到一个输出结果。所以面临的是一个非规则型的数值计算黑箱,仅靠大量的输入数据并且记录所获得的输出响应来了解网络的动态特性。

1992-11-10收到,1993-02-17定稿

* 国家攀登计划认知科学(神经网络)重大项目资助

吴蒙 男,1963年生,博士,主要从事神经网络、自适应信号处理以及移动通信等方面的研究和开发工作。现在南京邮电学院无线电工程系,邮政编码:210003。

贡璧 女,1935年生,副教授,现主要从事信号处理、信息处理、振动理论等方面的研究工作。

何振亚 男,1922年生,教授,博士生导师,主要从事神经网络、自适应信号处理、多维信号处理以及图象压缩编码等方面的研究工作。

神经网络与模糊逻辑混合的思想方法近期已受到相当的关注,有大量文献^[3-6]已报道了这一方面的研究成果。文献[5]将规则存贮于一 BP 网络中;而文献[6]则提出一种模糊联想映射(FAM),将规则存于双层联想记忆网络中,一个网络记忆一条规则。在网络上进行基于规则的推理,既能发挥神经网络独特的数值计算功能,又能在数值计算中充分计及模糊逻辑的推理作用,我们认为这种推理方式必能较好地模拟人类专家在诊断过程中的模糊思维过程,获得对问题的合理解决。本文将探讨一种新的规则记忆网络模型,在此基础上建立一诊断系统,还要讨论基于自组织学习算法规则的获取方法。

2 预备知识

考虑具有下列形式的规则:

$$\text{IF } x = A_k \text{ AND } y = B_k, \text{ THEN } z = C_k,$$

并且假定有 m 条规则, $k = 1, 2, \dots, m$ 。规则中的前提条件和结论可以是数值型变量,也可以是语言型变量,而且还可不限于上述几个分量。对变量 x, y 和 z 我们可以根据实际情况假定它们的取值范围分别为 X, Y 和 Z , 并且根据精度要求量化这些取值范围,则分别有 $X = \{x_1, x_2, \dots, x_n\}$, $Y = \{y_1, y_2, \dots, y_p\}$ 和 $Z = \{z_1, z_2, \dots, z_q\}$, 如 Z 的取值范围为 $[0, 1]$, 则可量化为 $[0, 0.1, \dots, 0.9, 1.0]$ 。

模糊集 A_k, B_k 和 C_k 分别是变量 x, y 和 z 上的模糊子集, 可以对一个变量定义多个模糊子集, 它们分别定义了 X, Y 和 Z 中各元素对它们的隶属程度, 这种隶属程度可以用一个抽象函数来表示:

$$m_A: X \rightarrow [0, 1], \quad (1a)$$

$$m_B: Y \rightarrow [0, 1], \quad (1b)$$

$$m_C: Z \rightarrow [0, 1]. \quad (1c)$$

因此 A_k, B_k 和 C_k 实质上是一个隶属度值矢量:

$$A_k = (a_{1k}, a_{2k}, \dots, a_{nk}), \quad (2a)$$

$$B_k = (b_{1k}, b_{2k}, \dots, b_{pk}), \quad (2b)$$

$$C_k = (c_{1k}, c_{2k}, \dots, c_{qk}). \quad (2c)$$

这里 $a_{ik} = m_{A_k}(x_i)$, $b_{jk} = m_{B_k}(y_j)$ 和 $c_{lk} = m_{C_k}(z_l)$

这样对于模糊集 A_k, B_k 和 C_k 可分别用一组激活程度不同的神经元来表示。激活程度则分别由 a_{ik}, b_{jk} 和 c_{lk} 决定。每组神经元的个数分别为 n, p 和 q 。

3 诊断系统的构成

基于神经网络和模糊逻辑混合的模糊诊断系统由 2 个部分组成: 模糊推理模块和规则学习模块。图 1 为系统结构图。将规则以数值的方式存贮在模糊推理模块中, 建立起变量与变量之间的模糊关系。在规则学习模块中, 通过自组织学习过程, 以聚类产生规则。

3.1 模糊推理模块

模糊推理模块由一个 3 层网络构成, 即输入层、记忆层和输出层, 这种网络我们称为规则记忆网络, 如图 2 示。




图 1 系统结构




图 2 规则记忆网络

输入层的神经元个数为 $(n+p)$ ，对应于各个输入变量上的模糊子集维数之和。记忆层上的每个神经元对应于一条规则 M_k 。输入层上的每个神经元与记忆层上的每个神经元相连。输出层的神经元个数对应于各个输出变量上的模糊子集的维数之和，这里为 q 。记忆层和输出层上的神经元也相互连接。各层上的神经元之间不存在联接。整个网络是前馈的。

记忆层上的每个记忆节点分别接收 2 组来自输入层的信息，分别对应于每个输入变量。记每个记忆节点与输入层的连接权值矢量为

$$W_k = (w_{1k}, w_{2k}, \dots, w_{nk}, w_{(n+1)k}, w_{(n+2)k}, \dots, w_{(n+p)k}).$$

对于输入矢量 $IN = (a_1, a_2, \dots, a_n, b_1, b_2, \dots, b_p)$ ，记忆节点的激活水平 $e_k(M_k, IN)$ 用以度量输入矢量 IN 与记忆规则中的前提条件的匹配程度，我们以点积来测量两矢量的相似程度：

$$e_k(M_k, IN) = \{ \bigvee (a_1 \wedge w_{1k}, a_2 \wedge w_{2k}, \dots, a_n \wedge w_{nk}) \} \text{AND} \\ \{ \bigvee (b_1 \wedge w_{(n+1)k}, b_2 \wedge w_{(n+2)k}, \dots, b_p \wedge w_{(n+p)k}) \}. \quad (3)$$

这里符号 $\vee, \wedge$ 分别表示逻辑“或”和逻辑“与”。不同组间信息的组合按规则中前提条件的关系确定，这里是 AND。

因此每个记忆节点的输出就代表了每条记忆规则的激活程度。若记每个记忆节点与输出层的连接权值矢量为 $U_k = (u_{1k}, u_{2k}, \dots, u_{qk})$ ，则输出层上每个神经元的输出为

$$c_l = \sum_{k=1}^m (e_k \wedge u_{lk}), l = 1, 2, \dots, q. \quad (4)$$

输出矢量 $C = (c_1, c_2, \dots, c_l)$ 代表了某个隶属度分布，可以按下式把 C 解模糊为 1 单一的实输出值 $\bar{C}$ ：

$$\bar{C} = \frac{\sum_{l=1}^q z_l \cdot m_C(z_l)}{\sum_{l=1}^q m_C(z_l)}. \quad (5)$$

网络的记忆节点数等于规则数，且学习是非迭代型的，可以简单地将记忆的原型规则

对应地赋予每个权值,即

$$W_k = (A_k, B_k), U_k = (C_k), k = 1, 2, \dots, m \quad (6a)$$

或

$$w_{ik} = a_{ik}, w_{jk} = b_{jk}, u_{lk} = c_{lk}. \quad (6b)$$

网络的这种前馈方式可由如下逻辑关系表达:

$$\begin{aligned} F(IN) &= \sum_{k=1}^m \{[(a_1, a_2, \dots, a_n) \cdot A_k^T \circ C_k] \wedge [(b_1, b_2, \dots, b_p) \cdot B_k^T \circ C_k]\} \\ &= \sum_{k=1}^m \{(a_i \wedge C_k) \wedge (b_j \wedge C_k)\} \\ &= \sum_{k=1}^m \{\min(a_i, b_j) \wedge m_{C_k}(z_l)\} \\ &= (c_1, c_2, \dots, c_q). \end{aligned} \quad (7)$$

这里“ $\bullet$ ”表示逻辑运转($\vee, \wedge$);“ $\circ$ ”表示($\wedge$).

3.2 自学习模块

在建立一个诊断系统时,常常为推理规则的匮乏而困扰。然而在我们的诊断系统中,通过使用自组织聚类算法可以直接从输入输出样本数据中估计出规则,并且随着诊断系统的运行,出现系统未考虑到的情况时,通过学习算法也可以将新的规则及时扩充到系统中。

对于有 I 个输入变量、 J 个输出变量的推理系统,可以构造一输入输出乘积空积 R^{I+J} ,在此空间使用自组织聚类算法,估计出规则和规则的数目。其基本思想是一个聚类等于一条规则^[6]。

一般地,一个系统通常有 m 条规则,我们可能不知道 m 确切的值,但总可以任意假定系统有 H 条规则、 $H > m$ 。

自组织聚类算法通过竞争神经元之间的相互竞争来估计样本数据 $x(i)$ ($i = 1, 2, \dots$) 在 R^{I+J} 空间的分布的概率密度函数^[7]。假设在输入域有 $(I+J)$ 个线性神经元,在输出域有 H 个竞争神经元, $V_1, V_2, \dots, V_H$ 表示每个竞争神经元与输入神经元的联接权矢量,因此规则的产生可归纳为以下 5 步:

(1) 对联接矢量 V_i 随机地赋予初值。

(2) 对每个输入样本数据 $x(t)$, (t 为时间索引),寻找与它最贴近的联接矢量 $V_i(t)$:

$$\begin{aligned} \text{winning}(V_i(t)) &= \min_i (d_1(V_i(t), x(t)) + d_2(V_i(t), x(t))) \\ &= \min_i [d_1(V_i(t), x(t)) + d_2(V_i(t), x(t))], \end{aligned} \quad (8a)$$

$$d_1(V_i(t), x(t)) = \|V_i(t) - x(t)\|, \quad (8b)$$

$$\begin{aligned} d_2(V_i(t), x(t)) &= \frac{1}{I+J+1} \sum_{l=1}^{I+J-1} [(v_{i(I+1)}(t) - v_{il}(t)) - (x_{I+1}(t) \\ &\quad - x_l(t))]^2, \end{aligned} \quad (8c)$$

$v_{il}(t), x_l(t)$ 分别为矢量 $V_i(t), x(t)$ 中的各元。

在聚类分析中,同时考虑故障样本数据与联接矢量在距离 d_1 和形态相似程度 d_2 两

个聚类指标。

(3) 按下式修改选中的联接矢量 $V_i(t)$:

$$V_i(t+1) = V_i(t) + \alpha(t) \cdot [x(t) - V_i(t)],$$

$\alpha(t)$ 为一缓慢下降的时间因子。

(4) 回到(2),直到联接矢量收敛。

(5) 根据聚类情况,在每个变量的取值范围内,选择适当的模糊集合,从而将聚类转化为规则。

4 模拟实验

作为该模糊诊断系统的一个应用实例,我们模拟了旋转主轴的故障发生情况。针对 4 种典型的故障,即联轴节不对中、油膜振荡、碰摩和不平衡,并且在频谱域中选择如下 11 个故障征兆,即 <0.4 倍频分量 ($0.4 \times$), $(0.4 \sim 0.49) \times$, $0.5 \times$, $1 \times$, $2 \times$, $3 \times$, $4 \times$, $5 \times$, $6 \times$, 低频分量 ($<1 \times$) 以及高频分量 ($>5 \times$)。由于这 4 类故障在频域均有明显的差别,在征兆中暂不考虑其它情况,如时域波形状况、轴心运动轨迹等。针对不同故障和故障发生烈度,共获 80 个样本数据。对每个征兆和故障,分别把它们量化为 10 数量等级,并且在其上分别定义了小(S),较小(RS),中等(M),较大(RL)和大(L) 5 个模糊子集。各征兆(或故障)上的模糊子集的宽度和中心位置可视不同的情况具体定义。图 3 为各类故障的量化等级和模糊子集的定义情况。故障发生烈度定义在 $[0,1]$ 间取值。通过自组织聚类算法,共产生 12 条规则,据此构造一 110-12-40 规模的模糊推理网络。




图 3 各类故障的定义情况




图 4 故障频域征兆

表 1 推理结果

故 障	第一种情况		第二种情况	
	推理结果	实际情况	推理结果	实际情况
不对中	0.58	1.0		
碰 摩			0.21	0.25
不平衡			0.98	1.0

根据已建立的推理网络,我们又模拟了2种故障情况以检验该网络的性能。一是强烈的不对中故障,二是强烈的不平衡故障,并伴随有轻微的碰摩。这2种情况的频谱特征如图4(a)、(b)示。根据采集的征兆矢量,经过网络推理、解模糊化等过程((3)式—(5)式),结果如表1示。可见,推理结果与模拟故障烈度基本符合,如果增加量化精度或在量化范围内定义更多的模糊子集,则可增加推理精度。

5 结 论

机械运行状态的模糊性是客观存在的,故障诊断专家能以模糊语言描述这种模糊性,并通过联想、模糊推理等思维过程,最终对诊断问题作出合理的解释。本文提出的故障模糊诊断方法,通过将规则记忆在网络中,并在网络上进行基于规则的推理,以图更加真实地模拟诊断专家的这种思维过程。模拟结果显示了该诊断方法的良好性能,且推理过程计算简便,避免了传统方法求隶属度函数的困难。我们相信,将神经网络与模糊逻辑相结合,是解决故障诊断模糊现象的有效途径。

参 考 文 献

- [1] Sorsa T, *et al.* IEEE Trans. on SMC, 1991, SMC-21(4): 815—825.
- [2] Peng Y, Reggia J A. IEEE Trans. on SMC, 1989, SMC-19(2): 285—298.
- [3] Buckley J J, *et al.* On the equivalence of neural networks and fuzzy expert system. Proc. Inter. Joint Conf. on NN Baltimore: 1992, 691—695.
- [4] Keller J M, Hunt D J. IEEE Trans. on PAMI, 1985, PAMI-7(6): 693—699.
- [5] 应行仁,曾 南. 自动化学报, 1991, 17(1): 63—67.
- [6] Kosko B. Neural network fuzzy systems. Englewood Cliffs, NJ: Prentice-Hall, 1991, 327—334.
- [7] Kong S G, Kosko B. IEEE Trans. on NN, 1991, NN-2(1): 118—124.

A NEURAL NETWORK BASED FAULT FUZZY DIAGNOSTIC SYSTEM

Wu Meng Gong Bi He Zhenya

(Southeast University, Nanjing 210018)

Abstract A fault fuzzy diagnostic system (FFDS) based on neural network and fuzzy logic hybrid is proposed. FFDS consists of two modes: a fuzzy inference mode and a rules learning mode. The fuzzy inference rules are stored in the memory layer. The excitation levels of the memory neurons reflect the matching degree between the input vector and the prototype rules. In the rules learning mode, the rules can be produced automatically through the cluster process. As a application case of this diagnostic system, the fault diagnosis experiment of the rotating axis is simulated.

Key words Fault diagnosis, Neural networks, Fuzzy inference, Expert knowledge