

文章编号: 1001-0920(2006)07-0821-04

一种基于属性重要性的粗糙 RBF 神经网络

李昌彪¹, 夏克文¹, 宋建平¹, 闫晓晨²

(1. 西安交通大学 电子与信息工程学院, 西安 710049; 2 华南理工大学 物理科学与技术学院, 广州 510640)

摘要: 提出一种基于属性重要性的粗糙 RBF 神经网络模型, 该模型不仅具有明确的生物意义和物理意义, 而且简化了拓扑结构, 减少了运算量和成本。实际应用结果表明, 这种粗糙 RBF 神经网络在油水层识别中效果显著, 其学习训练速度和拟合精度远优于传统的 RBF 网络算法。

关键词: 粗糙 RBF 神经网络; 粗糙集; 属性重要性; 油水层识别

中图分类号: TP18 **文献标识码:** A

Rough RBF Neural Networks Based on Attribute Significance

LI Chang-biao¹, XIA Ke-wen¹, SONG Jian-ping¹, LV Xiao-chen²

(1. School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2 School of Physics Science and Technology, South China University of Technology, Guangzhou 510640, China
Correspondent: LI Chang-biao, E-mail: cbli@mailst.xjtu.edu.cn)

Abstract: A model of rough radial basis function (RBF) neural network with attribute significance is presented. It not only has evident physical and biologic meanings, but also can simplify topology structure, and decrease operation and cost. The application example shows that the effect in oil-water layer recognition is very good, and this algorithm is superior to the traditional one at fitting precision and training rate.

Key words: Rough RBF neural network; Rough set; Attribute significance; Oil-water layer recognition

1 引言

径向基函数(RBF)网络是根据生物感受野的思想而提出的,其神经元的产生具有很强的生物背景。目前它已成功地应用于模式识别、函数逼近、信号处理、系统建模和控制等领域^[1,2]。粗糙集理论是处理模糊和不确定知识的一种新型数学工具,近年来在人工智能、数据挖掘、模式识别等领域获得了成功的应用^[3,4]。在智能信息处理中,不少作者将RBF网络与粗糙集相结合,取得了一定的成果。然而这仅是简单的组合,即把粗糙集当作神经网络的前置或者规则的提取^[5,6],没有将粗糙集与神经网络真正地融合在一起。

本文依据生物感受野对事物能作出第一印象或判断的观点,提出一种基于属性重要性的粗糙RBF神经网络模型,其机理是人脑能利用样本信息各属

性的重要性,进行下一步的思维或评判。在网络模型构造中,将样本信息的属性重要性作为RBF网络的输入层与隐含层之间的连接权值,这样便使输入层与隐含层之间的连接权值具有明确的生物意义和物理意义,并简化了网络的拓扑结构。油水层识别实际应用表明,该模型切实可行且应用效果显著。

2 基本原理描述

2.1 属性重要性与属性约简

设 $L = (U, R)$ 为一信息系统, $U = \{u_1, u_2, \dots, u_n\}$ 为有限非空的个体全集, $R = \{r_1, r_2, \dots, r_m\}$ 为有限的属性集, $R = C \cup D, C \cap D = \emptyset$,其中 C 和 D 分别为条件属性和决策属性。

2.1.1 基于差别矩阵的属性约简

目前,计算属性约简最常用的方法是利用差别矩阵表示知识的方法^[7]。其步骤如下:

收稿日期: 2005-04-14; 修回日期: 2005-06-27

基金项目: 国家自然科学基金项目(60173058, 60377020); 中国石油集团“九五”重点攻关项目(2001-6-1)。

作者简介: 李昌彪(1977—),男,湖南邵东人,博士生,从事计算智能、数据挖掘的研究; 宋建平(1946—),男,江苏苏州人,教授,博士生导师,从事信息处理、无损探测等研究。

- 1) 计算信息系统 L 的差别矩阵 $M(L)$;
- 2) 计算与 $M(L)$ 相关联的差别函数 $f_{M(L)}$;
- 3) 求出差别函数 $f_{M(L)}$ 的最小析取范式, 它将给出所有的属性约简

2.1.2 属性重要性

为克服基于依赖度和信息熵这两种重要性引起的分歧^[8], 根据知识具有粒度的思想, 从粗糙集的两个近似精度出发, 给出如下定义^[9,10]:

定义 1 设 L 为由 D 所决定的 U 的划分 $\{Y_1, Y_2, \dots, Y_k\}, Y \subseteq U$, 则集合 Y 关于属性集 P 的近似精度为

$$\alpha_P(Y) = \frac{\text{card}(PY)}{\text{card}(PY)}. \quad (1)$$

其中: PY 和 \overline{PY} 分别表示 P 的下近似和上近似, $\text{card}(Y)$ 表示集合 Y 所含元素的个数

划分 L 关于属性集 P 的近似精度为

$$\mathcal{Y}_P(L) = \frac{\sum_{i=1}^k \text{card}(PY_i)}{\text{card}(U)}; \quad (2)$$

划分 L 关于属性集 P 的粗糙近似精度为

$$\alpha_P(L) = \frac{\sum_{i=1}^k \text{card}(PY_i)}{\sum_{i=1}^k \text{card}(\overline{PY_i})}. \quad (3)$$

对每个条件属性计算以下 $k + 2$ 个参数: $\alpha_{c_i}(Y_j) (j = 1, 2, \dots, k), \alpha_{c_i}(L)$ 和 $\mathcal{Y}_{c_i}(L)$. 令 α_{c_i} 和 α_{c_i} 分别为这 $k + 2$ 个参数的均值和方差

定义 2^[10] 属性 C_i 的重要性为 $S_{C_i} = \alpha_{c_i}$; 当属性重要性相等时, 使 α_{c_i} 最小的 C_i 的重要性为优

2.2 RBF 网络结构




图 1 径向基函数网络结构

RBF 神经网络的结构如图 1 所示, 其输入层与隐含层之间的连接权值 w_{ij} 均为 1, 隐含层的每个单元都包含一个中心, 隐含层单元的基函数为高斯函数, 即

$$\phi_j(x) = \exp(-\frac{\|x - c_j\|^2}{\rho^2}). \quad (4)$$

其中: x 为输入矢量, c_j 为隐含层第 j 个单元的中心点, ρ 是其单元的宽度值, $\|\cdot\|$ 表示 Euclid 距离

输出层单元是各个隐含层单元的线性组合 RBF 网络的映射关系 $f: R^n \rightarrow R^m$ 为

$$y_k = f_k(x) = \sum_{j=1}^J \phi_j(x - c_j, \rho) v_{jk}, \quad k = 1, 2, \dots, m. \quad (5)$$

其中: J 和 m 分别表示隐含层和输出层单元的个数, y_k 表示输出层第 k 个单元的输出值, v_{jk} 表示隐含层第 j 个单元到输出层第 k 个单元的输出加权值

由式 (5) 可知, 在网络训练中, 只要确定合适的隐含单元的中心点、宽度值和输出加权值, 便可得到一个描述 $f: x \rightarrow y$ 函数映射的 RBF 网络

3 粗糙 RBF 神经网络的构造和算法

3.1 粗糙 RBF 网络的构造

图 1 也是基于属性重要性的粗糙 RBF 神经网络的结构, 只是输入层与隐含层之间的连接权值并不均为 1, 而是由样本属性的重要性 S_{c_i} 所构成 其机理是人脑感受野对样本信息作出的第一印象或判断, 即将样本属性的重要程度存储在神经元中, 通过人工神经网络可以反映在输入层与隐含层之间

1) 输入层: 经过样本属性约简后, 得到输入向量 $X = \{x_1, x_2, \dots, x_n\}$, 经过属性重要性加权操作, 再输入到隐含层

2) 隐含层: 选择高斯函数作为基函数, 首先将输入的数据采用 k -means 法进行聚类, 求出高斯函数的中心点值, 然后按式 (4) 求出基函数的宽度值, 最后得到隐含层的输出

$$N_j^{\text{out}} = \sum_{i=1}^n [(-S_{c_i} x_i - c_j) / \rho^2], \quad (6)$$

3) 输出层: 输出通过一次加权得到, 即

$$y_k = \sum_{j=1}^J v_{jk} N_j^{\text{out}} = \sum_{j=1}^J \sum_{i=1}^n [(-S_{c_i} x_i - c_j) / \rho^2] v_{jk}, \quad k = 1, 2, \dots, m. \quad (7)$$

其中: S_{c_i} 表示属性的重要性, c_j 和 ρ 分别表示基函数的中心点值和宽度值

3.2 学习训练算法

粗糙 RBF 网络的学习训练, 实际是对 S_{c_i}, c_j, ρ 和 v_{jk} 的确定, 具体分为以下 3 个步骤

3.2.1 输入层单元数目和 S_{c_i} 的确定

一种相对最简的约简算法如下:

- 1) 根据差别矩阵法求出条件属性 C 的所有约简;
- 2) 求核 $\text{core}(C)$, 即 $\text{core}(C) = \text{red}(P)$;
- 3) 计算可约简属性 $c_i \in C$ 关于决策属性 D 的重要性 $S_{c_i}, i = 1, 2, \dots, k$;

4) 求相对最简约简: 在核 $\text{core}(C)$ 中将所有可约简属性按 S_{c_i} 由大到小的次序逐渐添加, 形成集合 X , 直到 $\text{ind}(X) = \text{ind}(C), X$ 即为所求的相对最简约简

于是 X 即为粗糙 RBF 神经网络的输入向量, 输

入层单元数目为 X 中的属性个数, 而输入层与隐含层之间的连接权值为属性的重要性 S_{c_i} , 若 S_{c_i} 为零, 则令其数值为一个相当小的数, 比如 10^{-6} .

3.2.2 隐含层中 c_j 和 ρ 的确定

1) 各单元的中心 c_j 的确定: 对于约简后的样本集, 采用 k -means 聚类算法来确定

2) ρ 的确定: 为使网络能获得理想的训练效果, 基于样本集合的误差分布, 本文提出如下改进措施:

第 1 次计算利用如下经验公式:

$$\rho = \sqrt{d_{\max}^2 / (J + 1)}, \quad (8)$$

其中 d_{\max} 表示训练样本中输入向量间的最大距离

从第 2 次开始, 所有计算使用如下修正公式:

$$\rho^{\text{New}} = \min \text{center}^{\text{New}} - \text{center}^{\text{Old}}. \quad (9)$$

其中: $\text{center}^{\text{New}}$ 指当次隐含层单元的中心点位置, $\text{center}^{\text{Old}}$ 指前次隐含层单元的中心点位置

3.2.3 连接权值 v_{jk} 的确定

根据网络的实际输出 y_k 与期望输出 \hat{y}_k 之间的误差 E 为最小的原则, 求解如下极值问题:

$$\min E = \sum_{k=1}^m (y_k - \hat{y}_k)^2, \quad (10)$$

便可得到 v_{jk} 式(10)可采用最小二乘法来求解 当整个网络学习训练完成后, 即可利用式(7)对未知样本进行识别

4 应用实例

在油水层模式识别系统中, 选择胜利油田临南地区一口油井的测井信息作为研究对象 如表 1 所示, 选取 12 个典型层位的数据为样本集, 其中 SP, GR, RT, DEN, CNL 和 RWA 分别表示自然电位、自然伽玛、电阻率、密度、补偿中子和地层水电阻率 构成如下信息表:

表 1 测井属性样本信息

No	SP (mV)	GR (API)	RT ($\Omega \cdot m$)	DEN (g/cm^3)	CNL (%)	RWA ($\Omega \cdot m$)	D
1	89.47	92.12	6.20	2.47	19.41	0.13	0
2	90.85	89.53	5.32	2.48	18.27	0.12	0
3	92.11	86.38	7.04	2.46	17.88	0.15	0
4	49.98	45.01	3.00	2.42	22.02	0.10	1
5	55.00	48.01	4.00	2.41	21.01	0.13	1
6	52.49	46.51	3.50	2.41	21.52	0.12	1
7	58.19	73.14	6.68	2.42	18.98	0.19	2
8	39.09	78.56	6.16	2.47	15.95	0.10	2
9	37.33	69.54	5.56	2.49	14.32	0.07	2
10	45.07	62.54	13.49	2.38	16.87	0.36	3
11	49.74	39.34	12.81	2.41	16.23	0.31	3
12	65.73	70.52	9.76	2.41	16.80	0.13	3

条件属性

$$C = \{SP, GR, RT, DEN, CNL, RWA\},$$

决策属性

$$D = \{\text{干层, 水层, 油水共层, 油层}\}.$$

首先将决策表中的属性进行离散化和泛化 令决策属性 $D = \{d\}$, $d = \{d_i = i, i = 0, 1, 2, 3\}$, 其中 0~3 分别表示干层、水层、油水共层、油层 利用测井解释专家经验, 将 C 离散成对应于决策层 0~3 的数值, 得到表 2 的离散化信息

表 2 离散化后的样本信息

No	SP	GR	RT	DEN	CNL	RWA	D
1	0	0	2	3	1	2	0
2	0	0	1	3	1	3	0
3	0	0	3	3	1	2	0
4	2	2	0	2	0	3	1
5	1	2	0	2	0	2	1
6	1	2	0	2	0	3	1
7	1	0	2	2	1	1	2
8	3	0	2	3	1	3	2
9	3	1	1	3	2	3	2
10	2	1	3	1	1	0	3
11	2	3	3	2	1	0	3
12	1	0	3	2	1	2	3

由差别矩阵法得到约简集

$$\begin{aligned} &\{SP, GR, RT, DEN, RWA\}, \\ &\{SP, GR, RT, CNL, RWA\}, \\ &\{SP, RT, DEN, CNL, RWA\}, \end{aligned}$$

则核为

$$\text{core}(C) = \text{red}(C) = \{SP, RT, RWA\}.$$

各属性的重要性计算结果如表 3 所示, 其中 L 的划分为

$$\begin{aligned} L &= \{Y_1, Y_2, Y_3, Y_4\} = \\ &\{\{1, 2, 3\}, \{4, 5, 6\}, \{7, 8, 9\}, \{10, 11, 12\}\}. \end{aligned}$$

计算得

表 3 属性重要性计算结果


参数	SP	GR	RT	DEN	CNL	RWA
$ac_i(Y_1)$	1	0	0	0	0	0
$ac_i(Y_2)$	0	1	1	0	1	0
$ac_i(Y_3)$	1/3	0	0	0	0	1/6
$ac_i(Y_4)$	0	1/9	0	1/7	0	1/3
$ac_i(L)$	5/23	1/13	1/6	1/29	3/26	1/10
$\chi_{c_i}(L)$	5/12	1/3	1/4	1/4	1/4	1/4
S_{c_i}	0.328	0.254	0.236	0.030	0.228	0.142
α_{c_i}	0.115	0.124	0.126	0.003	0.128	0.015

$$Y_C(L) = 1.0, Y_{core(C)}(L) = 5/6$$


利用前述属性约简算法, 选择重要性最大的属性{GR} 与 core(C) 组成集合 $X = \{SP, RWA, RT, GR\}$, 有 $Y_X(L) = 1.0 = Y_C(L)$, 则 X 即为相对属性约简表

根据约简表 X 的属性个数, 可设计粗糙RBF神经网络的输入层单元为 4 个. 将属性重要性 S_{C_i} 作为输入层与隐含层之间的连接权值, 并确定出隐含层各单元的中心值和宽度值. 输出层单元设计为 4 个, 其期望输出分别为 (1, 0, 0, 0), (0, 1, 0, 0), (0, 0, 1, 0) 和 (0, 0, 0, 1), 分别表示干层、水层、油水共层和油层. 最后利用最小二乘法确定出隐含层与输出层之间的连接权值 v_{jk} , 其中网络输出误差 E 设计为 10^{-6} . 至此, 整个神经网络的学习训练便全部完成

在逼近精度为 10^{-6} 的情况下, 粗糙RBFNN 和传统RBFNN 求解隐含层宽度值的迭代次数误差曲线如图 2 所示, 其中实线表示迭代误差, 虚线表示目标误差. 显然, 本文算法收敛速度很快, 只需迭代 40 次即可, 而传统算法则需迭代 226 次



(a) 传统 RBF 网络



(b) 粗糙 RBF 网络

图 2 求解隐含层单元宽度值的迭代次数和误差
利用上述训练好的粗糙RBF神经网络对该并另外 10 个典型层位进行识别, 其结果与传统的RBF

表 4 对 10 个典型层位的识别结果

层位编号	1	2	3	4	5	6	7	8	9	10
试油结论	3	0	1	2	3	0	1	2	3	1
传统RBFNN	3	0	1	3	3	0	1	1	3	2
粗糙RBFNN	3	0	1	2	3	0	1	1	3	1

网络识别的结果如表 4 所示. 其中结论 0~ 3 分别表示干层、水层、油水同层和油层. 由表可知, 粗糙RBF神经网络的识别率高达 90%, 而传统RBF的识别率只有 70%, 粗糙RBF的应用效果明显优于传统RBF.

5 结 论

本文提出一种基于粗糙集属性重要性的RBF神经网络模型, 它融合了粗糙集属性约简和RBF神经网络的优点. 通过粗糙集属性约简, 可剔除冗余信息和噪声的干扰, 并能简化神经网络的拓扑结构, 起到了减少运算量和节省成本等功效, 同时也使RBF的输入层与隐含层之间的连接权值获得明确的生物意义和物理意义. 油水层识别的实例表明了粗糙RBF神经网络的应用效果, 该网络在模式识别等领域具有广阔的应用前景

参考文献 (References)

- [1] Meng J, Chen E, Wu S Q. High-speed Face Recognition Based on Discrete Cosine Transform and RBF Neural Networks[J]. *IEEE Trans on Neural Networks*, 2005, 16(3): 679-691.
- [2] Lu Y W, Sundarajan N, Saratchandran P. Performance Evaluation of Sequential Minimal Radial Basis Function (RBF) Neural Network Learning Algorithm [J]. *IEEE Trans on Neural Networks*, 1998, 9(6): 308-317.
- [3] 倪远平, 周建华, 李彬华, 等. 基于粗糙集理论的电力变压器故障诊断方法研究[J]. *控制与决策*, 2004, 19(8): 943-946.
(Ni Y P, Zhou J H, Li B H, et al. Method of Fault Diagnosis for Power Transformer Based on Rough Set Theory [J]. *Control and Decision*, 2004, 19(8): 943-946.)
- [4] 安利平, 陈增强, 袁著祉. 基于粗糙集理论的多属性决策分析[J]. *控制与决策*, 2005, 20(3): 294-298.
(An L P, Chen Z Q, Yuan Z Z. Multi-attribute Decision Analysis Based on Rough Set Theory [J]. *Control and Decision*, 2005, 20(3): 294-298.)
- [5] Swiniarski R, Hargis L. Rough Set as a Front End of Neural-networks Texture Classifiers [J]. *Neuro-computing*, 2001, 36(1): 85-102.
- [6] Jelonek J, Krawiec K, Slowinski R. Rough Set Reduction of Attributes and Their Domains for Neural Networks [J]. *Computational Intelligence*, 1995, 11(2): 339-347.
- [7] Skowron A, Rauszer C. The Discernibility Matrices and Function in Information System [A]. *Intelligent Decision Support Handbook of Application and Advances of the Rough Sets Theory* [C]. Dordrecht: Kluwer Academic Publishers, 1991: 331-362.

(下转第 828 页)




图4 不同级别法向加速度跟踪结果




图5 复合控制系统控制分配结果

7 结 语

气动面和直接侧推力复合控制技术是提高导弹对高空、高速、大机动、快速拦截性能的重要保障,它能有效地补偿气动面控制系统的非最小相位造成的延迟,尤其是在高空、大机动、大攻角等气动效率低的情况下,可提高拦截导弹的快速大机动跟踪能力。可采用常规气动力控制+智能直接力控制的复合控制结构,并通过定性推理和定量优化相结合的设计方法,实现导弹气动力和直接侧向力之间合理的控制分配,满足特定的导弹复合控制系统的高性能要求。

参考文献(References)

- [1] Wise K A, Broy D J. Agile Missile Dynamics and Control [J]. *J. of Guidance, Control and Dynamics*, 1998, 21(3): 441-449.
- [2] Yong S C, Choi C L. Autopilot Design for Agile Missile with Aerodynamic Fin and Side Thruster [A]. *SICE Annual Conf* [C]. Fukui: IEEE Press, 2003: 1476-1481.
- [3] Vishnu L P, David B D. A Nonlinear Programming Approach for Control Allocation [A]. *Proc of the 2004 American Control Conf* [C]. Boston: IEEE Press, 2004: 1689-1694.
- [4] 程凤舟, 万自明, 陈士鲁, 等. 防空导弹直接力与气动力复合控制系统设计 [J]. *飞行力学*, 2003, 21(2): 49-52.
(Cheng F Z, Wan Z M, Chen S L. Side Jet and Aerodynamics Compound Control System Design of Air Defense Missiles [J]. *Flight Dynamics*, 2003, 21(2): 49-52.)
- [5] Menon P K, Iragavarapu V R. Adaptive Techniques for Multiple Actuator Blending [A]. *AIAA Guidance, Navigation and Control Conf* [C]. Boston, 1998: 1-12.
- [6] Thukral A, Innocenti M. A Sliding Mode Missile Pitch Autopilot Synthesis for High Angle of Attack Maneuvering [J]. *IEEE Trans on Control Systems Technology*, 1998, 6(3): 359-371.
- [7] Hirokawa R, Sato K. Autopilot Design for a Missile with Reaction Jet Using Coefficient Diagram [A]. *AIAA Guidance, Navigation and Control Conf and Exhibit* [C]. Montreal, 2001: 1-8.
- [8] Schroeder W K, Liu K. An Appropriate Application of Fuzzy Logic: Missile Autopilot for Dual Control Implementation [A]. *IEEE Int Symp on Intelligent Control* [C]. Columbus: IEEE Press, 1994: 93-98.
- [9] Choi D H, Oh S Y. A New Mutation Rule for Evolutionary Programming Motivated from Backpropagation Learning [J]. *IEEE Trans on Evolutionary Computation*, 2000, 4(2): 188-190.
- [8] 石峰, 姜臻亮, 张永清. 一种改进的粗糙集属性约简启发式算法 [J]. *上海交通大学学报*, 2002, 36(4): 478-481.
(Shi F, Lou Z L, Zhang Y Q. A Modified Heuristic Algorithm of Attribute Reduction in Rough Set [J]. *J of Shanghai Jiaotong University*, 2002, 36(4): 478-481.)
- [9] 叶东毅, 黄翠微, 赵斌. 基于逼近精度的一个粗糙集属性约简算法 [J]. *福州大学学报*, 2000, 28(1): 7-10.
(Ye D Y, Huang C W, Zhao B. An Algorithm for Attributes Reduction in Rough Set Based on Approximation Quality [J]. *J of Fuzhou University*, 2000, 28(1): 7-10.)
- [10] 夏克文, 沈钧毅, 李昌彪. 样本信息处理中一种属性约简方法的研究 [J]. *西安交通大学学报*, 2005, 39(6): 558-561.
(Xia K W, Shen J Y, Li C B. Method of Attribute Reduction in Sample Information Processing [J]. *J of Xi'an Jiaotong University*, 2005, 39(6): 558-561.)

(上接第 824 页)