

文章编号: 1007-4619 (2004) 02-0178-07

Kohonen 神经网络在遥感影像分类中的应用研究

张友水¹, 冯学智¹, 阮仁宗¹, 麻士华²

(1. 南京大学 城市与资源学系, 江苏 南京 210093; 2. 浙江省国土资源厅 信息中心, 浙江 杭州 310007)

摘 要: 根据 Kohonen 网的生物学基础, 基本结构和学习算法, 提出了解决遥感影像分类的途径。依据实验区土地利用类别的光谱特征, 采用主成分分析对遥感影像进行预处理, 结合地理辅助数据的量化输入训练出 Kohonen 自组织图后对融合有地理辅助数据的影像进行土地利用分类, 并与 BP 网和最大似然法分类结果进行分析比较。结果表明, 地理辅助数据的参与对提高 Kohonen 网影像分类精度具有意义。

关键词: 人工神经网络; 自组织; 土地利用; 遥感图像分类

中图分类号: TP79 **文献标识码:** A

1 引 言

遥感影像主要通过像元亮度值的差异或其空间梯度变化来表示不同地物间的差异。像元间的亮度差异反映了地物的光谱信息的差异, 而空间变化的差异则反映了地物的空间信息, 这是遥感影像分类的物理依据。遥感影像的传统统计模式识别方法是采用 Bayes 分类器实现的, 该方法假定各类服从 Gauss 正态分布, 按待分像元与已知模式的相近程度进行分类。在多源数据的情况下, 特别是地理信息系统提供的 DEM 数据, 坡度数据, 土壤类型数据及土地利用等数据, 这些不同来源的空间数据可能不具备正态分布特征, 另外, 一些地面实测的离散类别数据不一定符合统计分布模型, 传统统计分类方法难以对此进行分类。而且, 在高维多源数据的情况下, Bayes 准则所要求的协方差矩阵也会随数据维数的增加而难以得到^[1]。

ANN(人工神经网络)方法可解决上述存在的困难, ANN 不要求输入数据符合一定的统计分布模型。如对多光谱数据进行分类时, ANN 不需要一个概率分布模型, 而且可方便地将地理辅助数据加入到多光谱数据的分类中去, 并且无需像专家分类时要建立复杂的知识库^[2-4]。

本论文基于“浙江省土地利用遥感调查”项目, 使用 Landsat TM 数据及地理辅助数据。实验区位于丘陵山地和平原的交接地带, 地形比较复杂, 地物分

布明显受地形影响, 遥感影像上存在着“同物异谱, 异物同谱”的现象, 进行分类时必须充分利用地理辅助数据才能获得较理想的结果。考虑到限于梯度下降算法的 BP 神经网络(BPNN)固有的缺陷, 即收敛速度慢、易陷入局部极小值, 无法保证全局最优性, 同时 BP 网隐层数目和隐层节点数确定较困难。因此, 应用 ANN 中自组织特征映射网(Self-Organizing feature Map, 简称 SOM, 又称 Kohonen 网)结合地理辅助数据对遥感影像的土地利用和覆盖分类进行了研究, 并对实验区的数据进行验证和分类结果进行分析评价。

2 Kohonen 网的基本特征

Kohonen 网的学习过程是一个非监督的自组织过程, 其神经元通过非监督竞争学习, 变得对不同的输入模式敏感, 从而使特定的神经元在模式识别中可充当某一输入模式的检测器。即神经网络接受外界输入模式时, 将分成不同的对应区域, 各区域对输入模式具有不同的响应特征, 这个过程是自动完成的。

2.1 Kohonen 网的生物学基础

生物学研究表明, 在人脑的感觉通道中, 神经元的组织原理是有序排列。当人脑通过感觉接受外界时空信息时, 大脑皮层的特定区域兴奋, 使得外界信息在对应区域是连续映像的。如在听觉通道中, 神

经元在结构排列上与频率的关系十分密切,对某个频率,特定的神经元具有最大的响应,位置邻近的神经元具有相近的频率特征,而远离的神经元具有的频率特征差别也较大。大脑皮层的神经元这种响应特点不是先天的,而是通过后天学习自组织形成的。

对接受外界某一信息而产生特定兴奋过程是 Kohonen 网竞争机制的生物学基础。而神经元的有序排列以及对外界信息的连续映像 in Kohonen 网中也有反映,当外界输入不同样本时,网络中哪个位置的神经元兴奋开始是随机的,但自组织训练后会在竞争层形成神经元的有序排列,功能相近的神经元非常靠近,功能不同的神经元离得较远^[5]。此特点与人脑神经元的组织原理很相似。

2.2 Kohonen 网的基本结构

Kohonen 网分为两层,即输入层和输出层,输入层各神经元通过权向量将外界信息汇集到输出层的各神经元。输入层的形式与 BP 网相同,结点数与样本维数相等。输出层也是竞争层,神经元的排列有多种形式,如一维线阵、二维平面阵和三维栅格阵,其原理可推广到 n 维处理单元阵列中去^[6]。其中,二维平面阵列最典型,最常用,其结构如图 1。

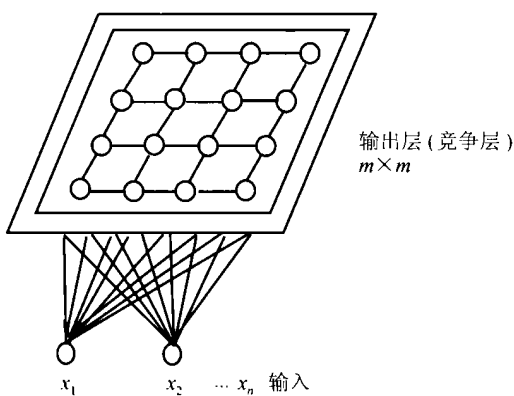


图1 Kohonen 网的二维阵列

Fig.1 Two-dimensional array of Kohonen network

2.3 学习算法与运行原理

Kohonen 算法可表达如下:

(1) 初始化。将 n 个输入结点到 m 个输出结点的权值设置为一个小的随机数,设置较大的邻域范围 $N_j^*(t)$,这个邻域范围随时间增长而不断缩小。

(2) 提供一个输入模式。

(3) 用如下公式计算输入样本 x_i 到每一输出结点 j 之间的距离 d_j ,该距离称为尤克利(Euclidean)距离。该公式为^[6]:

$$d_j = \sum_{i=1}^n [x_i(t) - w_{ij}(t)]^2$$

w_{ij} 表示输入样本到输出结点的权值, t 为正整数,表示时刻。

(4) 选取具有最小距离 d_j 的结点 j^* 为输出结点。

(5) 修改 j^* 与邻近结点之间的权值,权值修正可采用多种公式,这里采用如下公式:

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

其中 $\eta(t)$ 为一个增益项($0 < \eta(t) < 1$),随时间增长下降到 0。

(6) 如果增益项的值已减小至 0,则结束;否则转换至(2)。

3 问题解决的基本途径

3.1 土地利用分类类别的确定

根据“浙江省国土资源遥感综合调查”项目,将浙江省绍兴市及其附近地区作为实验区,本实验区位于绍兴东南,之所以选择该地区,主要因为该区地貌类型丰富,植被类型也较有代表性,可以有效地测试本研究所用的方法。实验区大小为 700×420 个像元。

使用 Landsat TM 1—5 和 TM7 波段,该遥感数据为 2001 年 5 月成像,专题数据有该区 1:5 万土地利用现状图和 1:5 万地形图。由专题图和地形图产生土地利用数据,DEM 数据,坡度数据(由 DEM 产生)等地理辅助数据。影像数据和地理辅助数据经几何配准后均校正到高斯坐标系中。

参照全国农业区划委员会 1984 年颁发的《土地利用现状调查规程》,针对实验区特点,结合实地考察结果,确定土地利用的类别为 7 类,即水体、有林地、水田、茶园、旱地、居民地和桑园等。图 2 为实验区遥感影像。

3.2 数据分析处理

图 3 为分类类别在 TM 各波段的波谱特征(通过抽样点的平均值得出),可以看出水体和林地有较好的光谱分辨性,其他地类光谱特征较为接近,尤其是旱地、桑园和茶园,单纯依据光谱特征难以获得较




图 2 实验区的遥感影像

Fig.2 RS image of experimental area




图 3 分类类别在 TM1-5 和 TM7 波段的波谱特征

Fig.3 Spectral reflectance of classifications in TM1-5 and TM7

据进行尺度变换。考虑地物的光谱反射率在 0-255, 因此, 将 DEM 数据及坡度数据分别压缩和拉伸至 0-255。通过归一化处理, 相当于增加了两个“波段”, 使得各分量在网络训练一开始就处于同等重要的地位。

3.3 Kohonen 神经网络分类及结果评价

3.3.1 Kohonen 神经网络分类方法

将地理辅助数据加入参与最终分类, 主要有两种方法, 一是采用专家分类方法, 利用土地利用类型与 DEM 和坡度的相关关系, 将 DEM 及坡度等地理辅助数据组成决策树参与分类^[7]。二是采用 DEM 和坡度数据参与 Kohonen 网分类, 使地理辅助数据规整化, 量化输入 Kohonen 网, 参与竞争分类。本文采用第二种方法。

好的分类精度。

图 3 还可以看出, TM1、2、7 波段中各分类类别的亮度值较为接近, 所以可对 TM1、2、7 波段进行 KL 变换, 取其第一分量 KL1 作为一个新波段, 舍去另外两个分量, 将第一分量 KL1 和 TM3、4、5 波段组合成新的多波段遥感影像, 提高了各分类类别的光谱可分性。因此, 采用 Kohonen 神经网络分类方法所采用的光谱数据为 KL1、TM3、TM 4 和 TM 5。

实验区高程变化区间为 10-738m, 坡度变化区间为 0-34°, 地貌类型包括平原、沟谷和丘陵山地 3 类, 7 类地物的分布明显受地貌类型控制。随光谱数据同时进入神经网络的地理辅助数据, 在进入网络之前需通过归一化处理, 即对 DEM 数据和坡度数

Kohonen 网的运行分训练和工作两个阶段。在训练阶段, 对网络输入样本数据, 输出层产生竞争学习, 对竞争获胜神经元及其领域内的所有神经元进行权值修正, 网络通过竞争学习完成自组织特征映射过程。竞争学习是一种非监督学习方法, 在学习训练过程中, 只需向网络提供学习样本, 不需提供理想的目标输出。

通过前述数据处理, 实验区采用了 KL1 和 TM3-5 四种光谱数据和经过变换处理的 DEM 数据及坡度数据, 因此, 本试验区数据的输入模式为 6 维向量, 从而设定输入层结点数为 6。输出层 Kohonen 自组织图的神经元设计采用 10×10 的二维平面阵列, 自组织图的大小根据经验和多次实验结果确定, 自组织图的大小主要考虑要分类别的数量, 当神经元较少且要分类别较多时, 各分类的中心将受到挤

压而靠得很近,从而不能很好地代表要分的各类别^[8,9]。当神经元数量较多时,要花费较长时间才能使网络收敛。由于实验区土地利用类型共分为7类,10×10大小的神经网络基本能够表达各种分类类别的特征。

首先要训练 Kohonen 网,使其在输出层形成有规则的拓扑结构。使用 600 个像元来训练网络,设定学习率 $\eta(t)$ 的初始值为 0.5,领域半径为 1,以 $\eta(t)$ 衰减到 0.007 为训练结束条件。通过加入训练数据,获胜神经元及其邻域内神经元按照前述 Kohonen 算法进行修正,使各权向量趋于稳定。网络收敛后,精确、仔细地选出实验区各土地利用类型样本数据,将 7 类地物的样本数据加入网络,本实验每类均选出 60 个样本数据。在加载样本数据时,为了使各类平等地竞争,取得较好的分类效果,各类别样本数量应大体一致。通过训练,网络中的神经元按照输入数据在自组织图中进行排列和调整,从而实现功能相同的神经元在空间分布上的聚集。图 4 为训练结束后的 Kohonen 自组织图(为了便于比较各类别差异和混淆程度,分别用 1-7 表示水田、旱地、桑园、茶园、有林地、居民地和水体,0 表示没有归属类的神经元)。由图 4 可看出共有 33 个神经元没有归属类,说明其周围各类之间较少重叠,因此该 Kohonen 图能较好地区分出各类别。通过地物样本数据的加入可看出,即使经过精细调整,仍有少部分神经元属于两种或两种以上的类别,对于这种神经元,按

照该神经元的最大类别数量确定其所属类别。如某一神经元既属于桑园又属于茶园,在 10×10 神经元的自组织图中,共有 7 个神经元属于桑园,但属于茶园的神经元共 14 个,因此,该神经元所属类别应为茶园。

7	7	7	7	7	0	6	0	5	5
7	7	7	0	0	6	6	0	0	5
7	0	0	0	3	0	6	0	5	5
0	0	0	3	3	0	3	3	5	5
4	4	0	0	4	3	3	0	5	5
4	4	4	4	4	0	0	4	0	0
0	0	4	4	4	4	4	0	1	1
2	2	0	2	0	0	0	1	1	1
2	2	2	2	2	2	0	1	1	1
2	0	2	2	0	1	0	1	1	1

图 4 用于最后分类的 Kohonen 自组织图

Fig.4 Kohonen self-organization mapping for classification

网络训练结束后,输出层各节点和输入模式类的特定关系就确定了,因此可用作模式分类器。当输入一个模式,输出层代表该模式类的特定神经元将产生最大相应,将输入自动归类。如果向网络输入的模式不属于网络训练时见过的任何模式类时,Kohonen 网将其归入最接近的模式类。将实验区数据输入网络进行分类,通过分类结果的分析可看出,地理辅助数据的加入对提高分类精度还是有贡献的。实验区遥感影像采用 Kohonen 方法的最终分类结果见图 5。



图 5 地理辅助数据参与的 Kohonen 网络分类结果

Fig.5 Classification results of Kohonen network with geographical ancillary data

3.3.2 实验结果评价

为了验证该方法的有效性,采用最大似然法与 BPNN 法进行影像分类并与其比较。

最大似然法 欲将实验区图像的土地利用的类别划分为 7 类,考虑虽为同一类别但光谱特征并不一致,根据基于 Bayes 统计理论的最大似然分类法

的特点,对每一类别按光谱特征细分再进行分类,最后将分类结果合并为 7 类(图 6)。对比分类结果与经过实地验证和修正的土地利用图,可看出,该方法

仅考虑到光谱特征,不能很好地解决“异物同谱”现象,混分较普遍。

BPNN 分类 采用单隐层网络,同 Kohonen 网络




图 6 最大似然法分类结果

Fig.6 Classification results of Maximum Likelihood

分类相同,将 DEM 数据和坡度数据归一化,同样用增加“波段”的方法加入地理辅助数据,因此 BPNN

输入节点数为 6,输出节点数为 7,设定隐层节点数为 12,图 7 为分类结果。




图 7 地理辅助数据参与的 BPNN 分类结果

Fig.7 Classification results of BPNN with geographical ancillary data

尽管 BPNN 能够自动调整节点间的权值,能够方便加入地理辅助数据,使分类结果在某种程度上较客观准确,但分类算法存在易形成局部极小而得不到全局最优;训练次数多使得学习效率低,收敛速度慢以及隐节点的选取缺乏理论指导等缺陷。

遥感影像上,通过目视解译并结合实地检验修正,选取 500 个点作为实测数据,然后将 500 个点的实测数据分别与前述 3 种方法的分类结果叠加比较。

表 1 为每类地物的分类精度及该分类器 Kappa 系数和分类总精度。

分析与评价 将实验区土地利用现状图叠加于

对于水体,由于其光谱可分性较好,3种方法均

表 1 不同分类方法的分类精度对照表

Table 1 A comparative account on the classification accuracy using different methods /%

	水体	旱地	桑园	茶园	有林地	居民地	水田	Kappa 系数	总精度
最大似然法	96	73.54	64.47	70.21	85.22	78.03	85.72	75.67	77.87
BP 神经网络	95	75.83	70.91	75.34	84.87	82.41	86.34	77.50	79.56
Kohonen 神经网络	96	75.71	74.58	75.83	86.31	83.34	87.23	80.32	82.41

能获得较好的分类精度,精度可达95%。

3种方法中Kohonen网的有林地分类精度最高,可达86%,最大似然法的分类精度最低。有林地分布区的高程一般位于70m以上,其中200m以上几乎全为有林地,其分类误差主要由于和茶园及早地存在较多的误分,因为该丘陵区山脚地带分布有较多茶园和旱地作物。

3种方法中居民地分类精度相差不大,均在84%左右,主要误差来源于水田,居民地的零星分布和水田存在一定的混合像元,从而产生误分类。

除水田外,3种方法的桑园、茶园和旱地的分类精度均低于76%,其中桑园和茶园,水田和旱地的光谱特征较为接近,存在较多的误分,其中最大似然法分类中桑园误分较多。水田分布较广,与其他地类均有误分。Kohonen网和BPNN的茶园和桑园分类精度均高于最大似然法的分类精度,其中Kohonen网的分类精度最高。

当地物分布明显受高程和坡度影响,地理辅助数据参与的Kohonen网分类能够在一定程度上消除“异物同谱”现象,提高了分类精度。本实验中该分类方法得到的结果满足精度指标的要求,即二级分类要素的精度指标按面积统计应达到80%的要求,因此,该方法具有一定应用意义。

4 结论

通过Kohonen自组织特征映射网的应用研究,可得出以下认识:

(1) 与传统统计模式识别方法及专家分类方法相比,神经网络方法可以方便加入地理辅助数据参与分类。传统统计模式识别方法难以加入地理辅助数据参与分类,而专家分类方法则要建立复杂的知识库。BPNN能够自动调整节点间的权值,能够方便加入地理辅助数据,使分类结果在某种程度上较客观准确,但分类算法存在易形成局部极小而得不到全局最优,训练次数多使得学习效率低,收敛速度慢以及隐节点的选取缺乏理论指导等缺陷。

(2) 训练数据的选择对神经网络分类结果有着直接影响,无论传统的统计模式识别方法,专家分类方法,还是神经网络分类方法都如此。神经网络方法是用每一个训练数据训练出能分出各类别的权重

体系,因此,训练数据选择方法成为一个值得研究的问题。

(3) 网络结构的选择对分类结果有明显的影响,竞争层神经元的数量与分类类别数有直接关系。神经元数量过多影响分类速度,过少则使得分类类别出现重复,影响分类精度。

(4) 遥感数据和地理辅助数据输入时的编码方法影响神经网络的分类结果,网络的输入数据通常具有不同的物理意义和量纲,其变换区间对分类精度有重要影响。怎样对遥感数据和地理辅助数据进行编码输入,需针对具体应用目的进行研究。

参考文献 (References)

- [1] Jayantha E Hierarchical Maximum-Likelihood Classification for Improved Accuracies[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1997, **35**(4): 1122—1143.
- [2] Xiong Z, Zheng L F, Tong Q X. Hierarchical Neural Network Classification Algorithm[J]. *Acta Geodaetica et Cartographica Sinica*, 2000, **29**(3): 229—234. [熊桢, 郑兰芳, 童庆喜. 分层神经网络分类算法[J]. 测绘学报, 2000, **29**(3): 229—234.]
- [3] Iio Y, Omatu S. Category Classification Method Using A Self-organizing Neural Network[J]. *INT J Remote Sensing*, 1997, **18**(4): 829—845.
- [4] Justin D, et al. The Effect of Neural-Network Structure on a Multi-spectral Land-Use/Land-Cover Classification [J]. *Photogrammetric Engineering & Remote Sensing*, 1997, **63**(5): 535—544.
- [5] Han L Q. Theory, Technique and Application of ANN[M]. Beijing: Publishing House of Chemical Industry, 2002. [韩力群. 神经网络理论、设计及应用[M]. 北京: 化学工业出版社, 2002.]
- [6] Hu S R, Yu S B, Dai K. Introduction of ANN[M]. Publishing House of National University of Defence Technology, 1993. [胡守仁, 余少波, 戴葵. 神经网络导论[M]. 国防科技大学出版社, 1993.]
- [7] Zhu H L, Mao Z Y. Knowledge Based Image Classification Approach Supported by a GIS [J]. *Acta Geodaetica et Cartographica Sinica*, 1997, **4**(26): 328—336. [朱洪磊, 毛赞猷. GIS辅助下的基于知识的遥感影像分类方法研究[J]. 测绘学报, 1997, **4**(26): 328—336.]
- [8] Ji C Y. Crop Classification Method Using a Self-organizing Neural Network[R]. *Interim Report on Crop Classification Using Neural Networks*, 1999.
- [9] Cortijo F J, Perez De La blanca N. A Comparative Study of Some Nonparametric Spectral Classifiers[J]. *Applications to problems with high overlapping training sets. Int J Remote Sensing*, 1997, **18**(6): 1259—1275.

Application of Kohonen Network in RS Image Classification

ZHANG You-shui¹, FENG Xue-zhi, RUAN Ren-zong¹, MA Tu-hua²

(1. Department of Urban and Resources Science, Nanjing University, Nanjing 210093, China;

2. Zhejiang Information Center of Land Resources, Hangzhou 310007, China)

Abstract: According to the biological basis, basic structure and learning algorithms of Kohonen network, an image classification method is introduced. Pre-processing the image with principal component analysis method based on spectral characteristics of the land use types in the experimental area, and training Kohonen self-organization mapping with geographical ancillary data, land use classifications of Kohonen network are made by integrating image with geographic ancillary data. The classification results are analyzed and compared with the results obtained by Back-Propagation neural network and Maximum Likelihood. The result shows that the classification with geographic ancillary data can improve the image classification accuracy of Kohonen network.

Key words: artificial neural network; self-organization; land use; RS image classification