

文章编号: 1001-8166(2003)03-0345-06

ASTER 数据的自组织神经网络分类研究

哈斯巴干, 马建文, 李启青

(中国科学院遥感应用研究所 北京 100101)

摘要 传统的遥感数据分类方法大多基于统计学的参数估计, 假设数据分布服从高斯正态分布。神经网络方法无需参数估计和统计假设, 因而, 近来越来越多地应用于遥感数据分类之中。介绍了基于聚类分析的自组织特征映射分类方法。ASTER 卫星数据是新型遥感数据, 包括 3 个 15 m 分辨率波段和 3 个 30 m 分辨率的短波红外波段。选择北京地区的 ASTER 数据作为方法实验数据, 首先对数据进行了小波融合, 然后进行了土地覆盖类型的自组织特征映射神经网络分类研究, 把研究结果同最大似然判别法得到的分类结果进行了比较, 分类精度比最大似然判别法总体提高了 9%。

关键词 分类; 小波融合; 自组织特征映射; 神经网络

中图分类号 TP183 TP7 文献标识码 A

0 引言

遥感数据分类的目的是模拟人工目视判读, 快速提取信息, 分类的关键是找到一种判决法则并应用这种法则, 把图像划分成 K 个不相交的类别区域。最大似然判别法 (MLH, Maximum Likelihood Method) 又称贝叶斯 (Bayes) 分类, 它广泛应用于遥感数据分类并在应用中取得了很好的结果^[1, 2]。在运用最大似然判别法则对遥感数据进行分类时需要假设每一类的数据服从正态分布规律, 根据训练数据估算类的均值矢量和协方差矩阵, 对损失函数和先验概率进行估算等, 但是, 由于遥感信息的不确定性, 这些估计和假设在遥感数据中常常不能取得满意的分类效果。因此, 探索利用人工神经网络等数学方法来处理遥感数据成为当前的研究热点^[3]。

Kohonen 自组织特征映射神经网络 (SOFM, Self-Organizing Feature Map) 也称作 Kohonen 特征映射或拓扑保存映射, SOFM 网络在语音识别、图像压缩等领域得到了广泛应用^[4, 5]。SOFM 网络抗噪声

能力强, 可以对多维数据进行平行高速处理, 把多维数据进行降维, 并且把多维数据映射到低维空间中能够在低维空间中保持多维数据信息的拓扑性质。因此, SOFM 网络适合处理当前多波段的遥感数据。

ASTER 是美国国家航空航天局 (NASA) 推进的对地观测系统 (EOS) 的第二阶段发射的 TERRA 卫星上搭载的 5 个对地观测传感器中的一个, TERRA 于 1999 年发射, 是太阳同步极轨卫星, 每日地方时上午过境。ASTER 设有 15 个波段, 1、2 波段 (可见光) 和 3N、3B 波段 (近红外), 3N 和 3B 波段的光谱范围相同的空间分辨率是 15 m, 4 ~ 9 波段 (短波红外) 是 30 m 分辨率, 10 ~ 14 波段 (热红外) 是 90 m 分辨率。为充分利用多波段的光谱信息, 提高分类精度, 本文利用小波融合提高 ASTER 数据的 5、7 和 9 波段的空间分辨率增强其光谱特征信息后, 用 Kohonen 自组织特征映射网络进行了土地覆盖的分类研究, 并把分类结果与基于统计方法的最大似然判别法的分类结果进行了比较, 取得了优于最大似然判别法的分类结果。

收稿日期: 2002-10-18 修回日期: 2003-01-07

* 基金项目: 国家 863 计划项目“基于 SIG 框架的数字城市服务系统与示范”(编号: 2002AA134030) 863-103 项目“遥感图像处理平台”(编号: 2002AA133030) 资助。

作者简介: 哈斯巴干 (1967-) 男, 内蒙古翁牛特旗人, 博士研究生, 主要从事遥感数据模型研究。E-mail: hasibagan@263.net

1 原理和算法

1.1 小波变换和数据融合

小波理论是 20 世纪 80 年代后期发展起来的一类新的信号处理工具。小波分析的最大特点在于具有敏感的变焦特征,它能形成可调时频窗,在低频段采用高的频率分辨率和低的时间分辨率,在高频段则采用低的频率分辨率和高的时间分辨率,从而在不同的分辨率下,反映出不同的图像结构特征,从而在增强图像纹理信息方面具有独到的能力^[6-8]。

ASTER 数据的 1、2、3N 和 5、7、9 波段的空间分辨率不同,为了充分利用多波段的光谱数据,需要把 5、7、9 波段的空间分辨率变为与 1、2、3N 波段的空间分辨率一致。小波变换是当前融合不同分辨率遥感图像的有力工具,小波融合主要利用多分辨率分析(MRA)的 Mallat 算法对高分辨率图像和低分辨率图像进行小波正变换,把高分辨率数据的各级各方向的高频成分与低分辨率数据相应的各级各方向的高频成分进行局部方差最大的比较,组成新的高频,然后与低分辨率数据的低频成分,进行小波逆变换,得到分辨率提高并且信息得到增强的融合图像^[9]。

1.2 SOFM 神经网络和矢量量化学习算法

SOFM 神经网络模型是从生物系统中得到启发而发展起来的人工神经网络模型之一。SOFM 网络模型模拟了大脑中视觉皮层中侧反馈的特征。人的大脑视觉皮层对外界的刺激有一个小范围的侧反馈(兴奋或抑制)区域,这个区域可分为 3 个明显的侧作用区域:对近距离侧反馈是兴奋的,对稍远距离处有一抑制的区域,再远处有一减弱的兴奋区域。Kohonen 正是根据人脑的这些特点提出了自组织映射理论。他认为神经网络中邻近的各个神经元通过彼此侧向交互作用,相互竞争,自适应发展成检测不同信号的特殊检测器,这就是自组织特征映射的含义。自组织特征映射神经网络对样本自学习后,在输出神经元层中排列成一张二维的映射图,功能相同的神经元靠得比较近,功能不相同的神经元分得比较开,这个映射过程是用竞争算法来实现的,其结果可以使一些不规则的输入自动排序,在调整连接权的过程中可以使权的分布与输入样本的分布相似^[10, 21]。

应用 SOFM 网络进行数据聚类时,SOFM 网络在输入模式上执行在线聚类过程,SOFM 网络对输出层神经元施加了一个侧反馈邻域约束,因而使得

输入的多维数据中的拓扑性质可以聚类到输出层神经元的权值上。聚类中心以权值表示,通过竞争学习规则更新权值。在此聚类过程中,不仅更新获胜神经元的权值,而且更新获胜神经元周围侧反馈邻域内所有神经元的权值。侧反馈邻域的大小通常随每次迭代缓慢减少。当此过程完成后,输入数据被划分成彼此不相交类别,使得相同类别中个体的相似性大于其他类别中个体的相似性。

SOFM 网络的训练步骤如下:

设 w_j 是从输出层的神经元 j 到输入层各节点 i 的连接权向量 $x = (x_1, x_2, \dots, x_n)$ 是输入向量, n 是维数(输入的光谱波段数)。网络训练分两个部分:粗调和细调。粗调是自组织竞争学习过程,属于无导师的聚类,过程如下:

步骤 1 对每一个神经元的权值随机初始化为 0.0 ~ 255.0 之间的实数。

步骤 2 对每一输入向量 x , 使用欧几里得距离作为不相似性度量,计算输出层各神经元的激活值(距离):

$$a_j = \left(\sum_{i=1}^n (x_i - w_{ij})^2 \right)^{0.5} = |x - w_j| \quad (1)$$

步骤 3 找到对应输入向量 x 的具有最小激活值的神经元,然后按下式更新权值:

$$w_{ij}(t+1) = w_{ij}(t) + (t)^{-1} [x_i(t) - w_{ij}(t)]$$

if $j \in N_c(t)$

$$w_{ij}(t+1) = w_{ij}(t) \quad \text{if } j \notin N_c(t) \quad (2)$$

$N_c(t)$ 是 t 时刻的获胜单元的侧邻域, j 是输出层神经元。 (t) 是学习速率,并随 t 逐渐减少,其初值一般设在 0.0 ~ 1.0 之间。

步骤 4 输入新的向量,重复步骤 2 到步骤 3, 达到预设的循环次数或聚类为止。

步骤 5 对每一输入的向量标出它所属的类,按多数原则(如果在一个聚类中属于类别 c 的数据点占多数,则该聚类被标注成类别 c)。对输出层各神经元标出它所属的类别。

学习速率 (t) 随时间缓慢减少: $(t) = (t-1)^*$, 的初始值选在 0.5 ~ 0.9 之间。

自组织竞争学习完成后,输入数据被划分为一些不相交的类别,每一类由其聚类中心表示。对粗调后的网络权向量,应用学习矢量量化(LVQ, Learning Vector Quantization)算法,按下式进行细调,此过程属于有导师的训练:

步骤 1 随机选择一个训练输入向量 x , 并找到使 $|x - w_c|$ 最小的 c 。

步骤 2 用 LVQ 算法, 如果 x 和 w_c 属于同一类, 按下式更新 w_c :

$$w_c(t+1) = w_c(t) + (t)[x_i(t) - w_c(t)]$$

否则, 按下式更新 w_c :

$$w_c(t+1) = w_c(t) - (t)[x_i(t) - w_c(t)]$$

当 i 不等于 c 时 权向量为 :

$$w_i(t+1) = w_i(t) \quad (3)$$

学习速率 是小的正常数, 随每次迭代递减, 递减至 0.001 后不再减少。

步骤 3 : 如果已达到了最大迭代次数, 停止 ; 否则 返回步骤 1。

2 ASTER 数据处理流程与结果分析

ASTER 卫星数据同 ETM 数据比较, 其数据波段数增多, 数据的空间分辨率提高而且 S/N 比等性能都有很大的提高, 这些方面的改进有利于提高像元分解能力从而提高分类精度。

试验区为北京地区, 位于北京市区的东北部分。实验数据是 2001 年 6 月 4 日获得的 ASTER 卫星数据, 获得的数据中 1、2、3N 波段 (15 m 分辨率) 5、7 和 9 波段 (30 m 分辨率) 的光谱数据能够利用。1、2 波段在可见光范围之内, 其光谱范围为 0.52 ~ 0.60 μm 和 0.63 ~ 0.69 μm 3N 波段是近红外波段, 其光谱范围为 0.76 ~ 0.86 μm 5、7 和 9 波段是短波红外波段, 其波长分别为 2.145 ~ 2.185 μm 、2.235 ~ 2.285 μm 和 2.36 ~ 2.43 μm 。实验所选研究区域为 2 048 \times 2 048 个像元 (15 m 分辨率)。图 1 是实验区的原始 ASTER 卫星数据的 3N、2、1 波段的彩色合成图。为增强短波红外的 5、7 和 9 波段的空间分辨率和光谱分辨率, 利用 ASTER 数据的 3N 和 2 波段进行主成分变换, 然后取其第一主成分, 与 5、7 和 9 波段进行小波融合。融合过程简述如下: 首先, 对 5、7 和 9 波段按最近邻法重采样为 15 m 分辨率, 然后, 对取得的第一主成分和重采样后的 5、7 和 9 波段进行小波正变换, 把高分辨率数据 (第一主成分) 的各级各方向的高频成分与低分辨率数据 (重采样后的 5、7 和 9 波段) 相应的各级各方向的高频成分进行局部方差最大的比较, 取方差大者组成新的高频, 然后与低分辨率数据的低频成分进行小波逆变换, 得到空间分辨率和光谱分辨率提高了新的 5、7 和 9 波段。

融合过程结束后用 ASTER 数据的 1、2 和 3N 及小波融合后的 5、7 和 9 光谱波段, 利用实地考察结果结合目视解译和该地区的土地利用图, 选取了训

练和验证数据集。表 1 是实验所用的训练和验证样本点数据集的构成描述。

表 1 训练数据集与验证数据集

Table 1 Training and testing samples

类别号	土地覆盖	描述	训练数 验证数	
			数据集	数据集
1	水体	河流、池塘	4132	847
2	林地	天然林、人工林	2797	670
3	草地	草坪、冬小麦	2643	369
4	耕地	耕地、人工种植的花草	5670	1041
5	道路	主干马路、高速公路	2712	322
6	城镇	城镇、农村居民点	7761	1302
7	其它	建筑工地、大型厂矿裸土地	1347	171
	共计		27062	4722

实验中选择了输入层有 6 个节点、输出层是 25 \times 25 的二维结构的 SOFM 网络结构。ASTER 数据的 1、2 和 3N 及小波融合后的 5、7 和 9 光谱波段分别对应一个输入层节点, 学习速率 的初始值为 0.9, 随着训练时间的增加逐渐减少到 0.001 后不再减少, 最大循环次数取 2 500 次。输出层上的侧反馈邻域的初始大小选为 14。SOFM 网络训练结束后对网络权值进行细调, 然后开始进行分类。应用 SOFM 网络进行遥感数据分类的流程见图 2。

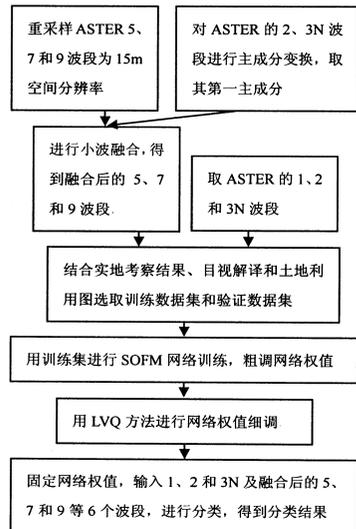


图 2 SOFM 网络的分类流程

Fig.2 Flow chart of the SOFM networks

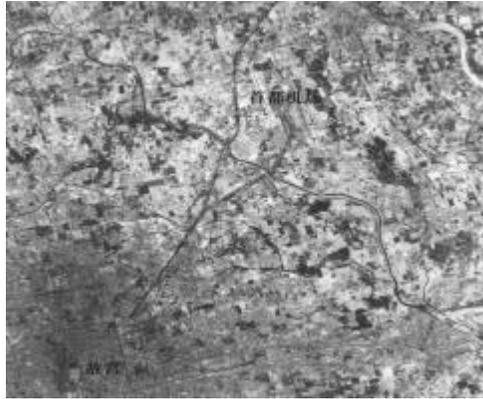


图1 ASTER 3N、2、1波段合成图

Fig.1 The image of ASTER band 3N、2 and 1

为了把SOFM网络的分类结果同MLH的分类结果进行比较,用选取的训练集,对ASTER数据的1、2和3N及小波融合后的5、7和9光谱波段共6个波段按MLH方法进行了分类试验。图3的(1)和(2)分别是应用SOFM网络和MLH对ASTER数据的6个波段的分类结果。为比较两种方法的精度,用预先取得的独立验证数据集对SOFM方法和

MLH方法进行了精度测试,将测试结果分别表示在混淆矩阵中,见表2、表3。通过比较混淆矩阵,SOFM方法的总体精度是95.68%,MLH方法的总体精度是86.64%,因此SOFM方法的分类精度高于MLH方法。特别在耕地分类精度方面SOFM神经网络分类的精度是97.79%,而MLH方法的分类精度只有76.08%。

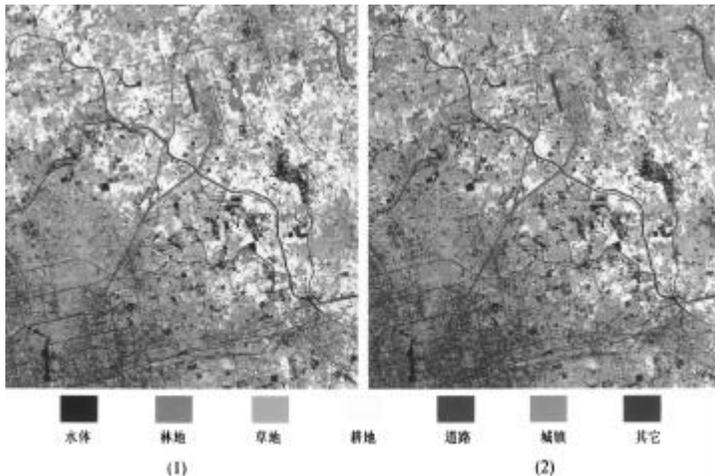


图3 SOFM与MLH算法的结果比较(1)SOFM(2)MLH

Fig.3 Comparison between the results of SOFM and MLH classification algorithms (1) SOFM (2) MLH

表 2 SOFM 分类结果的混淆矩阵

Table 2 Confusion matrix for classification using SOFM

总样本 4722		正确分类的样本 4518						总体精度 95.68%	
类别	水体	林地	草地	耕地	道路	城镇	其它	用户精度	
水体	79 6	0	0	0	37	1	0	95.44%	
林地	0	663	0	6	0	0	0	99.10%	
草地	0	7	369	0	0	0	0	98.14%	
耕地	0	0	0	1018	0	3	0	99.71%	
道路	49	0	0	0	276	50	0	73.60%	
城镇	2	0	0	17	9	1248	23	96.07%	
其它	0	0	0	0	0	0	148	100.00%	
合计	847	670	369	1041	322	1302	171		
地表真实精度	93.98%	98.96%	100.00%	97.79%	85.71%	95.85%	86.55%		

表 3 MLH 分类结果的混淆矩阵

Table 3 Confusion matrix for classification using MLH algorithm

总样本 4722		正确分类的样本 4518						总体精度 95.68%	
类别	水体	林地	草地	耕地	道路	城镇	其它	用户精度	
水体	75 0	0	0	0	17	0	0	97.78%	
林地	0	603	0	0	0	0	0	100.00%	
草地	0	67	368	0	0	1	0	84.40%	
耕地	0	0	0	792	0	4	0	99.50%	
道路	97	0	0	17	305	187	0	50.33%	
城镇	0	0	1	204	0	1110	8	83.90%	
其它	0	0	0	28	0	0	163	85.34%	
合计	847	670	369	1041	322	1302	171		
地表真实精度	88.55%	90.00%	99.73%	76.08%	94.72%	85.25%	95.32%		

3 结论与讨论

当代卫星遥感的发展主要表现在它的多传感器、高分辨率和多时相特征。光学传感器的未来发展将进一步提高空间分辨率和光谱分辨率^[12]。从而随着空间分辨率和光谱分辨率的提高,所获取的遥感数据量也将大幅度地增加。小波变换与自组织神经网络方法结合将为处理这类遥感数据提供新的方法,小波融合方法可以很好地提高各波段的光谱分辨率,神经网络计算方法可以对多波段的遥感数据进行并行快速的处理。本文选择了北京地区的 ASTER 数据,利用 ASTER 数据进行了 SOFM 神经网络地表覆盖分类的方法实验。为了充分利用 ASTER 数据的高空间分辨率和光谱信息,采用小波方法在分类前用 ASTER 数据 15m 分辨率的 3N 和 2 波段的第一主成分分别和 ASTER 数据的 30m 分辨率 5、7、9 波段进行融合处理。实验结果与 MLH 方法比较,总体提高分类精度 9%。特别在耕地分类精度方面 MLH 方法的分类精度只有 76.08%,而 SOFM 神经网络分类的精度是 97.79%。

参考文献(References):

- [1] Zhang Xiaocan, Huang Zhicai, Zhao Yuanhong. Remote Sensing Digital Image Processing [M]. Hangzhou: Zhejiang University Press, 1997. 222-232. [张孝灿, 黄智才, 赵元洪. 遥感数字图像处理[M]. 杭州: 浙江大学出版社, 1997. 222-232.]
- [2] Luo Jianheng, Wang Qinmin, Ma Jianhong et al. The EM-based maximum likelihood classifier for remotely sensed data[J]. Acta Geodaeica et Cartographica Sinica, 2002, 31(2): 234-239. [骆剑承, 王钦敏, 马江洪等. 遥感图像最大似然分类方法的 EM 改进算法[J]. 测绘学报, 2002, 31(2): 234-239.]
- [3] Sun Jiabing, Shu Ning, Guan Zegun. Remote Sensing Theory, Method and Application [M]. Beijing: Surveying and Mapping Press, 1997. 176-242. [孙家炳, 舒宁, 关泽群. 遥感原理、方法和应用[M]. 北京: 测绘出版社, 1997. 176-242.]
- [4] Kohonen T. Self-organized formation of topologically correct feature maps[J]. Biological Cybernetics, 1982, 43: 59-69.
- [5] C Y Qi. Land-use classification of remotely sensed data using kohonen selforganizing feature map neural networks[J]. Photogrammetric Engineering & Remote Sensing, 2000, 66(12): 1451-1460.
- [6] Cui Jirai. An Introduction to Wavelets [M]. Xi'an: Xi'an Jiaotong University Press, 1995. 198-242. [崔锦泰. 小波分析论[M]. 西安: 西安交通大学出版社, 1995. 198-242.]
- [7] Mallat S G. A theory of multiresolution signal decomposition the

- wavelet representation[J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 1989 11(7): 674-693.
- [8] Jorge Nunez, Xavier Otazu, Octavi Fors, et al. Multiresolution-based image fusion with additive wavelet decomposition[J]. IEEE Transactions on Geoscience and Remote Sensing, 1999, 37(3): 1204-1211.
- [9] Hasibagan MA Jianwen LI Qi-qing et al. Wavelet high frequency substitution fusion method[J]. Journal of Image and Graphics, 2002, 7A(10): 012-016. [哈斯巴干, 马建文, 李启青, 李波. 局部高频替代融合方法[J]. 中国图象图形学报, 2002, 7A(10): 012-016.]
- [10] Kohonen T. The self-organizing map[J]. Proceedings of the IEEE, 1990, 78(9): 1464-1480.
- [11] Yuan Zengsen. Artificial Neural Network and Application[M]. Beijing Tsinghua University Press, 1999. [袁曾任. 人工神经网络及其应用[M]. 北京: 清华大学出版社, 1999.]
- [12] Li Deren. Discussion on Earth observation and geographic information system[J]. Advance in Earth Sciences, 2001, 16(5): 689-703. [李德仁. 对地观测与地理信息系统[J]. 地球科学进展, 2001, 16(5): 689-703.]

STUDY ON ASTER DATA CLASSIFICATION USING SELF-ORGANIZING NEURAL NETWORK METHOD

HASI Ba-gan MA Jian-wen, LI Qi-qing

(The Institute of Remote Sensing Applications CAS, Beijing 100101, China)

Abstract: The assumption of statistical model is not needed for Neural Networks (NN) while most traditional classification method for remote sensing data assumed normal distribution model. More and more NN application cases have been found in remote sensing data classification. In this paper, we proposed a method of Kohonen Self-organizing feature map based on clustering analysis. ASTER data is a new remote sensing data, which includes 3 bands of 15 m resolution and 3 bands of 30 m resolution. ASTER data of Beijing have been chosen for our research. The land cover classification result in neural networks method has been shown in this paper after wavelet fusion of data. The classification has 9% of accuracy ratio more than MLH classification.

The idea of neural networks came from the basic structure of functioning of the human brain. In the modern field of science and engineering, the neural networks have strengthened their importance with numerous applications ranging from pattern recognition, fields of classification etc. There are different kinds of the neural networks available depending on the task to be performed. In this study the Kohonen self-organized network is used. There are 6 nodes in import layer of the structure of Kohonen self-organized network and ASTER data bands 1, 2, 3N, 5, 7, 9 corresponding to one node in import layer. Output layer has the structure of 25 × 25 neural nodes. Learning speed starting value is 0.9, reduced to 0.001 stopped with net calculation processing. Maximum circulation time is 2500.

ASTER is the only instrument to fly on the EOSAM-1 platform that will acquire high-resolution image. The primary goal of the ASTER mission is to obtain high-resolution image data in 15 channels over targeted areas of the Earth's surface, as well as black-and-white stereo images, with a revisit time between 4 and 16 days. Band 1, 2 are visible bands, band 3N, 3B are near infrared bands, the resolution is 15 m; Band from 4 to 9 are group of short wave infrared bands, the resolution is 30 m; Band from 10-14 are thermal bands, the resolution is 90 m. With ASTER's merits earth scientists to address a wide range of globe-change topics. In the paper we introduce Kohonen self-organized network in classification of land cover in Beijing area in 2001 by using ASTER data.

Key words: Classification; Wavelet fusion; Self-organizing feature map; Neural networks.