学 术 论 文

基于 Rough 集理论的模糊神经网络构造方法

黄显明，易继锴
（北京工业大学电子信息与控制工程学院，北京 100022）

[摘要] 提出了在模糊神经网络中使用 Rough 集理论进行网络结构设计的方法。由于 Rough 集理论有强大的数值分析能力，而模糊神经网络具有准确的逼近收敛能力和较高的精度，所以通过两者的结合，可以得到一种可理解性好、计算简单、收敛速度快的神经网络模型。这种网络构造方法的主要过程为：首先，利用 Rough 集理论对给定数据集进行规则获取；然后，根据这些规则构造模糊神经网络各层的神经元个数及相关参数初始值；最后，用 BP 算法迭代求出网络的各种参数，完成网络的设计。给出了一个二维非线性函数拟合的实例，进一步验证了方法的正确性。

[关键词] 模糊神经网络；Rough 集；规则获取；函数拟合
[中图分类号] TP183 [文献标识码] A [文章编号] 1009－1742（2004）04－0044－07

1 前言

近年来，不同的计算方法，如模糊集理论、神经网络、遗传算法以及 Rough 集理论的集成，成为一个活跃的领域，是为了产生更为有效的混合系统，称为软计算方法[1]。人工神经网络通常考虑的是一种把神经元按预先定义的方法连接起来的、固定的拓扑布局，如果能够合理地确定网络的层数、各层的结点数、作用函数及权值的初始化值等，那么神经网络可以逼近数学上许多复杂问题。将模糊逻辑和神经网络的优势结合起来，既能处理模糊信息，完成模糊推理功能，又具有神经网络的并行处理和自学习等特点[2]。Rough 集反映了认知过程在非确定性、非模型化信息处理方面的机制和特点，从而成为一种有效的非单调推理工具。

在神经网络中，试图应用 Rough 集理论是从 Yasdi[3]开始的。然而，方法中的 Rough 集理论只是被用于数据提取一级的知识发现，并没有用于构造网络结构。文献[4]分析了基于神经网络集成的高木－关野模糊系统的缺点为精度不高、训练时间长，并提出了改进的神经网络模型，但该模型没有明显的模糊系统的对应关系，语义性差。

笔者把 Rough 集理论应用于模糊神经网络中，由训练样本形成的决策表中产生规则，并利用规则可信度作为阈值来约简规则（实际上采用了 Skowron 提出的缺省规则的思想[5]），以约简后的规则数作为模糊神经网络的隐含层的节点数，构造一种新的网络结构，得到较为满意的数值结果。

2 利用 Rough 集理论获取规则

1）论域划分 要运用 Rough 集理论，必须基于利用现有的知识对论域所做的划分，因此首先面对的问题便是将条件与决策论域按照某些不可分辨关系进行划分。在操作中，划分主要依据专家知识及数据聚类（文献[3]采用了 FUSINTER 聚类）。为简便起见后面的实例进行人为的划分。因划分带有极大程度的专家性、主观性，所以论域中的元素与其所在的类之间实际上具有一种模糊隶属关系，

[收稿日期] 2003－06－02；修回日期 2003－08－12
[基金项目] 北京市自然科学基金资助项目（3993010）
[作者简介] 黄显明（1976－），男，山东临清市人，北京工业大学博士研究生

故在划分论域的同时，每个类（实为一个模糊集）的隶属函数也根据专家知识确定下来。

2）*构建决策表*　按上面所确定的每个类的隶属函数，计算出样本数据针对其相应类的隶属度。取数据针对各隶属函数隶属度最大的类替代该数据，可依次得出条件属性值和决策值。

3）*决策表约简*　决策表约简可采用任一 Rough 集约简算法。例中采用文献[5]的算法。

4）*计算规则可信度*　计算每条规则中，决策属性类针对条件属性类的上、下近似，并利用

$$\mu(x_k) = \min\left|[x_k]_{R_i} \cap D_k\right| \Big/ \left|[x_k]_{R_i}\right|$$

计算各规则的可信度，其中 x_k 代表第$k(k=1,2,\cdots,n)$条规则，D_k 代表第 k 条规则的决策属性类，R_i 代表针对该规则的第 i 个条件属性所作的分类（$i=1,2,\cdots,n$）。

3　构造模糊神经网络结构

应用多层前馈 BP 网络构造模糊变量集隶属函数，实现 Rough 推理过程。该网络是 1 个具有 3 层隐层的前馈神经网络，如图 1 所示。

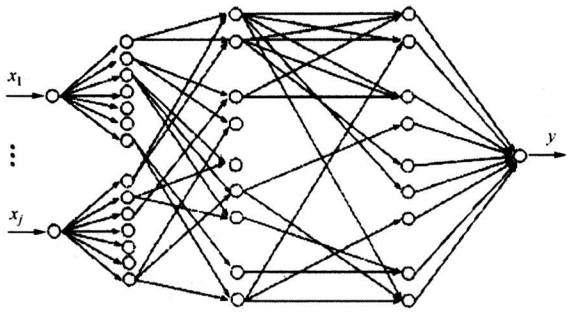

图 1　模糊神经网络结构图

Fig.1　The structure of fuzzy neural network

第一层的输入为语言变量 $\{x_j\}$，第 j 个节点对应输入向量 $\boldsymbol{x}$ 的第 j 个分量，输入值为精确值，输入向量 $\boldsymbol{x}$ 的分量个数就是最简决策表的属性核的个数$j=1,2,\cdots,n$。

第二层是词集节点，用来表示 x_j 分别属于{NB, NM, NS, 0, PS, PM, PB}的隶属函数为

$$\mu_{A_{ij}}(x_j) = \exp\left[-((w_s x_j - w_c)/(1/w_d))^2\right],$$

式中 $i=1,2,\cdots,7$ 为模糊化等级为 7 级(也可选 3 级或 5 级)，w_s 为输入变量的量化因子，w_c 为隶属函数的中心元素，w_d 为隶属函数的尺度因子，在网络训练时的初始值为随机数。第二层在语言节点与对应的词集节点之间完全相联系。

设网络的第 L 层的第 j 个节点的输入为 I_j^L，输出为 O_j^L。网络第一层和第二层的输入输出关系如下：

第一层　$I_j^1 = w_{sj}x_j$，$O_j^1 = I_j^1$，$j=1,2,\cdots,n$。

第二层　$I_j^2 = O_n^1 - w_{cj}$，$O_j^2 = \exp\left[-(w_{dj}I_j^2)^2\right]$，$j = 7(n-1)+1,\cdots,7n$。

第二层神经元的作用函数（核函数）取用高斯函数，具有如下优点：**a.** 表示形式简单，即使对多变量输入也不增加太多的复杂性；**b.** 径向对称；**c.** 光滑性好，任意阶导数均存在；**d.** 由于该基函数表示简单且解析性好，因而便于进行理论分析。

第三层是规则前件层，具有模糊“与”运算功能，所有第三层节点形成模糊规则基。该层神经元的个数为最简决策表所得出的初始规则的条件属性个数。第三、第四层间的连线起到联接机制的推理作用，以避免出现规则匹配过程。

第四层是规则决策层，执行模糊“或”运算，以合成有同样结果的加权规则。该层节点数为由最简决策表得出的初始规则的决策属性个数。

第五层是输出层，起清晰化作用，去模糊后得到网络输出。在多输入单输出系统中，该层的节点数为 1，权值的初始值预设为各规则的可信度值。

网络第三层至第五层的输入输出关系如下：

第三层　$I_k^3 = O_{i_1}^2 O_{i_2}^2 \cdots O_{i_n}^2$，$i_n = 7(n-1)+1,\cdots,7n$，$O_k^3 = I_k^3$，$k=1,2,\cdots,7^n$；

第四层　$I_k^4 = O_k^3 \Big/ \sum_{s=1}^{7^n} O_s^3$，$O_k^4 = I_k^4$；

第五层　$I_1^5 = \sum_k O_k^4 w_{bk}$，$O_1^5 = I_1^5$。

根据上述推导，模糊神经网络的输出为 $y = \sum_k P_k(x_j) w_{bk}$，其中

$$P_k(x_j) = \prod_{j=1}^{n} \mu_{A_{jk}}(x_j) \Big/ \sum_k \prod_{j=1}^{n} \mu_{A_{jk}}(x_j)。$$

所以，模糊神经网络的输出 $y = \sum_k \prod_{j=1}^{n} \mu_{A_{jk}}(x_j) \cdot w_{bk} \Big/ \sum_k \prod_{j=1}^{n} \mu_{A_{jk}}(x_j)$ 的形式恰等同于文献 [6] 中提及的典型模糊推理系统的输出 $y = \sum_{j=1}^{R} \mu_j y^j \Big/ \sum_{j=1}^{R} \mu_j$，其中 $\mu_j = \mu_{A_1^j}(x_1)\mu_{A_2^j}(x_2)\cdots\mu_{A_n^j}(x_n)$。

4 网络的学习算法

在网络结构确立之后，就进入学习阶段以优化调整隶属函数的参数。对于模糊神经网络来说，误差函数定义为

$$E = \frac{1}{2}\sum^{m}(y_0(t) - y(t))^2,$$

式中 m 是学习样本数，$y_0(t)$ 是系统期望输出值，$y(t)$ 是系统实际输出值。反向传播思想被用来监督学习，通过调整网络各权值，使误差函数 E 达到最小，从而达到修正隶属函数参数的目的。对每组训练数据，从输入节点开始，采用前向通道计算网络内所有节点的活性水平；从输出节点开始，通过反向通道计算所有隐节点的$\frac{\partial E}{\partial y}$。假设 w 是一节点的可调参数，一般的学习规则为

$$\Delta w \propto -\frac{\partial E}{\partial w}, w(t+1) = w(t) + \eta\left(-\frac{\partial E}{\partial w}\right),$$

其中 η 是学习速率。为了表示学习规则，从输出节点开始，使用隶属函数进行计算，因此用隶属函数中心 w_{ci} 和宽度 w_{di} 作为可调整参数。

设用 σ_j^L 表示第 L 层第 j 个节点的误差反传信号，各层的误差反传信号为：

输出层 $w_{ci}(t+1) = w_{ci}(t) + \eta[y_0(t) - y(t)]w_{di}O_i^4 \Big/ \sum_k w_{dk}O_k^4$,

$$w_{di}(t+1) = w_{di}(t) + \eta[y_0(t) - y(t)] \cdot \left[w_{ci}O_i^4\sum_k w_{dk}O_k^4 - \left(\sum_k w_{ck}w_{dk}O_k^4\right)O_i^4\right] \Big/ \left(\sum_k w_{dk}O_k^4\right)^2;$$

第四层 $\sigma_i^4(t) = [y_0(t) - y(t)]\left[w_{ci}O_i^4\sum_k w_{dk} \cdot O_k^4 - \left(\sum_k w_{ck}w_{dk}O_k^4\right)O_i^4\right] \Big/ \left(\sum_k w_{dk}O_k^4\right)^2;$

第三层 $\sigma_i^3 = \sum_k \sigma_k^4$；

第二层 $w_{cij}(t+1) = w_{cij}(t) - \eta\sum_k \sigma_k^3 O_i^2 2(O_i^1 - w_{cij}) \Big/ w_{dij}^2$,

$$w_{dij}(t+1) = w_{dij}(t) - \eta\sum_k \sigma_k^3 O_i^2 2(O_i^1 - w_{cij})^2 \Big/ w_{dij}^3。$$

5 网络模型的全局逼近性质

引理（Stone－Weirstrass 定理[7]） 设 Z 为一组定义在致密集 U 上的连续实函数。如果：**a.** 为一个代数，即集合 Z 对加法、乘法和标量乘法是封闭的；**b.** Z 能离析 U 上的各点，即对每一个 x，$y \in U \subset R^n$，若 $x \neq y$，则必然存在 $f \in Z$，使得 $f(x) \neq f(y)$；**c.** Z 在 U 上任意一点不为零，即对每一个 $x \in U$，均存在 $f \in Z$，使得 $f(x) \neq 0$，则 Z 的一致封闭包括了 U 上的所有连续函数，即 (Z, d_∞) 在 $(c[U], d_\infty)$ 上是致密的。

证明 基于 Rough 集理论的模糊神经网络是一个全局逼近器。由网络的输入输出关系可知，Y 是定义在 U 上的一组连续实函数，从三方面证明：

1）(Y, d_∞) 是一个代数

设 $\forall f_1, f_2 \in Y$，令 f_1，f_2 的表达式为：

$$f_1(x) = \sum_{k=1}^{m_1} P_k^1(x_j)w_{bk}^1,$$

$$f_2(x) = \sum_{k=1}^{m_2} P_k^2(x_j)w_{bk}^2,$$

于是有 $f_1(x)f_2(x) = \sum_{k=1}^{m_1} P_k^1(x_j)w_{bk}^1 \sum_{k=1}^{m_2} P_k^2(x_j) \cdot w_{bk}^2 = \sum_{k=1}^{m_1}\sum_{k=1}^{m_2} P_{k_1}^1(x_j)P_{k_2}^2(x_j)w_b^1 w_{bk}^2$。

由于 $P_k^1(x_j)$ 和 $P_k^2(x_j)$ 均为高斯型，因而二者的乘积仍为高斯型。所以上式的形式完全等同于网络输出的形式。所以有 $f_1(x)f_2(x) \in Y$。$\forall c \in R$，有 $cf_1(x) = \sum_{k=1}^{m_1} P_k^1(x_j)cw_{bk}^1$，显然该式的形式完全等同于网络输出的形式，所以有 $cf_1(x) \in Y$。同样有 $f_1(x) + f_2(x) = \sum_{k=1}^{m_1} P_k^1(x_j)w_{bk}^1 + \sum_{k=1}^{m_2} P_k^2(x_j)w_{bk}^2$，显然该式的形式也完全等同于网络输出的形式，所以有 $f_1(x) + f_2(x) \in Y$。

因此可知，(Y, d_∞) 是一个代数。

2）(Y, d_∞) 能离析 U 上的点

证明 要证对于任意给定的 x^0，$y^0 \in U$，当 $x^0 \neq y^0$ 时，有 $f(x^0) \neq f(y^0)$。模糊神经网络的输出表达式中，令 $k=2$，则有：

$$y = \frac{\prod_{j=1}^{n}\mu_{A_{j1}}(x_j)w_{b1} + \prod_{j=1}^{n}\mu_{A_{j2}}(x_j)w_{b2}}{\prod_{j=1}^{n}\mu_{A_{j1}}(x_j) + \prod_{j=1}^{n}\mu_{A_{j2}}(x_j)}。$$

令 $\mu_{A_{j1}}(x_j) = \exp[-(x_j - x_j^0)^2]$，$\mu_{A_{j2}}(x_j) = \exp[-(x_j - y_j^0)^2]$，则有

$$f(x^0)=\frac{w_{b1}+\prod_{j=1}^{n}\exp[-(x_j^0-y_j^0)^2]w_{b2}}{1+\prod_{j=1}^{n}\exp[-(x_j^0-y_j^0)^2]},$$

$$f(y^0)=\frac{w_{b2}+\prod_{j=1}^{n}\exp[-(y_j^0-x_j^0)^2]w_{b1}}{1+\prod_{j=1}^{n}\exp[-(y_j^0-x_j^0)^2]}。$$

由于前面已经假设 $x^0\neq y^0$，因而必然存在某些 j，使得 $x_j^0\neq y_j^0$，这样就有 $\prod_{j=1}^{n}\exp[-(x_j^0-y_j^0)^2]\neq 1$，所以就有 $f(x^0)\neq f(y^0)$。

3）(Y, d_∞) 上所有点均不为零

从模糊神经网络的输出表达式中可以看出，只要简单地选取 $w_{bk}>0$，其所对应的任何 f 均可以保证 (Y, d_∞) 上所有点不为零。

从以上结论，再根据引理（Stone－Weirstrass 定理）的内容，可以直接推出图 1 所示的基于 Rough 集理论的模糊神经网络是一个全局逼近器。

6　实例及分析

以文献[8]中的二维非线性函数 $z=\sin(\pi x)\cdot\cos(\pi y), x, y\in[-1,1]$ 来说明和验证新提出的方法。将 $x, y\in[-1,1]$ 分别均匀划分为 20 个区间，代入上式可以得到 441 组样本数据见表 1，函数图像见图 2，采样图像见图 3。对上述数据按表 2 的离散化方法进行处理，离散后的数据以 x，y 为条件属性，z 为决策属性构成一个决策表，并利用 Rough 集理论，得到属性核为 $P_{CORE}=\{x, y\}$，通过约简得到 68 条规则如表 3 所示。通过可信度阈值（大于 0.65）的限定，最后得到 7 条规则见表 4。

表 1　样本数据*

Table 1　The sample data

	-1.00	-0.90	-0.80	-0.70	-0.60	-0.50	-0.40	-0.30	-0.20	-0.10	0.00	0.10	0.20	0.30	0.40	0.50	0.60	0.70	0.80	0.90	1.00
-1.0	0	0.31	0.59	0.81	0.95	1.00	0.95	0.81	0.59	0.31	0	-0.31	-0.59	-0.81	-0.95	-1.00	-0.95	-0.81	-0.59	-0.31	0
-0.9	0	0.29	0.56	0.77	0.90	0.95	0.90	0.77	0.56	0.29	0	-0.29	-0.56	-0.77	-0.90	-0.95	-0.90	-0.77	-0.56	-0.29	0
-0.8	0	0.25	0.48	0.65	0.77	0.81	0.77	0.65	0.48	0.25	0	-0.25	-0.48	-0.65	-0.77	-0.81	-0.77	-0.65	-0.48	-0.25	0
-0.7	0	0.18	0.35	0.48	0.56	0.59	0.56	0.48	0.35	0.18	0	-0.18	-0.35	-0.48	-0.56	-0.59	-0.56	-0.48	-0.35	-0.18	0
-0.6	0	0.10	0.18	0.25	0.29	0.31	0.29	0.25	0.18	0.10	0	-0.10	-0.18	-0.25	-0.29	-0.31	-0.29	-0.25	-0.18	-0.10	0
-0.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
-0.4	0	-0.10	-0.18	-0.25	-0.29	-0.31	-0.29	-0.25	-0.18	-0.10	0	0.10	0.18	0.25	0.29	0.31	0.29	0.25	0.18	0.10	0
-0.3	0	-0.18	-0.35	-0.48	-0.56	-0.59	-0.56	-0.48	-0.35	-0.18	0	0.18	0.35	0.48	0.56	0.59	0.56	0.48	0.35	0.18	0
-0.2	0	-0.25	-0.48	-0.65	-0.77	-0.81	-0.77	-0.65	-0.48	-0.25	0	0.25	0.48	0.65	0.77	0.81	0.77	0.65	0.48	0.25	0
-0.1	0	-0.29	-0.56	-0.77	-0.90	-0.95	-0.90	-0.77	-0.56	-0.29	0	0.29	0.56	0.77	0.90	0.95	0.90	0.77	0.56	0.29	0
0	0	-0.31	-0.59	-0.81	-0.95	-1.00	-0.95	-0.81	-0.59	-0.31	0	0.31	0.59	0.81	0.95	1.00	0.95	0.81	0.59	0.31	0
0.1	0	-0.29	-0.56	-0.77	-0.90	-0.95	-0.90	-0.77	-0.56	-0.29	0	0.29	0.56	0.77	0.90	0.95	0.90	0.77	0.56	0.29	0
0.2	0	-0.25	-0.48	-0.65	-0.77	-0.81	-0.77	-0.65	-0.48	-0.25	0	0.25	0.48	0.65	0.77	0.81	0.77	0.65	0.48	0.25	0
0.3	0	-0.18	-0.35	-0.48	-0.56	-0.59	-0.56	-0.48	-0.35	-0.18	0	0.18	0.35	0.48	0.56	0.59	0.56	0.48	0.35	0.18	0
0.4	0	-0.10	-0.18	-0.25	-0.29	-0.31	-0.29	-0.25	-0.18	-0.10	0	0.10	0.18	0.25	0.29	0.31	0.29	0.25	0.18	0.10	0
0.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0.6	0	0.10	0.18	0.25	0.29	0.31	0.29	0.25	0.18	0.10	0	-0.10	-0.18	-0.25	-0.29	-0.31	-0.29	-0.25	-0.18	-0.10	0
0.7	0	0.18	0.35	0.48	0.56	0.59	0.56	0.48	0.35	0.18	0	-0.18	-0.35	-0.48	-0.56	-0.59	-0.56	-0.48	-0.35	-0.18	0
0.8	0	0.25	0.48	0.65	0.77	0.81	0.77	0.65	0.48	0.25	0	-0.25	-0.48	-0.65	-0.77	-0.81	-0.77	-0.65	-0.48	-0.25	0
0.9	0	0.29	0.56	0.77	0.90	0.95	0.90	0.77	0.56	0.29	0	-0.29	-0.56	-0.77	-0.90	-0.95	-0.90	-0.77	-0.56	-0.29	0
1.0	0	0.31	0.59	0.81	0.95	1.00	0.95	0.81	0.59	0.31	0	-0.31	-0.59	-0.81	-0.95	-1.00	-0.95	-0.81	-0.59	-0.31	0

* 第一行为 x，第一列为 y，其余为 z

这样，根据上述的数据处理方法得到相应的神经网络模型，即：第一层的节点数为 2 个，第二层的节点数为 9 个，第三层的节点数为 7 个，第四层的节点数为 3 个，第五层的节点数为 1 个。第四层

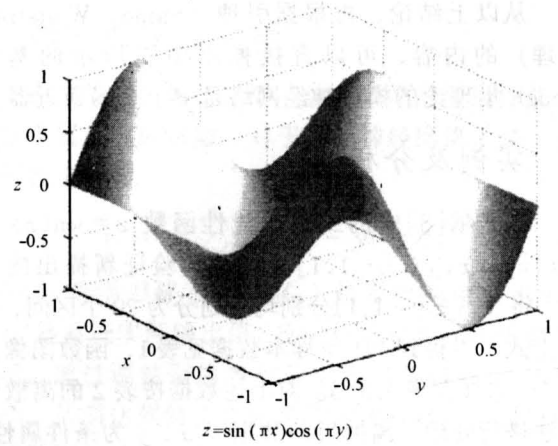

图2 函数图像

Fig. 2 Function figure

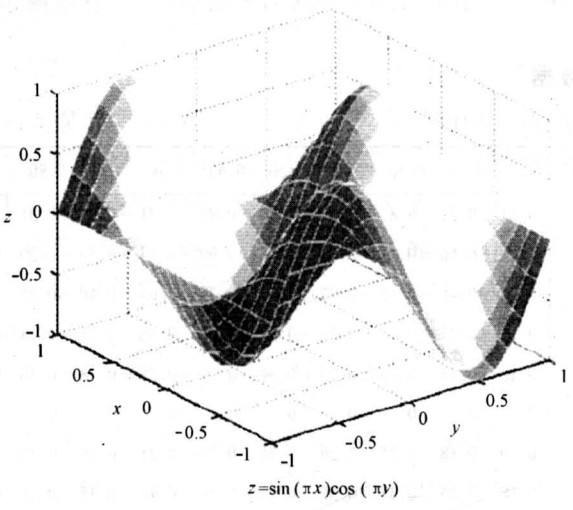

图3 采样图像

Fig.3 Sampling figure

表2 x，y，z 值的离散方法

Table 2 The discretization method of x, y, z

	x, y, z 值				
离散区间	[-1,-0.6]	[-0.6,-0.2]	[-0.2,0.2]	[0.2,0.6]	[0.6,1]
对应离散值	1	2	3	4	5

和第五层之间的连接权值的初始值取规则的可信度，即为{1, 0.75, 0.937 5}，其余参数的初始值取[-1, 1]间的随机数。最后构造的模糊神经网络结构如图4所示。

最后，用表1中的数据作为训练样本，学习速率为0.005，通过655次的训练后，总体误差为0.000 982（文献[8]中在75组数据同样训练次数的总体误差为0.007 595）。训练完成后 x，y 在[-1, 1]区间以0.01为间隔取点输入网络，测试网络的插值能力。共测试40 401组数据，测试结果如图5，显然该方法是一种很好的方法。

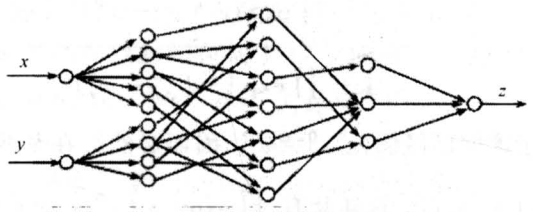

图4 根据 Rough 集理论构造的模糊神经网络结构

Fig.4 The structure of constructed fuzzy neural network by Rough set theory

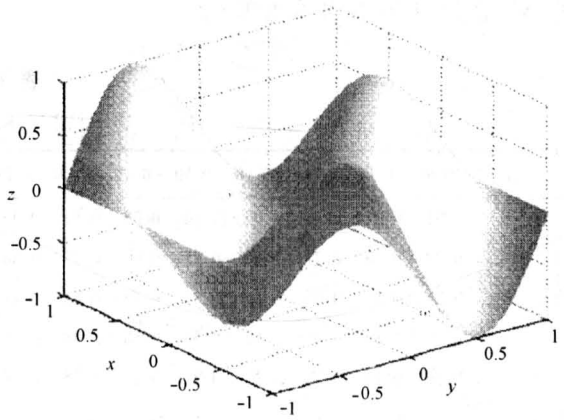

图5 网络拟合图像

Fig.5 The network approaching figure

7 结论

所提出的把 Rough 集理论和模糊神经网络结合起来的新型神经网络构造方法，充分发挥了 Rough 集理论和模糊神经网络各自的优势，弥补了各自的缺点，从实例的结果可以看出该网络可以得到令人满意的解决问题的方法。这种模糊神经网络的模型和算法具有如下特点：

1）通过 Rough 集理论进行知识约简，得出针对原始数据的最简初始规则，使网络从开始就具有良好简洁的拓扑结构，学习速度相应优良；

2）该网络是一个全局逼近器；

3）各层都有明显的物理意义，具有极好的语义性；

4）模型可以解释，每层的节点数都可具体确定；

表 3　利用 Rough 集理论获取规则

Table 3　The rules acquired by Rough set theory

$x([-1, -0.6])$ AND $y([-1, -0.6])\Rightarrow z([-0.2, 0.2])$ OR $z([0.2, 0.6))$ OR $z([0.6, 1])$	0.3125, 0.5, 0.1875
$x([-1, -0.6]]$ AND $y([-0.6, -0.2))\Rightarrow z([-0.2, 0.2))$ OR $z([-0.6, -0.2))$ OR $z([0.2, 0.6))$	0.75, 0.1875, 0.0625
$x([-1, -0.6])$ AND $y([-0.2, 0.2]]\Rightarrow z([-0.2, 0.2]]$ OR $z([-0.6, -0.2]]$ OR $z([-1, -0.6))$	0.25, 0.5, 0.25
$x([-1, -0.6])$ AND $y([0.2, 0.6))\Rightarrow z([-0.2, 0.2))$ OR $z([-0.6, -0.2))$ OR $z([-1, -0.6))$	0.625, 0.3125, 0.0625
$x([-1, -0.6])$ AND $y([0.6, 1])\Rightarrow z([-0.2, 0.2]]$ OR $z([0.2, 0.6]]$ OR $z([0.6, 1])$	0.4, 0.45, 0.15
$x([-0.6, -0.2])$ AND $y([-1, -0.6))\Rightarrow z([0.6, 1])$ OR $z([0.2, 0.6))$	0.75, 0.25
$x([-0.6, -0.2])$ AND $y([-0.6, -0.2]]\Rightarrow z([0.2, 0.6]]$ OR $z([-0.2, 0.2]]$ OR $z([-0.6, -0.2))$	0.25, 0.25, 0.5
$x([-0.6, -0.2])$ AND $y([-0.2, 0.2])\Rightarrow z([-1, -0.6])$	1
$x([-0.6, -0.2])$ AND $y([0.2, 0.6))\Rightarrow z([-1, -0.6))$ OR $z([-0.6, -0.2))$ OR $z([-0.2, 0.2))$	0.25, 0.5, 0.25
$x([-0.6, -0.2])$ AND $y([0.6, 1])\Rightarrow z([0.2, 0.6))$ OR $z([0.6, 1])$	0.4, 0.6
$x([-0.2, 0.2])$ AND $y([-1, -0.6]]\Rightarrow z([0.2, 0.6]]$ OR $z([-0.2, 0.2]]$ OR $z([-0.6, -0.2))$	0.4375, 0.375, 0.1875
$x([-0.2, 0.2])$ AND $y([-0.6, -0.2))\Rightarrow z([-0.2, 0.2))$ OR $z([-0.6, -0.2))$	0.9375, 0.0625
$x([-0.2, 0.2])$ AND $y([-0.2, 0.2]]\Rightarrow z([-0.6, -0.2]]$ OR $z([-0.2, 0.2]]$ OR $z([0.2, 0.6))$	0.5, 0.25, 0.25
$x([-0.2, 0.2])$ AND $y([0.2, 0.6))\Rightarrow z([-0.6, -0.2))$ OR $z([-0.2, 0.2))$ OR $z([0.2, 0.6))$	0.1875, 0.75, 0.0625
$x([-0.2, 0.2])$ AND $y([0.6, 1])\Rightarrow z([-0.2, 0.2]]$ OR $z([0.2, 0.6]]$ OR $z([-0.6, -0.2))$	0.5, 0.35, 0.15
$x([0.2, 0.6])$ AND $y([-1, -0.6))\Rightarrow z([-0.6, -0.2))$ OR $z([-1, -0.6))$	0.4375, 0.5625
$x([0.2, 0.6]]$ AND $y([-0.6, -0.2]]\Rightarrow z([-0.2, 0.2]]$ OR $z([0.2, 0.6]]$ OR $z([-0.6, -0.2))$	0.375, 0.4375, 0.1875
$x([0.2, 0.6]]$ AND $y([-0.2, 0.2))\Rightarrow z([0.2, 0.6))$ OR $z([0.6, 1])$	0.25, 0.75
$x([0.2, 0.6]]$ AND $y([0.2, 0.6]]\Rightarrow z([0.2, 0.6]]$ OR $z([-0.2, 0.2))$ OR $z([0.6, 1])$	0.5, 0.3125, 0.1875
$x([0.2, 0.6))$ AND $y([0.6, 1])\Rightarrow z([-0.2, 0.2))$ OR $z([-0.6, -0.2))$ OR $z([-1, -0.6))$	0.05, 0.5, 0.45
$x([0.6, 1])$ AND $y([-1, -0.6]]\Rightarrow z([-1, -0.6]]$ OR $z([-0.6, -0.2]]$ OR $z([-0.2, 0.2))$	0.3, 0.45, 0.25
$x([0.6, 1])$ AND $y([-0.6, -0.2))\Rightarrow z([-0.6, -0.2))$ OR $z([-0.2, 0.2))$ OR $z([0.2, 0.6))$	0.1, 0.65, 0.25
$x([0.6, 1])$ AND $y([-0.2, 0.2]]\Rightarrow z([0.6, 1])$ OR $z([0.2, 0.6]]$ OR $z([-0.2, 0.2))$	0.4, 0.4, 0.2
$x([0.6, 1])$ AND $y([0.2, 0.6))\Rightarrow z([0.6, 1])$ OR $z([0.2, 0.6))$ OR $z([-0.2, 0.2))$	0.1, 0.35, 0.55
$x([0.6, 1])$ AND $y([0.6, 1])\Rightarrow z([-0.6, -0.2]]$ OR $z([-1, -0.6]]$ OR $z([-0.2, 0.2))$	0.44, 0.24, 0.32

表 4　约简后的缺省规则

Table 4　The default rules after the reduction

$x([-1, -0.6]]$ AND $y([-0.6, -0.2]]\Rightarrow z([-0.2, 0.2))$	0.75
$x([-0.6, -0.2))$ AND $y([-1, -0.6))\Rightarrow z([0.6, 1])$	0.75
$x([-0.6, -0.2])$ AND $y([-0.2, 0.2])\Rightarrow z([-1, -0.6])$	1.00
$x([-0.2, 0.2])$ AND $y([-0.6, -0.2])\Rightarrow z([-0.2, 0.2])$	0.937 5
$x([-0.2, 0.2]]$ AND $y([0.2, 0.6]]\Rightarrow z([-0.2, 0.2)$	0.75
$x([0.2, 0.6))$ AND $y([-0.2, 0.2))\Rightarrow z([0.6, 1])$	0.75
$x([0.6, 1])$ AND $y([-0.6, -0.2))\Rightarrow z([-0.2, 0.2)$	0.65

5）网络的精度取决于输入节点的不可分辨类的划分及规则的最小可信度的选取；

6）完全符合模糊推理过程。

参考文献

[1] Zadeh L A. Fuzzy logic, neural networks and soft computing [J]. Communications of the ACM, 1994, 37(3): 77～84

[2] 李士勇. 模糊控制神经控制和智能控制论 [M]. 哈尔滨:哈尔滨工业大学出版社,1996

[3] Yasdi R. Combining rough sets learning and neural learning method to deal with uncertain and imprecise information [J]. Neuro－Computing, 1995, 7(1): 61～84

[4] 王士同. 神经模糊系统及其应用 [M]. 北京:北京航空航天大学出版社,1998. 179～186

[5] 王国胤. Rough 集理论与知识获取 [M]. 西安:西安交通大学出版社, 2001

[6] 易继锴. 智能控制技术 [M]. 北京:北京工业大学出版社, 1999

[7] Rudin W. Principles of Mathematical Analysis [M]. New York McGRAW-HILL Book Company, 1976. 159～165

[8] 李永敏. 根据粗糙集理论进行BP网络设计的研究[J]. 系统工程理论与实践, 1999, 19(4): 62～69

A Method of Constructing Fuzzy Neural Network Based on Rough Set Theory

Huang Xianming, Yi Jikai

(*Electronic Information and Control Engineering College, Beijing University of Technology, Beijing* 100022, *China*)

[**Abstract**] A new method of constructing fuzzy neural network is presented and Rough set theory is applied to this method. Since Rough set theory has strong numeric analyzing ability and fuzzy neural network has exact function approaching ability, their combination can produce a neural network model with good intelligibility and fast convergence. First, some rules are acquired from given data set by rough set theory. Then, these rules are applied to constructing neural cell numbers and relative parameters in fuzzy neural network. Finally the initial network is trained by BP arithmetic and the whole network design is finished. Also in this paper, an example of nonlinear function approaching is discussed and the feasibility of this method is proved.

[**Key words**] fuzzy neural network; rough set; acquire rule; function approaching

(cont. from p.43)

The $S-N$ Curve Fitted by the Least Square Method Considering the Effect of Length of the Confidence Interval

Yang Xiaohua[1], Jin Ping[1], Yao Weixing[2]

(1. *Naval Aeronautical Engineering Institute Qingdao Branch, Qingdao, Shandong* 266041, *China*; 2. *Nanjing Aeronautical University, Nanjing* 210016, *China*)

[**Abstract**] The $S-N$ curve is the base of calculating fatigue structural life. Founding on physical mechanism, this paper presents a weighted least square method in which the weigh of a group of test data is inversely proportional to the length of the confidence interval. The calculating results show that the $S-N$ curve which is gained by the least square method considering the effect of length of the confidence interval is more reliable and secure than the $S-N$ curve which is gained by general least square method.

[**Key words**] confidence interval; fatigue life; least square method; $S-N$ curve