

# 遥感图像中多分类问题的树型 RBF 神经网络方法

苑进<sup>1</sup>, 刘雪美<sup>1</sup>, 江涛<sup>2</sup>

(1. 山东农业大学机械与电子学院, 泰安 271018; 2. 山东科技大学地球信息科学与工程学院, 泰安 271019)

**摘要:** 该文探讨 RBF 映射理论在遥感影像分类中的具体算法和实现过程, 给出了基于自适应聚类间距的快速聚类算法 (AGDFC) 的 RBF 网络训练算法和树型 RBF 网络构造算法。然后以实际的遥感土地覆盖分类为例, 通过与最大似然分类算法 (MLC) 相比较, 对分类过程和结果进行了综合分析, 实验结果表明树型 RBF 网络方法在学习速度、网络结构、分类精度等方面具有一定的优势。

**关键词:** RBF 神经网络; 遥感图像; 分类

中图分类号: TP75; P208

文献标识码: A

文章编号: 1002-6819(2004)05-0173-05

## 0 引言

遥感技术在农业上的应用主要有监测耕地变化、土地开发评价以及农作物估产。高精度遥感分类技术是提高各应用精度的关键。以农作物估产为例, 常常涉及到多地物的分类, 并且要求不同的分类等级同时存在。这就为提高分类精度增加了难度。使用分层神经网络是一种较好的方法。

遥感图像分类中, 当类别数目较大时, 使用单一神经网络将导致网络结构复杂、训练时间以指数增长、分类性能下降。分层处理技术也是遥感图像分类技术的发展方向之一, 近来被广泛用于遥感图像分类。它的主要优点是: 可以很好地处理高维遥感数据; 可以很好地处理不规则分布的复杂数据; 可以有效地提高分类精度。Jayantha 等人的实验均证实了这种分层处理技术的有效性<sup>[1]</sup>。

本文首先提出聚类间距可变的聚类系统, 并将之应用于 RBF 网络的学习参数的确定, 而后把 RBF 网络和分层技术结合起来, 提出了分层神经网络的概念, 使之能集中这两种技术的优点, 获得更好的分类效果, 同时解决神经网络的学习时间和网络性能的问题<sup>[2]</sup>。

## 1 基于自适应聚类间距的快速聚类算法

通过分析发现, 人脑的聚类判断主要是根据对象整体和局部分布情况所形成的反差对比<sup>[3]</sup>。对图 1 人们容易将其归为 3 个聚类。这里人所依据的基本规则是: 同一聚类中对象应相距较近, 而个聚类间距离则应较远; 至少从对象整体分布情况看, 其聚类结果应该符合这一规则要求。此算法称为基于整体聚类间距的快速聚类 (Global Distance Fast Cluster GDFC)。

使用上述算法可以有效解决 RBF 神经网络训练参数中隐层径向基函数的中心值和宽度值以及隐层神经元数目的确定。但是对训练网络进行分析发现: 当样本集合决定的模式空间中, 待分类得的类别较多并且类别

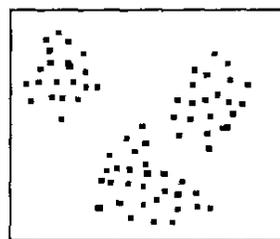


图 1 二维样本聚类分布

Fig 1 Clustering distribution of 2-D samples

疏密程度不同, 即分类数目大和类间距变化较大时, 上述算法聚类的结果不尽人意。因为对于采用有教师学习方式 RBF 网络来说, 它的学习样本包含了相对于 RBF 网络的输入输出信息, 即样本在模式空间中的特征值和该样本所属类别, 这个信息可以用来指导学习。如图 2, 在二维特征空间中有 3 个聚类, a 图的聚类效果良好, 其原因在于 3 个聚类分别被超球体的并集所包含。但是在 b 图中的分类结果却出现了一个超球体同时包含了类 1 和类 2。这样的聚类结果使 RBF 网络在学习的过程中隐单元非线性变换功能和输出单元线性变换功能不清晰, 于是训练的网络权值不能完整体现输出层的功能结构, 因而不利于 RBF 网络的分类精度。同时网络学习的第二阶段中确定网络权值的收敛速度也大大降低。因此必须保证在某一聚类中, 多维超球体的并集不包含其他聚类的样本。

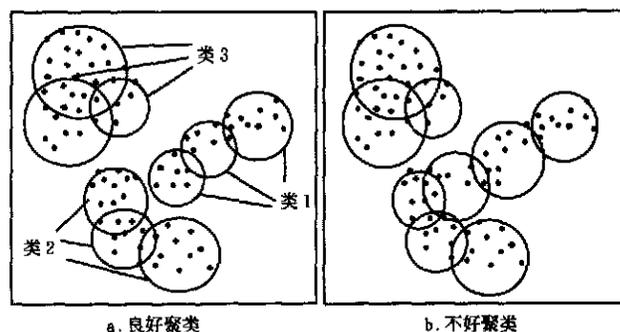


图 2 GDFC 的聚类示意图

Fig 2 Clustering of GDFC

对于该问题有两种解决方案:

收稿日期: 2004-02-06

作者简介: 苑进(1972-), 男, 山东泰安人, 讲师, 山东省泰安市山东农业大学机械电子学院, 271018

1) 遍历所有聚类中被超球体覆盖的样本, 找出同一超球体但不同属于一个类别的样本, 然后将该超球体在一个类别细分为不同的子超球体。图 3a 给出超球体分解后聚类示意图。该方法对样本敏感。

2) 将上节所述算法的平均距离  $D$  作动态调整, 使其所有的聚类均没有同超球体包含不同类别样本的现象。一般地, 平均距离  $D$  作减小处理效果较好。图 3b 给出了减小聚类间距后的聚类示意图。

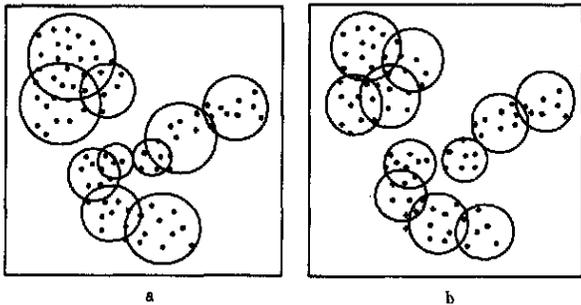


图 3 超球体分解后的聚类与减小聚类间距  $D$  后的聚类示意图

Fig 3 Clustering of hypersphere decomposed and clustering of decreased global distance

上述两种方法均可以再进行基类合并过程得到更少的子类数, 以便于 RBF 网络的简化和较高泛化能力。如果能保证样本集构造的准确性和正确性, 例如对某些非线性函数的仿真或建模等过程, 第一种方法能较好的缩短聚类时间。但是如果在样本集中存在错误样本, 这种方法对网络性能影响较大, 而第二种方法对样本集构造不敏感。由于各超球体是在各样本自组织竞争的情况下得到的, 反映了样本空间的固有特征, 因而对少量错误样本有较强的容错性。

在遥感数据分类中, 样本是由具有一定遥感图像人工判读能力的专业人员给出的, 具有一定的主观性。另外对于 TM 卫星数据而言, 其采样点的分辨率较低, 因而有大量的混合像元的存在, 这样在人工取点采样时很难避免有少量错误点存在。综合考虑以上原因, 本文选择第二种方法进行聚类的后续处理。基于自适应聚类间距的快速聚类算法 (Adaptive Global Distance Fast Cluster A GDFC):

- 1) 始化聚类平均间距  $D$ , 设置聚类间距变化率  $\lambda$ , 其一般取为 0.9。读入样本集数据。
- 2) 调用 FCGG 算法对样本集聚类运算。
- 3) 循环遍历各基类。
- 4) 循环遍历基类中的各样本的类属记号属性。
- 5) 如果存在不同样本的类属记号,  $D = \lambda \times D$ , 转到 2)。
- 6) 输出基类数量及各基类的中心坐标和半径属性。

第 6 步的输出结果即可分别作为 RBF 网络的隐单元数目、各隐单元中心位置以及宽度。聚类平均间距  $D$  的大小决定了 RBF 网络的复杂程度,  $D$  越小, 所得到的聚类数目就越多。基于聚类间距可变的聚类系统也是对

人视觉逆松弛化过程的模拟, 其中  $D$  表示眼睛对对象的放松尺度或观察距离, 初始时选择  $D$  为一极大值, 即视觉放松尺度为最大, 观察距离也足够远, 此时被观察对象融合为一个点; 随着  $D$  值缓慢缩减, 即视觉放松的尺度空间或观察距离逐渐减小, 对象中一定距离范围内的点开始分解为新的单元, 观察对象的每一个单元被看作一类; 最后当  $D$  值减小到一个极小值时, 视觉注意力为最大, 观察的事物越细致。如图 4 所示。

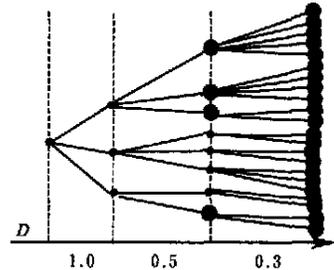


图 4  $D$  变化时的聚类效果

Fig 4 Clustering effect of varying  $D$

## 2 大类别分层策略

对大类别分类问题<sup>[4]</sup>, 可考虑以下 3 种方法:

1) 为每一类别建立一个网络。

将一个  $N$  分类问题看成  $N$  个单独类别确认问题的组合, 可分别建立  $N$  个网络, 每个网络仅需确认一个类别, 训练数据除包括类别本身的数据外, 训练数据还应包括类别集合中所有其他类别的数据, 这样一方面存在训练数据的均衡问题, 另一方面随着  $N$  的增大, 网络的训练数据量也随之增大, 进而使得网络的训练时间随着类别数的增大而增加。

2) 两分类网络方法。

如果一个分类问题  $N$  类可分, 则这  $N$  类中的任何两类间一定可分。反之, 在一个  $N$  分类问题中, 如果已知其任意两两可分, 通过一定的组合法则, 可由两两可分来最终实现  $N$  类可分。随着  $N$  的增大, 网络的训练数据量也随之增大, 进而使得网络的训练时间随着类别数的增大而增加, 故仍未从根本上解决大类别分类问题。

3) 采用树型网络结构。

从模式的可分性角度考虑, 将分类问题首先归为一些简单、易分类的基本类, 经过分类器的处理后, 基本类的类别数目将有所减少, 再对这些类别构造下一层的分类器, 下层各分类器完成各基本类中包含的类别的分类。这样便构成树型结构的分类器, 大类别问题就被逐级分解为一系列的小类别问题, 本文选择此种方法构造分层神经网络。

## 3 自适应树型网络结构的分类机理

由于人们进行专题信息提取的目的不同, 所以给出的待分类地物的类别也不同。某些类地物与其他类地物的光谱特性截然不同, 而对于一些地物的光谱特性则与某部分地物相近或相似。这样遥感图像的分类常常涉及到待分类地物存在可分性的不同, 也即当地物间的光谱

特性截然不同时, 聚类的类间平均距离大一些, 可分性好; 当地物间的光谱特性相近或相似时, 聚类的类间平均距离要小一些, 可分性差, 见图 5。此时本文利用上一层的 RBF 网络选择大的聚类平均距离  $D$  进行对各基本类地物的粗分类, 其中各基本类可能包含几个细节类, 也可能包含基本类和细节类。图 6 给出了一个树型分类的原理图。所谓细节类是指最终的待分类地物。对于基本类将进一步使用 RBF 网络分类器进行分类, 直到所有的基本类细分为细节类。图 7 给出了二维空间中的样本集逐层分类的示意图。(a) 树型 RBF 网络中第一层将 9 类样本分成 4 个基本类; (b) 将 (a) 虚矩形框中基本类的类间平均距离缩小后, 第二层 RBF 分类器将其分解为 2 个细节类; (c) 将 (b) 虚矩形框中基本类的类间平均距离缩小后, 第三层 RBF 分类器其分解为 3 个细节类。在此过程中, RBF 网络的隐单元的中心和宽度由缩小的聚类平均距离  $D$  在新的样本集中聚类得到。该样本集是总样本集的子集, 只包含下层基本类或细节类中的样本。在下层的分类中, 由于分类器减少了与其他类别的耦合以及其他样本的干扰, 因而能进一步提高分类精度。

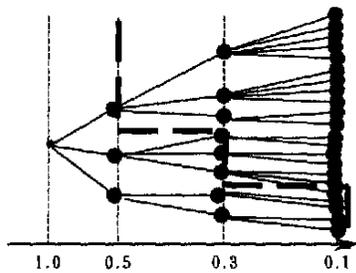


图 5 地物分类要求的分类层面

Fig 5 Hierarchy demanded by classification

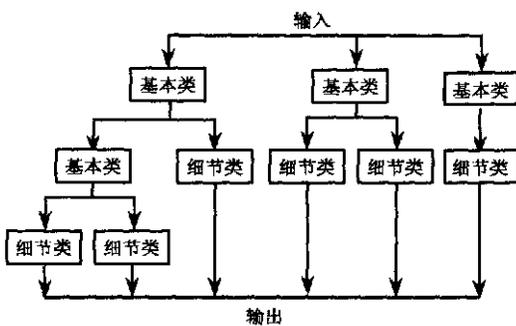


图 6 树型分类原理图

Fig 6 Principle of tree type classification

这样的树型 RBF 神经网络抛弃了单个 RBF 网络的单一特征空间进行决策面的分割, 而是将不同粒度下的样本特征空间作为解空间, 并且树的形状是由样本在特征空间中的分布特点决定的, 所以使其具有更好的分类适应性并且训练时间短、分类精度高和精简的网络结构。

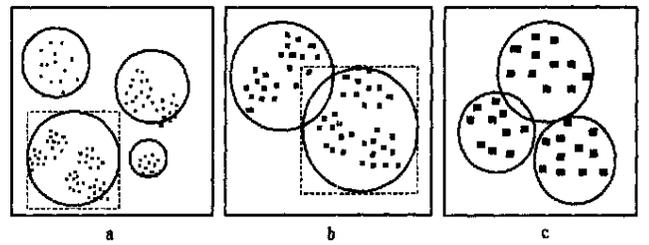


图 7 二维空间中的样本集逐层分类的示意图

Fig 7 2-D sample collection classified by hierarchical structure

### 4 自适应树型 RBF 网络构造的算法

- 1) 读入学习样本文件, 将各类样本数据放入动态链表中。将所有的类别看作一个基本类。
- 2) do {
- 3) flag= FALSE。
- 4) 遍历已有的树型结构, 寻找可继续分割的基本类。
- 5) 计算聚类平均距离为  $D = Range / \sqrt{N}$ , 其中 Range 是对应于当前基本类的所有样本的所有特征值中的最大值和最小值之差。
- 6) 计算各类样本集的中心位置  $C_i$ 。
- 7) 计算所有的类样本集中心间的欧氏距离  $D_{ij}$ 。
- 8) 如果  $D_{ij} < D$ , 则将第  $i$  类与第  $j$  类合并为新类, 从新计算类样本集的中心位置  $C_i$ , 同时将  $i$  和  $j$  记录在类别转换表中。Flag= TRUE; 否则, 转到 4), 直到所有类不再合并。
- 9) 重新统计各新类的样本集, 在此得到的一个新类即为一个基本类。
- 10) 记录该层网络结构。
- 11) }while(flag) //如果当前层有类别的合并, 则继续下一层的构造。否则所有的类已变为细节类, 树型结构构造完毕。

### 5 遥感地物分类实例分析

本次试验工作, 以泰安市区和市郊地区为实验区, 在 RBFNN 分类模型基础进行遥感影像分类试验, 然后对分类结果进行了精度分析, 并与最大似然分类 (MLC) 方法进行了综合比较分析。

#### 5.1 遥感图像的选取

泰安市属山东丘陵, 地形地貌较为复杂。实验区内主要反映的地类有裸岩地、水体、居民建筑用地、道路、林地、农田等, 各地类间错综分布, 十分复杂。

选用的遥感资料为 1994 年 9 月 6 日 Land-sat10-TM 数据。图像大小为 566 行  $\times$  1022 列, 对应区域面积近 470  $km^2$ 。本次工作是在自行开发的遥感地物识别系统 (RSR1.0) 上完成的。

#### 5.2 遥感图像的分类分析

通过对该区域实际情况的了解和目视解译, 把该区域大致分为以下 9 大地物, 分类后用相应的颜色表示该类地物:

代号	C1	C2	C3	C4	C5	C6	C7	C8	C9
类名	水体	城市居民点	树林	裸岩	裸地	农田	村庄	河床	阴影
颜色	红色	绿色	蓝色	黄色	品红色	青色	棕色	绿棕色	黑色

其中 C1、C7 和 C9; C4 和 C3 在样本空间上交错分布, 很难分清。我们选用 3 个波段数据 TM 作为 RBFNN 的输入向量, 即  $A = (CH2, CH4, CH7)$ , 分别为绿光波段、近红外波段、中红外波段。而 RBFNN 中对应的输出向量则表示对应象元点的类别序号。通过目视解译, 再根据与泰安市土地利用现状图和泰山区航空照片对照, 选择了 1000 个训练样本集, 1000 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 58 个结点, 最大学习次数 100, 类吸引强度 1.15, 学习速率  $\eta = 0.01$ , 使用学习时间为 30 s, 测试精度达到 90.80%, Kappa 系数<sup>[5]</sup>为 0.8966。

我们另外也用 ERDAS 软件对相同波段的遥感数据使用 MLC 算法<sup>[6]</sup>进行训练和测试, 由于我们无法获得 ERDAS 的样本集文件, 所以没有使用相同的学习文件。MLC 算法分类的误差矩阵(如表 2 所示), 测试精度为 85.70%, Kappa 系数为 0.8392。

表 3 是 MLC 和 RBFNN 使用的样本个数的比较, 可以看出 RBFNN 使用了很少的样本个数获得了更好的分类效果。

表 1 RBFNN 分类方法误差矩阵

Table 1 RBFNN classification error matrix

实际	分 类									合计	结果误差 /%
	C1	C2	C3	C4	C5	C6	C7	C8	C9		
C1	102	0	0	0	0	0	5	0	6	113	9.7
C2	0	102	0	6	0	0	0	0	0	108	5.5
C3	0	0	78	15	0	9	0	0	0	102	23.5
C4	0	10	12	84	0	0	0	0	0	104	21.1
C5	0	0	0	0	117	0	0	0	0	117	0
C6	0	0	3	0	0	122	0	0	0	125	2.4
C7	5	0	0	0	0	0	93	0	4	102	8.8
C8	0	0	0	0	0	0	0	112	0	112	0
C9	9	0	0	0	0	0	8	0	88	105	16.1
合计	116	112	93	105	117	131	106	122	98	1000	-
运行误差 /%	12	8.9	16.1	20	0	6.8	12.2	0	10.2	-	-

表格 2 MLC 分类方法误差矩阵

Table 2 MLC classification error matrix

实际	分 类									合计	结果误差 /%
	C1	C2	C3	C4	C5	C6	C7	C8	C9		
C1	96	0	0	0	0	0	7	0	8	111	13.5
C2	0	95	0	8	12	0	0	1	0	116	17.2
C3	0	0	78	10	0	9	0	0	0	97	19.6
C4	0	12	12	81	0	4	0	0	0	109	25.7
C5	0	4	0	0	105	0	0	0	0	109	3.6
C6	0	0	3	6	0	118	0	0	0	127	7
C7	8	0	0	0	0	0	89	0	6	103	13.6
C8	0	1	0	0	0	0	0	111	0	112	0
C9	12	0	0	0	0	0	10	0	84	106	20.7
合计	116	112	93	105	117	131	106	122	98	1000	—
运行误差 /%	12	8.9	16.1	20	0	6.8	12.2	0	10.2	—	—

表 3 MLC 和 RBFNN 使用的样本个数比较

Table 3 Comparison of sample number between MLC and RBFNN

	水体	城市居民点	树林	裸岩	裸地	农田	村庄	河床	阴影
MLC	634	2103	361	2167	894	613	571	688	480
RBFNN	149	155	96	100	104	90	90	118	98

## 6 结 论

通过比较, 不难发现: 分层RBFNN神经网络方法获得的分类结果, 在精度上优于MLC方法所获得的分类精度, 但使用了较少的样本数, 而且用RBFNN方法对于相似程度很高的类别的区分度要比MLC方法好。本文在RBF映射理论<sup>[7]</sup>及树型分层技术基础上, 针对遥感多分类的具体问题, 建立了RBFNN遥感影像分类模型, 并通过实际的土地覆盖分类, 证实了分层RBFNN的遥感影像分类方法与传统MLC方法相比较具有一定优势。

### [参 考 文 献]

- [1] Jayantha E. Hierarchical maximum-likelihood classification for improved accuracies [J]. IEEE Transactions on Geoscience and Remote Sensing, 1997, 35(4): 1122- 1143
- [2] 苑进. 基于RBF神经网络的遥感图像分类和基于结构特征的水体识别[D]. 泰安: 山东科技大学信息学院, 2002
- [3] 朱明, 王俊普. 一种聚类学习的新方法[J]. 模式识别与人工智能, 2000, (3): 262- 265
- [4] 岳喜才, 叶大田, 管桦. 多分类问题的RBF二叉神经网络方法[J]. 空军工程大学学报, 2000, 1(1): 34- 39
- [5] 朱述龙, 张占睦. 遥感图像获取与分析[M]. 北京: 科学出版社, 2000
- [6] 吴连喜, 王茂新. 一种改进的最大似然法用于地物识别[J]. 农业工程学报, 2003, 19(4): 54- 57
- [7] 边肇祺, 张学工. 模式识别(第2版)[M]. 北京: 清华大学出版社, 2000

[1] Jayantha E. Hierarchical maximum-likelihood classification

## RBF neural tree networks for multi-class classification in remote sensing

Yuan Jin<sup>1</sup>, Liu Xuemei<sup>1</sup>, Jiang Tao<sup>2</sup>

(1. College of Mechanical & Electronic Engineering, Shandong Agricultural University, Tai'an 271018 China;

2. College of Geoinformation Science & Engineering, Shandong University of Science and Technology, Tai'an 271019, China)

**Abstract** In this paper, the algorithm and realizing procedures of the RBFNN used in classification of remote sensing image were discussed, and a training algorithm based on Adaptive Global Distance Fast Cluster (AGDFC) and a tree-like hierarchical RBFNN constructing algorithm were. Then, the case of practical application of remote sensing land cover classification in Tai'an region was presented. Through comparing with MLC, classification process and results were synthetically analyzed. Experimental results show that RBF neural tree networks approach has more advantages in training time, network structure, classification precision, etc.

**Key words:** radial basis function neural networks; remote sensing image; classification