

文章编号: 1000-2022(2003) 01-0089-07

基于径向基函数网络的云自动分类研究

蒋德明, 陈渭民, 傅炳珊, 王建凯

(南京气象学院 电子工程系, 江苏 南京 210044)

摘 要: 采用 GMS-5 红外(10.5 ~12.5 μm) 和可见光(0.55 ~0.9 μm) 两通道资料, 采集了 1999 年 7—10 月中国东南沿海 57 区、58 区和 59 区包括晴空在内的 12 类云目标样本 2 912 个, 采样窗尺寸为 8×8 像素, 随机生成训练和测试两个样本子集。对径向基函数网络(radial base function neural network, RBF) 在云分类问题研究中的应用价值进行了全面的测试与分析, 得到了肯定的结论, 提出了优化设计的方法。对 6 类云型分类试验, 平均正确率为 86 %; 对 11 类云型分类试验, 平均正确率为 67 %。采用自组织竞争神经网络实现寻找 RBF 神经网络的隐层神经元中心。在特征空间生成过程中, 采用小波包分解算法实现模式特征抽出。结果表明, 小波包分解特征能很好地描述不同云型的差异。

关键词: 云分类; 神经网络; 卫星图像

中图分类号: P405; P422.15 **文献标识码:** A

云分类问题最早在 20 世纪 70 年代及 80 年代初由英国的 NOWCASTING 计划提出^[1]。随后发展了各种其他的云分类算法, 如多光谱技术^[2]、线性判别^[3]、最大似然估计^[4]、模糊逻辑方法^[5]和灰度等级阈值法^[6]等。

随着模式识别技术的发展, 神经网络模式识别技术逐渐成熟, 并于 20 世纪 90 年代初引进到云分类问题的研究中。Welch 等^[7]对 3 种不同的分类器(1) 传统的逐步判别分析方法(SDA); 2) BP 网络; 3) 概率神经网络(PNN)) 进行了测试比较, 并用于北极地区 5 类极地云和 5 类下垫面目标的识别。他们计算了 200 个光谱和纹理特征量, 用序贯前向选择法(Sequential Forward Selection, SFS) 筛选出其中的 20 个特征量用于分类, 用 Bootstrap 方法计算了各分类器的理论精度, 依次为 85.6 %, 87.6 % 和 87.2 %。Bankert 等^[8]用 PNN 对北半球沿海地区 10 类云进行了分类, 用 hold-one-out 方法测试理论分类正确率为 79.8 %, 用 bootstrap 方法测试理论分类精度为 77.1 %, 如果把云样本广义地分为 5 类(低云, 高层云, 高云, 降水云 and 晴空), 理论正确率为 91.2 %。Miller 等^[9]用 BP 网络对陆地和海面 9 类云进行了实验, 得到测试样本的正确率为 82 %。

香港 City Polytechnic 大学计算机科学系和应用科学系的 Lee 等^[10]用 BP 分类器对 GMS

收稿日期: 2001-12-20; 改回日期: 2002-05-15

基金项目: 国防预研基金项目

作者简介: 蒋德明(1962-), 男, 湖南道县人, 工程师, 硕士, 从事卫星遥感研究工作, 现在湖南省气象科学研究所。

云图中 5 类云进行分类, 分为低云组(积雨云、积云、层积云) 和高云组(卷云、卷层云) 两组分别进行试验, 其中低云组的平均正确率为 60 %, 高云组的平均正确率为 70 %。他们认为分类正确率较国外低的原因是国外使用的 NOAA 和 LANDSAT 资料的空间分辨率远远高于 GMS 资料。白慧卿等^[11-12]用 BP 网络对 GMS 云图 4 类天气尺度云系(冷锋、静止锋、雹暴云团 MCC) 进行了识别实验, 并与统计识别方法进行了比较。

神经网络能够实现一种特殊的非线性变换, 把在低维高度非线性的输入空间变换到由其隐层张成的高维输出空间, 在这个高维空间中能够较容易找到合适的判决表面, 甚至变得线性可分。这与 Fisher 线性判别准则相对应, 可以看作是 Fisher 线性判别的一种非线性多维推广。由于通常的模式分布是非常不规则的, 这就要求所用的模式分类方法在模式空间里形成各种非线性分割平面, 而神经网络分类器能够在模式空间里形成任意复杂形状的判决表面。因而神经网络技术在模式识别中获得了广泛的应用。

径向基函数网络是一种最适合于模式识别任务的神经网络, 它能以任意精度逼近任意非线性函数。但有两个设计难点阻碍了它在实际应用中的推广: 其一是隐单元中心问题; 其二是宽度参数问题。本文设计了一个自组织竞争网络来寻找隐单元中心, 并利用 RBF 网络对 GMS 云图上 11 类云进行了分类试验, 获得了较好的效果。

1 资料与类的定义

本文使用 GMS-5 可见光(0.55~0.9 m) 和热红外(10.5~12.5 m) 两通道资料。两通道的纬向分辨率为 13.22 km, 径向分辨率为 13.03 km。投影方式为 Lambert Conformal Conic 投影, 投影中心在 110 E, 30 N。采样区域为中国东南沿海的 57 区、58 区和 59 区(图 1), 时段为 1999 年 7—10 月。样本窗为 8×8 像素。这些卫星资料直接取自于气象业务网络, 云类的定义也与地面气象观测站的定义保持一致, 目的是为了试验能够面向基层、面向业务应用。

包括晴空在内的 12 类 2 912 个目标样本, 被分解为训练和测试两个样本子集。训练集与测试集的生成原则是: 各类别的训练样本数, 等于所有样本类别中最小的样本数的一半。训练样本由计算机从各类样本总体中随机抽取生成, 剩下的样本则构成测试集。例如: 在对晴空(243 个)、淡积云(618 个)、卷云(207 个) 进行试验时, 因为样本数最少的类别是卷云, 样本数是 207 个, 它的一半是 103 个, 所以训练集的生成方法是从晴空、淡积云、卷云中分别随机抽取 103 个样本, 共 309 个, 构成训练样本矩阵对 RBF 网络进行训练, 剩下的样本用于对训练好的网络进行测试。

类的定义和各类的样本数如表 1 所示。



图 1 采样区域示意

Fig. 1 Sampling area

表 1 云样本的类别定义

Table 1 Definitions of cloud classes

记号	云状	样本数
F00	晴空	243
F21	浓积云和秃积雨云	202
F32	透光高积云	110
F72	复高积云或蔽光高积云	289
F91	鬃积雨云或砧状积雨云	183
F23	卷云	207
F11	淡积云	618
F42	荚状高积云	231
F51	普通层层积云	459
F61	层云或碎层云	111
F81	不同高度的积云和层积云	213
F41	积云性层积云	46

2 特征空间

本文对云模式样本特征的抽出采用小波包 3 层分解的方法。与传统 Fourier 分析相比,小波分析提供了一种窗口区域可变的加窗技术,允许在要求高精度低频信息的地方使用大的时间窗和在高频区使用小的时间窗,因而能够提供更多的模式样本可分性信息。

小波基函数的尺度因子(伸缩因子) a 同时影响小波基函数的时窗宽度($t_a = a \cdot t$)和频窗宽度($\omega_a = \omega / a$,其中 t 、 ω 为小波母函数的时域窗口宽度和频域窗口宽度)。当 a 逐渐增大,基函数 ψ_a 的时间窗 t_a 逐渐变大,而其对应的频域窗口 ω_a 相应减小并且中心频率 $\omega_0 = \omega_0 / a$ 逐渐变低(其中 ω_0 为小波母函数的频域窗口中心),因而在低频部分具有较高的频率分辨率和较低的时间分辨率;相反,当 a 逐渐减小时,基函数 ψ_a 的时间窗口 t_a 逐渐变小,而其频域窗口 ω_a 相应增大,中心频率逐渐升高,因而在高频部分具有较高的时间分辨率和较低的频率分辨率。可见,小波变换是一种变分辨率的时频联合分析方法,同固定时窗的短时傅里叶变换(Short Time Fourier Transform, STFT)相比具有不可比拟的优点。

小波包定义为一个满足关于尺度函数 $\phi(t)$ 和小波函数 $\psi(t)$ 的二尺度方程的函数集合 $\{u_n(t); n \in Z\}$ 。小波包分解是对小波分解(多分辨率分析)的推广,它能为信号提供一种更精细的分析方法。它将频带进行多层次划分,对多分辨率分析中没有细分的高频部分进一步分解,并能够根据被分析信号的特征,自适应地选择相应的频带,使之与信号频谱相配,从而提高了时—频分辨率。如图 2 所示的 3 层分解,信号 S 被表示成 $A A A_3 + D A A_3 + A D A_3 + D D A_3 + A A D_3 + D A D_3 + A D D_3 + D D D_3$, 细节与概貌都同时进行了分解,这是通常的小波分解做不到的。图中, A 表示信号的概貌, D 表示细节, 数字下标表示所处的分解层次。

小波包变换特征提取的步骤(以两层分解为例):

第 1 步: 首先对图像进行两层二维小波包分解, 分别提取第 2 层从低频到高频的 16 个频率成分的图像特征, 其分解结构如图 3 所示。图中, (i, j) 表示第 i 层的第 j 个节点, 其中, $(0, 0)$ 节点代表原始信号 S , $(1, 0)$ 节点代表小波包分解的第 1 层低频系数 X_{10} , $(1, 1)$ 节点代表小波包分解的第 1 层高频系数 X_{11} , $(2, 0)$ 节点代表第 2 层第 0 个节点的系数, 其他依此类推。




图 2 1 维小波包 3 层分解树结构

Fig. 2 1-D 3-level wavelet packet decomposition tree

第 2 步: 对小波包分解系数重构, 提取各频带范围的云图信号。以 S_{20} 表示 X_{20} 的重构信号, S_{21} 表示 X_{21} 的重构信号, 其他依此类推。则有

$$S = \sum_{j=0}^{15} S_{2j} \tag{1}$$

第 3 步: 求各频带信号的总能量。设 $S_{2j}(j = 0, 1, \cdots, 15)$ 对应的能量为 $E_{2j}(j = 0, 1, \cdots, 15)$, 则有

$$E_{2j} = \int S_{2j}(t)^2 dt = \sum_k^n x_{jk}^2 \tag{2}$$

其中, $x_{jk}(j = 0, 1, \cdots, 15, k = 1, 2, \cdots, n, n$ 为样本数) 表示重构信号 S_{2j} 的离散点的幅值。

第 4 步: 构造特征向量。以能量为元素, 经归一化处理后可以构造一个特征向量 T

$$T = \{E_{2j}/E, j = 0, 1, \cdots, 15\} \tag{3}$$

其中, $E = \left[\sum_{j=0}^{15} E_{2j} \right]^{1/2}$ 。

除了可以得到图像各尺度细节的能量特征外, 还可以计算其他统计分析特征量和纹理特征量。图像 3 层分解特征提取的方法类似。




图 3 卫星图像的 2 维 2 层小波包分解树

Fig. 3 2-D 2-level wavelet packet decomposition tree for satellite images or cloud samples

3 基于径向基函数(RBF) 网络的分类器设计

径向基函数网络是一种前馈网络, 特点是在隐层采用了径向基核函数作为隐层神经元的传递函数, 而输出层只是对隐层输出求加权线性和。

本文中采用的径向基神经元传递函数是 $radbas(n) = e^{-n^2}$ 。其中, n 是神经元的输入。与

其他网络不同的是它的输入不是输入向量, 而是输入向量与权值向量之间的距离与阈值的乘积。传递函数的图形如图 4 所示。

径向基网络的结构有两层: 含有 S^1 个神经元的径向基层和含有 S^2 个线性神经元的输出层。

RBF 网络的训练通常包括确定函数中心、宽度和连接隐含层和输出层神经元的权值。中心和宽度的确定都有经验公式^[13], 但通常是采用聚类的方法, 如迭代聚类算法、 K -均值算法等^[14]确定中心, 而宽度参数也可用自适应学习算法来确定^[13]。当中心确定后, 求隐层至输出层之间的权系值可利用各种线性优化算法, 如 LMS 算法、最小二乘递推算法、镜像映射最小二乘法等^[15]。

本文设计采用自组织竞争神经网络对训练样本进行自组织聚类^[16], 将各聚类中心作为隐层神经元的中心。自组织竞争神经网络的基本思想是: 网络竞争层各神经元竞争对输入模式的响应机会, 最后仅一个神经元成为竞争胜利者, 并对那些与获胜神经元有关的各连接权进行朝着更有利于它竞争的方向调整, 这一获胜神经元就表示对输入模式的分类, 也就是说, 输入向量到权矩阵的各个列向量的欧氏距离加上阈值后, 通过竞争传递函数产生神经元输出向量, 该输出向量中只有一个元素是 1, 其他元素都为 0。

4 测试结果与讨论

表 2~5 是对 RBF 分类器的几组测试结果(表中 F00, F23, ……等符号的含义见表 1)。

表 2 对 4 类云的测试结果

Table 2 Testing results for 4 classes of clouds

	F00	F23	F72	F91	平均
正确率	1.00	0.75	0.75	0.95	0.86

表 3 对 11 类云的测试结果

T able 3 Testing results for 11 classes of clouds

	F00	F11	F21	F23	F32	F41
正确率	0.88	0.64	0.61	0.66	0.60	0.44
	F42	F51	F72	F81	F91	平均
正确率	0.75	0.60	0.55	0.77	0.92	0.67

表 4 对稀薄云层的识别

Table 4 Recognition of thin clouds

	晴空	淡积云	卷云	平均
正确率	0.90	0.50	0.55	0.65




图 4 径向基神经元传递函数图形

Fig.4 Plot of radial base neuron transfer function

表 5 对对流云的识别

Table 5 Recognition of convective clouds

	浓积云和秃积雨云	鬃积雨云或砧状积雨云	平均
正确率	0.90	0.95	0.925

表 2 是对晴空、密卷云、复高积云或蔽光高积云、鬃积雨云或砧状积雨云的测试结果, 平均识别率达到 86 %, 其中晴空和积雨云识别效果最好, 识别率分别为 100 % 和 95 %。

表 3 是对 11 类云的测试结果, 平均识别率为 67 %。识别率最好的还是晴空和积雨云, 分别为 88 % 和 92 %, 最差的是积云性层积云, 为 44 %。平均分类效果随类别数增多而变差的原因是由于某些类别的类内离散度较大, 导致类间样本重叠, 产生分类错误。解决办法是进行特征选择, 以增大类间距离, 减少重叠。

表 4 中, 稀薄云层由于受一次反照率的影响, 频谱分布很不稳定, 导致识别率下降. 而同在一组的晴空却识别率较高, 说明了在有云的情况下, 云对辐射传输的影响很大, 而水汽、臭氧和气溶胶粒子分布的不均匀性对晴空辐射传输的影响, 不足以导致晴空样本的类内离散度增大到使晴空识别率下降的程度。事实上, 从纹理分析的角度来说, 淡积云和卷云的类间离散度应该是很大的。这也说明单一的小波包分解特征抽出存在某种缺陷。

表 5 的结果表明, 两种对流性云型的频谱分布有很大的差异, 卫星观测到的主要是来自它们自身的热辐射和多次散射辐射。

从以上测试结果可以看到, 小波包分解能够给出各类云型的差异, 但对于某些云型仍然达不到理想的效果。这是因为小波包分解描述的是目标样本的空间频谱分布特征, 而不包括目标样本的纹理特征。云型的地面观测定义主要是根据云的结构特征和纹理特征来确定的。气象卫星能够提供云的丰富而细腻的纹理特征, 这一部分是云的重要的可分性信息, 应该在云的特征抽出过程中包括进来以增大各类别的类间离散度。一种可能的设想是, 在小波包分解的基础上除了提取能量特征外, 进一步提取各尺度上的纹理特征, 来构成最终的特征向量。这样做的困难是可能会产生高维特征向量, 需要高效率的搜索寻优算法和很大的计算机内存才能实现特征选择工作。

参考文献:

[1] Liljas E. Automated Techniques for the Analysis of Satellite Cloud Imagery [M]//Nowcasting K A. Browning: Academic Press, 1982: 177-190.

[2] 郁凡, 陈渭民. 双光谱云图分类的探讨[J]. 南京气象学院学报, 1994, 17(1): 117-124.

[3] 傅德胜, 王新芝. 云图纹理特征的抽取与云的自动分类[J]. 南京气象学院学报, 1995, 18(4): 530-535.

[4] Lee J, Weger R C, Sengupta S K, et al. A neural network approach to cloud classification[J]. IEEE Trans Geosci Remote Sens, 1990, 28(5): 846-855.

[5] Baum B A, Vasanth Tovinkere, Tay Titlow, et al. Automated cloud classification of global AVHRR data using a Fuzzy logic approach[J]. J App Met, 1997, 36(11): 1 519-1 535.

[6] Peak J E, Tag P M. Segmentation of satellite imagery using hierarchical thresholding and neural networks[J]. J App Met, 1994, 33(5): 605-616.

[7] Welch R M, Sengupta S K, Goroch A K. Polar cloud and surface classification using AVHRR imagery: an intercomparison of methods[J]. J App Met, 1992, 31(5): 405-420.

[8] Bankert R L. Cloud classification of AVHRR imagery in Maritime regions using a probabilistic neural network[J]. J Appl Met, 1994, 33(8): 909-918.

- [9] Miller S W, Emery W J. An automated neural network cloud classifier for use over land and ocean surfaces[J]. J App M et, 1997, 36(10): 1 346-1 362.
- [10] Lee Victor C S, Hung S L, Cheng Andrew Y S, et al. An Operational Cloud Classifier for Satellite Images [R]. Proceedings of the 2ND International Conference on East Asia and Western Pacific Meteorology and Climate, 7-10, September, 1992, Hong kong.
- [11] 白慧卿. NWP II⁺ 及其在云系分类中的应用[J]. 气象, 1999, 25(6): 27-30.
- [12] 白慧卿, 方宗义, 吴蓉璋, 等. 基于人工神经网络的 GMS 云图四类云系的识别[J]. 应用气象学报, 1998, 9(4): 402-409.
- [13] 黄德双. 神经网络模式识别系统理论[M]. 北京: 电子工业出版社, 1996.
- [14] Abhjit S Pandya. 神经网络模式识别及其实现[M]//徐 勇, 等译. 北京: 电子工业出版社, 1999.
- [15] 徐丽娜. 神经网络控制[M]. 哈尔滨: 哈尔滨工业大学出版社, 1999.
- [16] 闻 新, 周 露, 王丹力, 等. MATLAB 神经网络应用设计[M]. 北京: 科学出版社, 2000.

A Neural Network Approach to the Automated Cloud Classification of GMS Imagery over South-East China Maritime Regions

JIANG De-ming, CHEN Wei-min,
FU Bing-shan, WANG Jian-kai

(Department of Electronic Engineering, NIM, Nanjing 210044, China)

Abstract: This paper presents an automated and efficient cloud classification scheme based on radial base function neural network (RBF), which has an average classification accuracy of more than 86 % for less than 5 cloud patterns and 67 % for more than 10 cloud patterns. An additional self-organized competitive neural network is also suggested to find out the center of the hidden layer neurons of RBF network, which greatly ameliorates the efficiency of the RBF classifier. Features abstracted by using the two-dimensional wavelet packet 3-level decomposition provide essentials for the description of cloud patterns, thus improving the capability of pattern recognition of neural network classifier. The input dataset employed in the scheme are defined by 2912 samples of 8×8 pixels size taken in July-October 1999 over SE China maritime regions from the visible ($0.55 \sim 0.9 \mu\text{m}$) and infrared ($10.5 \sim 12.5 \mu\text{m}$) channels of Geostationary Meteorological Satellite 5 (GMS-5). These images in Lambert Conformal Conic Projection and in a coarsened resolution of $13.03 \text{ km} \times 13.22 \text{ km}$ for both channels are downloaded from the meteorological operational networks. Each of the samples in the dataset is classified into one of the eleven predefined classes in accord with the SYNOP codes used in weather reports.

Key words: cloud classification; neural network; satellite imagery