

小波神经网络的遥感图象分类*

王耀南

(湖南大学电气工程系,长沙 410082)

摘要 将小波和神经网络结合起来,提出一种自适应小波函数的神经网络。这种小波函数网络经过训练后,可应用于遥感图象的分类,其分类效果优于最大似然法。

关键词 小波 神经网络 遥感分类

0 引言

对于遥感图象分类来说,由于各种地物波谱辐射的复杂性以及干扰因素的多样性,有时仅仅考虑在某一特定时间和空间内选取训练样本还是不够的,为了提高分类精度,这时还必须多选取一些样本组和研究一些新的分类方法。目前在遥感图象分类中,主要常用的分类方法是概率统计、句法结构分类、模糊数学分类等。这些分类方法均通过计算各个类别的均值、方差、标准偏差和离散度等统计量,作为比较不同类别的相似程度的依据和标准,以便在这些统计量的基础上建立各个组类的类别识别特征来进行分类。这些分类方法需要大量的统计运算,而且分类精度较低。近年来,人工智能网络开始用于遥感图象分类中^[1-3],并且取得令人满意的结果。但是,大多数神经网络遥感图象分类器采用前馈型神经网络结构,利用BP学习算法实施监督性学习分类,其网络训练过程慢,不易收敛到最优值,影响了分类的精度。本文提出一种结构简单,训练过程快的小波基函数网络。这种小波基函数神经网络具有良好的局部化性质,可用于遥感图象的分类。

1 小波基函数网络模型

1.1 小波变换

小波分析的基本思想是用一族函数去表示或接近一信号或函数,这一族函数称为小波函数系,它是

通过基本小波函数的不同尺寸的平移和伸缩构成的。若设基本小波函数为 $h(x)$, 伸缩和平移因子分别为 a 和 b , 则小波变换基底定义为:

$$h_{a,b}(x) = |a|^{-\frac{1}{2}} \cdot h\left(\frac{x-b}{a}\right) \quad (1)$$

函数 $f(x) \in L^2(R)$ 的小波变换定义为:

$$W_{a,b}(f) = \int_{-\infty}^{\infty} h_{a,b}(x) \cdot f(x) dx \quad (2)$$

或写成内积形式为

$$W_{a,b}(f) = [f(x), h_{a,b}(x)] \quad (3)$$

它对应于 $f(x) \in L^2(R)$ 在函数族 $h_{a,b}(x)$ 上的分解,这一分解必须满足如下它对应于可容性条件:

$$W_h = \int_0^{\infty} \frac{|H(f)|^2}{|f|} df < \infty \quad (4)$$

或

$$\int_{-\infty}^{\infty} h(t) dt = 0 \quad (5)$$

这里 $H(f)$ 是 $h(f)$ 的傅立叶变换,由式(5)可知当 $f = 0$ 时, $|H(f)|^2 = 0$ 。

由式(2)定义的小波变换可通过对其伸缩尺度因子 a 和平移尺度 b 的采样而离散化,对 a 和 b 依如下规律采集:

$$a = a_0^m (a_0 > 1), \quad b = nb_0 a_0^{-m} \quad (b_0 \in R)$$

则由式(1),有 $h_{m,n}(x) = a_0^{-m/2} h(a_0^{-m} x - nb_0)$, 这样离散小波变换可定义为:

$$DW_{m,n}(f) = \int_{-\infty}^{\infty} f(x) \cdot h_{m,n}(x) dx \quad (6)$$

当 $a_0 = 2, b_0 = 1$ 时,式(6)即变成一离散正交的二元

* 本文研究受国家模式识别与智能机器人重点实验室基金资助
收稿日期:1998-04-21;收到修改稿日期:1998-07-29

小波变换。

小波变换还具有如线性叠加性、平移共变性、尺度共变性、能量守恒性、局域正则性等优点。

1.2 小波基函数网络

在信号分类中,可用小波作为信号分类的特征空间,而特征提取则是一组小波与输入信号的矢量内积,然后将这些特征输入到一分类器。问题是如何选择相应的小波基,作为自适应的分类器。我们将小波与神经网络结合起来,构造一种用于分类的自适应小波基函数神经网络。这种小波神经网络的结构如图 1 所示。




图 1 小波神经网络系统结构图

对于多变量输入、输出系统 $f: R^m \rightarrow R^n$, 小波神经网络的输入输出关系可表示为:

$$y_i(t) = f \left[\sum_{j=1}^r W_{ij} \cdot \left(\sum_{k=1}^m x_k(t) \cdot h \left(\frac{k-b_j}{a_j} \right) \right) \right], \quad i = 1, 2, \dots, n \quad (7)$$

式中, $x_k (k=1, 2, \dots, m)$ 表示输入层的第 k 个输入分量, $y_i (i=1, 2, \dots, n)$ 表示 i 个输出分量, 其中 m, n 和 r 分别表示输入、输出和隐层单元数, W_{ij} 表示隐层第 j 个单元到输出层第 i 个单元的连接权值, 由输入层第 k 个单元到隐层第 j 个单元的连接权为小波 $h \left(\frac{k-b_j}{a_j} \right)$, a_j, b_j 分别小波函数的尺度和位移, $f(z) = 1/(1 + e^{-z})$ 。

该小波神经网络中,对于给定的小波函数 $h(\cdot)$,通过对参数 a_j, b_j 的调节,隐层第 j 个单元的输出代表了自适应生成的一族小波基函数 ψ_j 为:

$$\psi_j = \sum_{k=1}^m x_k(t) \cdot h \left(\frac{k-b_j}{a_j} \right), \quad j = 1, 2, \dots, r \quad (8)$$

对应不同的输入模式 x_k , ψ_j 将自适应调节至最佳。这样网络方程转化为基函数估值方程:

$$\hat{y}_i = \sum_{j=1}^r W_{ij} \cdot \psi_j \quad (9)$$

分类参数 W_{ij} 和 a_j, b_j 可通过使用能量函数最小化来实现优化。

1.3 小波网络的参数优化

当输入样本总数为 L 个时,我们可采用如下形式的 LMS 能量函数:

$$E = \frac{1}{2} \sum_{p=1}^L \sum_{i=1}^n (d_i^p - y_i^p)^2 \quad (10)$$

其中, d_i^p 是期望分类输出, y_i^p 是网络实际输出。式 (6) ~ (9) 充分描述了自适应小波特征产生的概念,采用小波函数为 $h(t) = \exp(-t^2/2)$, 并令 $t = \left(\frac{k-b_j}{a_j} \right)$, $f(\cdot) = y_i(1 - y_i)$, 则式(10)的梯度可表示为:

$$\begin{aligned} \frac{\partial E}{\partial W_{ij}} = & - \sum_{p=1}^L \sum_{i=1}^n \sum_{k=1}^m (d_i^p - y_i^p) \cdot \\ & f' \left[\sum_{j=1}^r W_{ij} \left(\sum_{k=1}^m x_k^p(t) \cdot h \left(\frac{k-b_j}{a_j} \right) \right) \right] \cdot \\ & x_k^p(t) \cdot h \left(\frac{k-b_j}{a_j} \right) \end{aligned} \quad (11)$$

$$\begin{aligned} \frac{\partial E}{\partial a_j} = & - \sum_{p=1}^L \sum_{i=1}^n \sum_{k=1}^m (d_i^p - y_i^p) \cdot \\ & f' \left[\sum_{j=1}^r W_{ij} \left(\sum_{k=1}^m x_k^p(t) \cdot h \left(\frac{k-b_j}{a_j} \right) \right) \right] \cdot \\ & W_{ij} \cdot x_k^p \cdot h \left(\frac{k-b_j}{a_j} \right) \cdot \frac{(k-b_j)^2}{a_j^3} \end{aligned} \quad (12)$$

$$\begin{aligned} \frac{\partial E}{\partial b_j} = & - \sum_{p=1}^L \sum_{i=1}^n \sum_{k=1}^m (d_i^p - y_i^p) \cdot \\ & f' \left[\sum_{j=1}^r W_{ij} \left(\sum_{k=1}^m x_k^p(t) \cdot h \left(\frac{k-b_j}{a_j} \right) \right) \right] \cdot \\ & W_{ij} \cdot x_k^p \cdot h \left(\frac{k-b_j}{a_j} \right) \cdot \frac{(k-b_j)^2}{a_j^2} \end{aligned} \quad (13)$$

小波网络的参数优化式如下:

$$W_{ij}(t+1) = W_{ij}(t) - \eta \frac{\partial E}{\partial W_{ij}} + \alpha \Delta W_{ij}(t) \quad (14)$$

$$a_j(t+1) = a_j(t) - \eta \frac{\partial E}{\partial a_j} + \alpha \Delta a_j(t) \quad (15)$$

$$b_j(t+1) = b_j(t) - \eta \frac{\partial E}{\partial b_j} + \alpha \Delta b_j(t) \quad (16)$$

其中, η 为学习率, α 为动量因子。

2 小波神经网络在卫星遥感图象中的实验

小波神经网络应用于遥感图象分类需要解决好以下几个方面的问题:

- (1) 神经网络的输入信息: 图象信息数据预处理, 输入层节点数, 信息编码;
- (2) 神经网络的输出信息: 信息编码、分类的特征提取;

- (3) 神经网络的拓扑结构确定, 网络的训练;
 - (4) 与传统分类方法的比较。
- 具体的分类结构如图2所示:

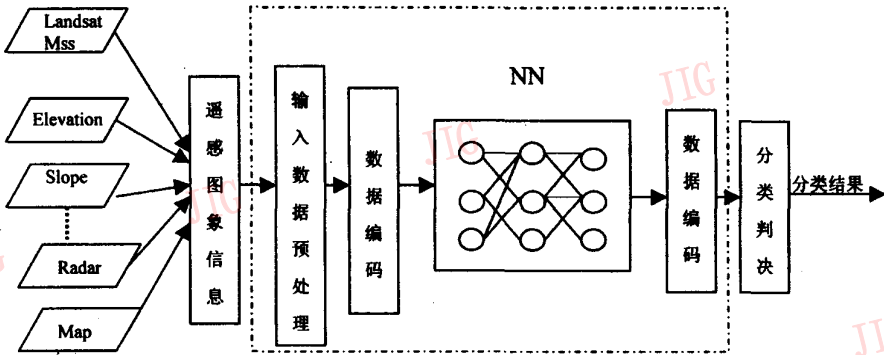


图2 小波神经网络分类过程

一般的神经网络的每个输入节点表示每一个光谱波段的数据(灰度值或者二进制), 输出节点表示分类序号, 分类选择可以采用取输出最大值法或模糊隶属函数判决法。在训练网络时, 可将多波段输入数据(灰度值0~255)转换成(0~1)的样本数据, 网络输出值(0~1), 若大于0.9, 则表示所分类, 若为0.1则表示其它类。

本文在用小波神经网络实现遥感图象分类时, 选取网络的输入节点数与遥感图象的波段数相同, 输出层节点数与分类的类别数相同。样本数据的采集方法是: 在某地 TM3, 4, 5 波段合成遥感图象上, 根据图视判读的效果, 结合地形图选取训练样本, 并求出各类别在波段上的平均值, 然后每一类一个期望值(0~1), 得到学习阶段的样本见表1。

表1 研究区的样本数据

种类	波段			期望值
	TM3	TM4(平均值)	TM5	
耕地	42.21	78.21	73.36	0.9
园地	40.39	60.37	63.72	0.7
林地	27.47	54.78	61.14	0.5
居民地	34.28	41.37	57.84	0.3
水域	32.42	22.77	17.54	0.1
未用地	38.35	67.95	88.84	0.02

利用训练样本数据作为网络学习依据, 在网络学习收敛后, 输入图象数据, 对图象进行分类。分类神经网络 3-8-6, 分类结果见表2所示。

表2 两种方法分类判别率

方法	耕地	园地	林地	居民地	水域	未用地
小波神经网络	89.4%	78.6%	94%	85.4%	82.4%	68%
最大似然法	78.8%	67.8%	84%	81.1%	74.2%	59%

3 结束语

本文将小波和神经网络的优点结合起来, 提出了自适应小波函数网络的遥感图象分类方法。实验结果表明这种小波函数网络结构简单、容易训练、收敛速度快, 一旦网络训练好后, 其分类适应性强。与传统最大似然法实验相比较, 只要用相同的学习样本训练, 小波神经网络分类精度高于最大似然法, 是一种有效的图象分类方法。

参考文献

- 1 Foody G M. Using prior knowledge in artificial neural network classification with a minimal training set. *INT J Remote Sensing*, 1995, 16(2): 301~302.
- 2 Sebastiano B Serpico, Fabio Roli. Classification of Multisensor remote-sensing images by structure neural networks. *IEEE Trans Geoscience and Remote Sensing*, 1995, 33(3): 562~577.
- 3 Paola J D, Schowengerdt R A. A detailed comparison of backpropagation neural network and maximum-likelihood classifiers for urban land use classification. *IEEE Trans Geoscience and Remote Sensing*, 1995, 33(4): 981~995.
- 4 Paola J D, Schowengerdt R A. A review and analysis of backpropagation neural networks for classification of remotely-sensed multi-spectral imag-

ery. *INT J Remote Sensing*, 1995, 16(16):3033 ~ 3058.

- 5 Zhang Qinghua, Albert Benvenste, Wavelet networks. *IEEE Trans Neural Network*, 1992, 3(6):889 ~ 898.
- 6 王耀南. 卫星遥感图象分类的神经网络处理方法. *电子学报*, 1997, 25(10):97 ~ 101.



王耀南 博士, 现任湖南大学电气与信息工程系教授、博士生导师。主要从事计算机应用, 人工智能, 智能控制与图象识别, 卫星遥感图象处理与分析等教学科研工作。

A Classification of Remote Sensing Image Using Wavelet Neural Network

Wang Yaonan

(*Department of Electrical Engineering, Hunan University, Changsha 410082*)

Abstract By integrating wavelet with neural network, a new adaptive wavelet function neural network is proposed in this paper. The wavelet neural network can be applied in classification of remote sensing image through network learning. Experimental results show that the classification of wavelet neural network is superior to that of the conventional maximum-likelihood.

Keywords Wavelet, Neural network, Classification of remote sensing