

# 基于径向基函数(RBF)映射理论的 遥感影像分类模型研究

骆剑承 周成虎

(中国科学院地理研究所, 北京 100101)

杨 艳

(北京师范大学环境科学研究所, 北京 100875)

**摘要** 与传统统计方法的分类器相比较, 人工神经网络(ANN)方法应用于遥感影像分类, 不需预先假设样本空间的参数化统计分布, 具有复杂的映射能力。大多数ANN分类器采用误差反向传播(BP)学习算法的多层感知器模型(BPNN), 其主要缺陷是学习速度缓慢、容易陷入局部极小而难以收敛等。基于径向基函数(RBF)映射理论的神经网络模型融合了参数化统计分布模型和非参数化线性感知器映射模型的优点, 在实现快速学习的同时, 保持了高度复杂的映射能力。该文主要探讨RBF映射理论在遥感影像分类中的具体算法和实现过程, 并初步提出了融合地学知识的RBF影像分类模型; 最后以实际的遥感土地覆盖分类为例, 通过与BP神经网络方法(BPNN)相比较, 对分类过程和结果进行了综合分析, 认为RBF方法在学习速度、网络结构、融合领域知识等方面具有一定的优势。

**关键词** 人工神经网络 径向基函数(RBF) 映射 遥感影像分类

中图分类号: TP75 文献标识码: A 文章编号: 1006-8961(2000)02-0094-06

## Radial Basis Function Map Theory Based Remote Sensing Image Classification Modal

LUO Jian-cheng, ZHOU Cheng-hu

(Institute of Geography, Chinese Academy of Sciences Beijing 100101)

YANG Yan

(Institute of Environmental Science, Beijing Normal University, Beijing 100875)

**Abstract** In recent years the artificial neural network has been developed and applied to remotely sensed data classification problem. Most modal of them are error back-propagation(BP), BP learning algorithm based multi-layer perceptron. Compared to the conventional statistical classifier, BPNN RS image classifier are non-parametric and may have the capacity of more robust proximity especially when distributions are strongly non-Gaussian, but its main shortcoming is its slow training speed, local minimum and even being unable to converge. The Radial Basis Functions Neural Network (RBFNN) modal, integrating the parametric statistic distribution modal and non-parametric single layer perceptron modal, trains faster and more stable than BPNN while keeping the complicated proximity. In this article, the survey and analysis of the RBFNN for the classification of remotely-sensed multi-spectral image is presented, and the RBF RS image classification modal, detailed algorithms and realization procedures is initially raised. The framework which fuses Geo-Knowledge into RBFNN by RBF functions and hierarchical clustering means with optimization evolution theory also are introduced. Finally, the case of practical application of remote sensing land cover classification in Hong Kong region is presented. After the procedure of RBFNN and BPNN approaches are synthetically analyzed, experimental results show that RBFNN approach has more advantages in train time, network structure, knowledge fusion, etc.

**Keywords** Artificial neural networks, Radial basis function, Map theory, Remote sensing image classification

## 0 引言

与符号主义相比较, 连接主义的人工神经网络(Artificial Neural Networks 缩写为 ANN) 结构是由大量简单的处理单元互相连接而形成的复杂并行网络结构, 虽然各单元只完成简单的计算功能, 而整个网络却构成了高度复杂的非线性动力系统<sup>[1]</sup>. ANN 能简单模拟人脑和神经系统功能的基本特征, 特别适合于人的视觉生理活动的仿真. ANN 已经成功地应用于组合优化、分类和模式识别、知识处理、信号处理等多种领域<sup>[1, 2]</sup>. 遥感影像分类是随着模式识别技术的发展而发展起来的, 主要的影像分类模型有最小距离模型、统计模型、基于规则的逻辑推理模型、模糊分类模型等. 80 年代末 ANN 开始在遥感影像分类中得到成功应用, 逐渐发展成为人工神经网络遥感影像分类模型<sup>[3]</sup>.

90 年代以来, 人工神经网络大量应用于遥感影像分类和信息提取, 如土地覆盖分类<sup>[3-5]</sup>、结构信息提取<sup>[3]</sup>等等. 我们发现基于这些经典的人工神经网络(ANN)模型的遥感影像分类方法, 大多采用的是基于误差反向传播(BP)学习算法的多层感知器(MLP)模型结构(BPNN). 与传统的基于高斯分布的统计方法分类器, 如最大似然方法(MLC)相比较, BPNN 具有不需要先验统计分布的复杂映射、可融合多种类型数据(如地理信息)、并行计算等优点, 因此在分类结果上精度往往要优于一般统计分类方法<sup>[3]</sup>. 但是, 基于梯度下降规则的 BP 学习算法也存在学习速度缓慢, 容易陷入局部极小、振荡而导致难以收敛以及网络结构难以确定等缺陷<sup>[6]</sup>, 而这些都是实际应用的关键问题. 近年来, 很多学者对 BP 算法进行了一些改进<sup>[2, 3, 6]</sup>, 包括引入遗传算法(GA)进行学习优化和确定网络结构、动态改变学习速度、引入动量项等, 但仍不能从根本上改变 BP 算法存在的上述问题; 另外, 在遥感影像分类中, 地学知识的参与是进一步提高分类精度的关键, 而 BPNN 一般是通过将知识转换为与输出类别相对应的输入向量方法来融合知识<sup>[4]</sup>的, 因此往往存在表达上的局限性.

径向基函数(Radial Basis Functions, RBF)神经网络(RBFNN)一定程度上克服了 BPNN 的上述缺点. RBFNN 不但可根据调节 RBF 函数获得复杂的映射关系, 而且具有结构简单、学习速度快和可

融合知识等优势. RBFNN 是 Powell 等于 80 年代首先提出的, 以后 S. Tan (1996)、A. Krzyzak (1996) 等人又在 RBF 函数定义、学习算法等方面进行了深入的发展<sup>[7-12]</sup>; Y. Leung (1996) 等则在 RBFNN 模型基础上进行了从大量样本集中自动快速提取模糊和非模糊规则的工作<sup>[2]</sup>. 本文的重点是探讨如何建立 RBFNN 的遥感影像分类模型及如何实现地学知识融合的问题.

## 1 径向基函数神经网络

### 1.1 径向基函数映射原理

径向基函数神经网络是参数化的统计分布模型与非参数化线形感知器模型相结合的一种前向神经网络模型<sup>[7, 8]</sup>. 根据模式识别理论, 对低维空间的非线性可分问题总可映射到一个高维空间, 并使其在此高维空间中线性可分. RBF 的映射原理就是通过用分解的统计密度分布来表示稀疏样本空间中的非统计混合密度分布, 然后用神经网络连接结构来获得各类别的映射.

RBFNN 的网络结构为 3 层(如图 1 所示). 中间层表示特征空间按照一定密度分布的中心点, 样本输入分别对应各中心点, 通过一个非线性的径向基函数得到中间层的竞争输出, 中间层的状态包括中间层结点的个数( $m$ )及其状态值, 反映了样本空间中数据的离散分布状况; 输出层输出则是对中间层 RBF 基函数输出的线性映射. 因此 RBFNN 实质是非监督的聚类方法和有监督的线性单层感知器方法的组合而实现非线性映射的神经网络模型. 从输入层到中间层的学习可通过一般的聚类算法形成中间层的状态; 而从中间层到输出层的学习可通过最小均方误差(LMS)算法实现线性映射关系.




图 1 RBFNN 网络结构

## 1.2 RBFNN 的学习算法

### 1.2.1 中间层(J) 的状态确定

中间层(J) 可以通过对样本数据的聚类来获得, 而且可视实际情况, 采用迭代自组织数据分析法 (ISODATA)、自组织映射网络 (ART) 等多种聚类方法. 现以 FUZZY-ISODATA 方法为例, 介绍如何确定 RBFNN 中间层 H 状态的设置<sup>[12]</sup>: 设样本数据集  $\mathbf{X} = \{x_1, x_2, \dots, x_k, \dots, x_n\}$ . 聚类类别为  $c$  类, 即中间层个数为  $c$ . 设有  $c \times n$  阶矩阵  $U$ ,  $u_{ik}$  表示数据  $x_i$  是否归属类  $A_i (i=1, \dots, c)$ , 在网络结构中, 它即为输入层与中间层的权值. ISODATA 采用最小平方误差和作为分类准则<sup>[12]</sup>, 通过迭代, 获得聚类中心  $\mathbf{V}$ :

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left( \frac{d_{ij}}{d_{jt}} \right)^{\frac{2}{m-1}}} \quad v_i = \frac{\sum_{k=1}^n u_{ik} x_k}{\sum_{k=1}^n u_{ik}} \quad (1)$$

中间层(J) 的状态可由聚类中心点集  $\mathbf{V}$  表示, J 的结点个数等于聚类数  $c$ . 虽然  $c$  越大, 反映的样本空间分布越稀疏, 其 RBF 映射能力越强, 但同时也增加了网络结构的复杂性和计算量. 因此一般可通过预先分析样本数据集的复杂性来确定中间层的个数  $c$ .

### 1.2.2 中间层到输出层的学习方法

中间层(J) 和输出层(K) 采用单层感知器 (SLP) 的互连结构, 每个连接上都附带权值  $W_{jk}$ .  $W_{jk}$  通过最小均方误差 (MSE) 法则进行迭代调整<sup>[1]</sup>:

$$W_{jk}(t+1) = W_{jk}(t) + \Delta W_{jk} \quad (2)$$

式(2)中, 调整项  $\Delta W_{jk} = \eta \delta_k O_k$ , 其中  $\eta (0 < \eta < 1)$  为学习速率;  $\delta_k$  为输出层结点  $k$  的误差, 即  $\delta_k = T_k - O_k$ ,  $T_k$  为期望输出,  $O_k$  为实际输出.

### 1.2.3 RBFNN 映射过程

RBFNN 的映射过程是由非监督的聚类形成的密度分布, 再通过线性组合形成映射关系. 模式向量则通过非线性径向基函数 (RBF) 以获得与各个聚类中心的竞争归属. RBF 函数可根据实际的分布确定, Lippmann R P 等定义了一组统计意义的 RBF 函数<sup>[7]</sup>, 但一般最常用的仍然是通过高斯 (Gaussian) 基函数表示:

$$O_j = e^{-\frac{(\mathbf{X} - \mathbf{V}_j) \cdot (\mathbf{X} - \mathbf{V}_j)}{2\sigma_j^2}} \quad (3)$$

式(3)中,  $O_j$  为中间层  $j$  的输出值,  $\mathbf{X}$  为模式向量,  $\mathbf{V}_j$  为与中间层对应的聚类中心模式向量,  $\sigma_j^2$  为标准化参数, 它表示聚类中心点  $\mathbf{V}$  的分布宽度, 一般可根据  $\mathbf{V}$  和训练样本集中归属于该类别的平均距离决定, 即:

$$\sigma_j^2 = \frac{1}{M} \sum_{\mathbf{X} \in \mathbf{V}_j} (\mathbf{X} - \mathbf{V}_j) \cdot (\mathbf{X} - \mathbf{V}_j) \quad (4)$$

根据式(4), 输入向量分别对应  $\mathbf{V}$  中各点, 进行竞争输出. 若  $\mathbf{X}$  在  $\mathbf{V}$  的一定范围内, 当  $\mathbf{X}$  越接近于  $\mathbf{V}$ ,  $O_j$  值就越接近于 1.

输出层 K 的输入  $I_k$  为  $O_j$  从中间层 J 与输出层 K 之间的线性组合:  $I_k = \sum W \cdot O_j$ ; 而  $k$  的输出为竞争输出, 即

$$O_k = \begin{cases} 1, & \text{如果 } O_k = \max(O) \\ 0, & \text{否则} \end{cases}$$

输出层的竞争获胜者为模式向量  $\mathbf{X}$  的映射类别.

## 2 RBFNN 遥感影像分类模型

RBFNN 是以径向基函数映射理论为基础的多层前向神经网络, 可实现复杂数据的分类. 图 2 为 RBFNN 遥感影像分类模型的流程结构, 主要过程包括遥感数据聚类处理 (A)、RBFNN 学习 (B)、遥感影像分类 (C) 3 个模块. 其中遥感数据聚类处理模块包括遥感数据采样、生成样本数据集及样本数据集通过聚类, 生成 RBFNN 的中间层结点 2 个子模块; RBFNN 的中间层和输出层之间的权值  $W$  通过对样本数据的输入 ( $X, Y$ ) 进行梯度下降运算使得误差达到最小, 最后 RBFNN 达到稳定态 (包括中间层状态、权值状态); 输入遥感影像的向量  $\mathbf{X}$ , 通过 RBF 函数得到中间层的输出值 ( $O_i$ ), 再与  $W$  线性乘积获得输出层的输入, 通过最大值竞争获得  $\mathbf{X}$  的归属类别 (C).

大多 RBFNN 中, 是用普通聚类方法获得中间层结点, 并用普通高斯分布函数作为 RBF 函数. 而实际的遥感影像分类模型中, 可以通过调整中间层的状态和 RBF 函数来融合地学知识, 这一定程度上可使分类模型更接近于实际的地学分布规律, 从而获得更高的分类精度. 另外可通过以下两种方法来进行 NN 与知识的融合:

(1) 通过对遥感影像复杂性的分析, 确定 RBFNN 的中间层结点状态. 主要方法包括动态聚类、直方图分析、决策树分析、实际影像覆盖区域的地物分布复杂性分析等等. 如, 利用遗传算法优化理论, 通过定义融合地学知识的样本分布适应函数 ( $f$ ), 使  $f$  值最大, 获取分布参数 (包括中心点向量、分布形状等), 逐步分离样本空间中的点集, 直到最后获得反映影像复杂程度的全部空间中心点集分布.

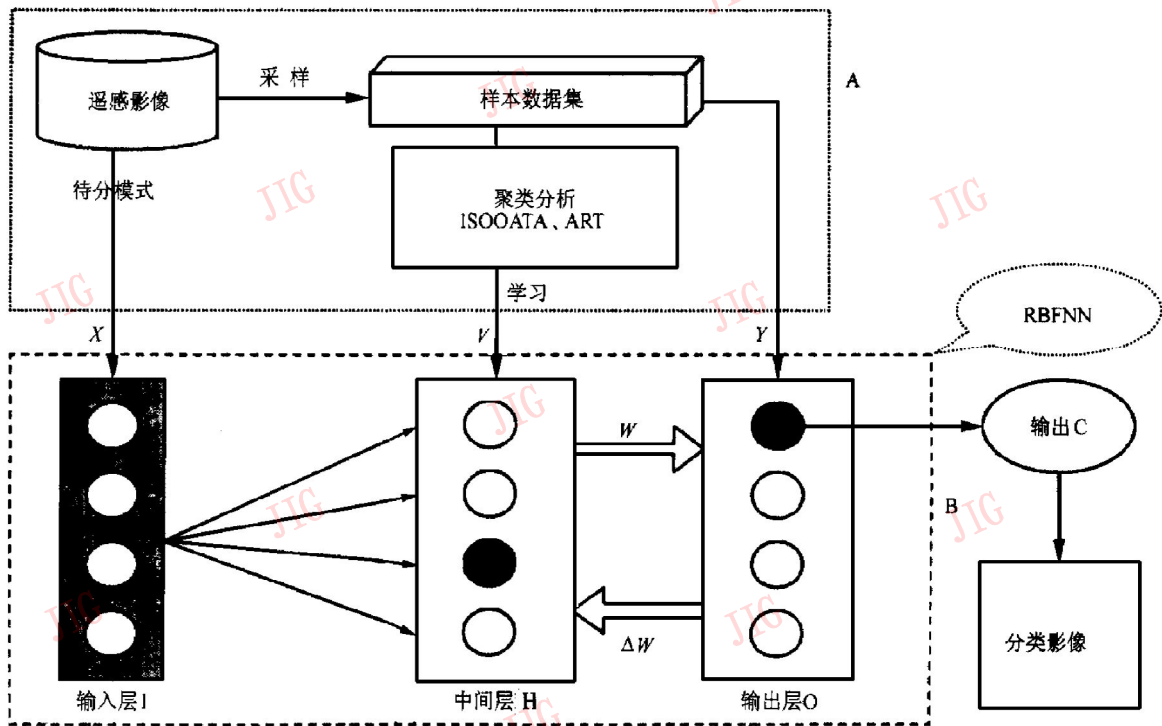


图 2 RBFNN 遥感影像分类流程图

(2) 基于规则的 RBF 函数的融合. RBFNN 中的基函数反映了围绕中心点(中间层结点状态)的分布, 在无先验知识状态下, 一般采用高斯正态分布函数. 同样, 如果已知一定规则的样本分布规律(如地物光谱范围、植被指数等), 可以通过修改 RBF 函数来反映样本的空间分布状况.

### 3 实例分析

本次试验工作, 以香港元朗地区为实验区, 在 RBFNN 分类模型基础进行遥感影像土地覆盖分类试验, 然后对分类结果进行了精度分析, 并与 BPNN 方法进行了综合比较分析.

香港-新界-元朗(Yuen Long)地区, 位于香港特别行政区的西北部(经度  $113^{\circ}58' - 114^{\circ}07'$ , 纬度  $22^{\circ}21' - 22^{\circ}31'$ ). 该地区北部与深圳市区接壤, 东部为深圳湾. 主要包括米埔自然保护区、元朗新市镇、元朗平原、林村山、大榄山等区域. 区内鸡公岭海拔最高, 达 572m, 区内主要地类有森林、草地、裸岩地、水体、居民建筑用地、道路、经济林地、耕地、沼泽地、滩涂等, 各地类间错综分布, 十分复杂.

选用的遥感资料为 1996 年 3 月 3 日 Landsat 10-TM 数据, 当时天气情况晴好. 图象大小为 328 行  $\times$  328 列. 本次工作是在自行开发的遥感地学理解系统(GRS99)上完成的, 运行平台为 Pentium 100.

通过对该实际情况的了解和目视解译, 把该区域大致分为以下八大地类:

- C1: (海洋) 水体      C2: 河流、水塘(淡水)
- C3: 红树林            C4: 城镇区
- C5: 道路                C6: 裸地
- C7: 林地                C8: 草地

其中 C1 和 C2、C4 和 C5 在样本空间上交错分布, 很难分清. 我们选用 6 个波段数据 TM 作为 RBFNN 的输入向量, 即  $A = (CH1, CH2, CH3, CH4, CH5, CH7)$ , 其中 CH1 为蓝光波段, CH2 为绿光波段, CH3 为红光波段, CH4 为近红外波段, CH5 和 CH7 为中红外波段(分别是  $1.55\mu m \sim 1.75\mu m$  和  $2.08\mu m \sim 2.35\mu m$ ). 而 RBFNN 中对应的输出向量则表示对应象元点的类别序号, 如 C1 为  $(1, 0, 0, 0, 0, 0, 0, 0)$ , C2 为  $(0, 1, 0, 0, 0, 0, 0, 0)$ , 依此类推.

通过目视解译, 选择了 900 个训练样本集, 再根据与实际土地利用现状图对照, 又采集了 500 个测试样本集. 首先通过训练样本集对 RBFNN 神经网络进行训练, 然后输入测试样本以分别获得各分类类别, 并通过与实际目标类别相比较, 得出分类的误差矩阵(如表 1 所示), 其中 RBFNN 网络中间层采用 30 个结点, 学习速率  $\eta = 0.01$ , 使用学习时间为 270s, 测试精度达到 90.90%. 我们另外也用 BP 神经网络方法(BPNN)对同样本数据集进行训练和测试, 测试结果如表 2 所示. BPNN 的网络结构为 3 层, 即输入层、隐层、输出

层它们分别有 6、12、8 个结点,大致需要通过 600s 左右约 10 000 次循环学习后,网络达到基本收敛,测试精度为 88.71%。通过比较,不难发现: RBFNN 神经网络方法获得的分类结果,在精度上可以达到、甚至优

于 BPNN 方法所获得的分类精度,但消耗的机器时间却比 BPNN 方法少,而且用 RBFNN 方法对于相似程度很高的类别的区分度要比 BPNN 方法好,如城镇 C4 和道路 C5。

表 1 RBFNN 分类方法误差矩阵( Time = 270s) 90.90%

实际	分类								Total
	C1	C2	C3	C4	C5	C6	C7	C8	
C1	59	6	0	0	0	0	0	0	65
C2	1	50	0	2	0	0	0	0	53
C3	0	0	65	0	0	0	0	0	65
C4	0	4	0	53	3	8	0	0	68
C5	0	0	0	15	26	0	0	0	41
C6	0	0	0	0	1	82	0	1	84
C7	0	0	5	0	0	0	70	0	75
C8	0	0	0	0	0	0	0	49	49
Total	60	60	70	70	30	90	70	50	500

表 2 BPNN 分类方法误差矩阵( Time = 600s) 88.71%

实际	分类								Total
	C1	C2	C3	C4	C5	C6	C7	C8	
C1	60	2	0	0	0	0	0	0	62
C2	0	52	0	1	0	0	0	0	53
C3	0	0	70	0	0	0	0	0	70
C4	0	6	0	39	7	5	0	0	57
C5	0	0	0	27	21	1	0	2	51
C6	0	0	0	3	1	83	0	0	87
C7	0	0	0	0	0	0	70	0	70
C8	0	0	0	0	1	1	0	48	50
Total	60	60	70	70	30	90	70	50	500

选择合理的中间层结点也是 RBFNN 分类模型的一个关键问题.如表 3 所示,我们分别选用 10、12、15、18、20、22、25、28、30 个中间层结点数(M),即首先将样本空间通过聚类方法划分为一定类别的区域,然后分别获得分类结果.图 3 显示平均精度随

中间结点个数关系的变化趋势,即:随着 M 增加,分类精度虽有所提高,但是学习时间也大幅度增加;且 M 增加到一定的限度,分类精度提高缓慢,因此需要综合考虑学习速度和精度两者关系,选择合适的中间层结点数。

表 3 中间层个数选择与分类结果关系列表

		BPNN	RBFNN 中间层结点数								
			10	12	15	18	20	22	25	28	30
学习时间(s)		600	46	54	73	96	125	148	174	216	260
精度 (%)	C1	100.0	98.33	90.00	96.67	96.67	96.67	96.67	96.67	96.67	96.67
	C2	86.67	61.66	83.33	88.33	83.33	83.33	83.33	83.33	83.33	83.33
	C3	100.0	98.57	92.86	92.86	92.86	92.86	92.86	92.86	95.71	95.71
	C4	55.71	57.14	57.14	58.57	67.14	74.29	74.29	74.29	75.71	75.71
	C5	70.00	76.67	80.00	83.33	83.33	83.33	83.33	86.67	86.67	86.67
	C6	92.22	87.77	91.11	91.11	91.11	90.00	90.00	90.00	90.00	91.11
	C7	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
	C8	96.00	46.00	50.00	86.00	86.00	86.00	98.0	98.00	98.00	98.00
	平均	88.71	78.27	80.57	87.11	87.55	88.31	89.81	90.22	90.76	90.90

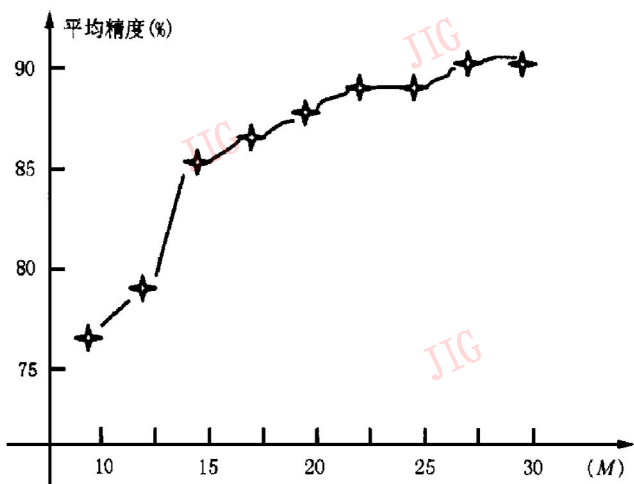


图 3 平均精度与中间结点数关系

### 4 结论与展望

RBFNN 是融合了参数化的高斯统计密度分布模型与非参数化的单层感知器映射模型的一种前向神经网络模型,RBF 的映射原理是通过分解的统计密度分布来拟合样本空间中的复杂稀疏分布,然后用神经网络感知器模型获得与类别相对应的线性映射关系.本文在 RBF 映射理论基础,针对遥感分类的具体问题,建立了 RBFNN 遥感影像分类模型,并通过实际的土地覆盖分类,证实了基于 RBFNN 的遥感影像分类方法与传统神经网络方法相比较具

有一定优势.

RBFNN 遥感应用模型还需要在以下几方面得到进一步的发展:

(1) RBFNN 的另一个优势是, 在其参数化的函数式表达模型中, 已使得地学知识的融合成为可能. 因此, 探索 RBF 函数的知识表达模型是 RBFNN 进一步在遥感地学分析应用中的关键问题;

(2) RBFNN 遥感分类的精度与网络结构有关, 选取合适的网络结构则需要通过分析遥感地学分析问题的复杂性来决定. 如何量化地进行遥感影像复杂性的分析是与 RBFNN 应用密切相关的问题之一.

### 参 考 文 献

- 1 Stephon I Gallant. Neural Network Learning and Expert Systems. Cambridge, Massachusetts: The MIT Press, 1992.
- 2 Yee Leung. Intelligent spatial decision support systems. In: Advances in Spatial Science. Germany: Springer, 1997.
- 3 Atkinson P M and Tatnall A R L. Neural networks in remote sensing. INT J Remote Sensing, 1997, 18 (4): 699~ 709.
- 4 Benediktsson J A, Swain P H, Ersoy O K. Neural network approaches versus statistical methods in classification of multi-source remote sensing data. IEEE Transactions on Geo-science and Remote Sensing, 1990, 28: 540~ 552.
- 5 Bischof H, Schneider W, Pinz A J. Multi-spectral classification of landsat images using neural networks. IEEE Transactions on Geo-science and Remote Sensing, 1992, 30: 482~ 490.
- 6 Paola J D, Schowengerdt R A. A review and analysis of back-propagation neural networks for classification of remotely-sensed multi-spectral imagery, INT. J. REMOTE SENSING, 1995, 16: 3033~ 3058.
- 7 Lippmann R P Neural networks, bayesian a posteriori probabilities, and pattern classification. In: From Statistics to Neural Networks—Theory and Pattern Recognition Applications, Cherkassky V, Friedman J H. (eds) 1994, 83~ 104, Springer-Verlag.
- 8 Girosi F. Regulation theory, radial basis functions, and networks. In: From Statistics to Neural Networks—Theory and Pattern Recognition Applications, Cherkassky V. Friedman J H (eds). Springer-Verlag, 1994, 166~ 187.
- 9 Tan S, Tsoi A C, Back A, and Ann-Kai Chan. A new worst-case training algorithm for RBF neural networks. In: Proceedings of ICONIP'96-Hong Kong, 1996, 174~ 179.
- 10 Krzyzak A, Xu L. Optimal radial basis function nets with applications to nonlinear function learning and classification. In: Proceedings of ICONIP'96-Hong Kong, 1996, 271~ 274.
- 11 Bapat P, Hegde M V, Naraghi-Pour M. Fault tolerant radial basis function networks. In: Proceeding of World Congress on Neural Networks—San Diego, 1994, III: 463~ 469.
- 12 Witold Pedrycz, James Waletzky, Fuzzy clustering with partial supervision, IEEE Transactions on Systems, Man and Cybernetics—Part B: Cybernetics, 1997, 27, (5): 787~ 795.



骆剑承 1970年生, 1991年毕业于浙江大学地球科学系遥感专业, 现为中国科学院地理研究所资源与环境信息系统国家重点实验室博士生. 主要研究方向为遥感图象处理、神经计算和进化计算、遥感地学分析、空间信息认知等.