

自组织网络在遥感土地覆盖分类中应用研究

孙丹峰 汲长远 林培

(中国农业大学土地资源管理系 北京 100094)

摘要 设计完成和比较了自组织网络的几种算法在遥感土地覆盖分类中的应用,结果表明非监督和监督学习相结合方法进行遥感土地覆盖分类,各算法在分类性能上无显著差异,因此可采用算法较简单的简单竞争学习网络,根据最邻近原则进行非参数分类。

关键词 自组织网络,非监督和监督学习,Kappa系数,总精度,Z检验

1 引言

近几年来随人工神经网络理论的发展,许多学者开展了人工神经网络非参数方法在遥感分类中的应用。在3大类神经网络中,遥感分类应用最多的是多层前馈网络的反向传播神经网络(BP算法),BP以外的模型很少有报道^[1],BP网络需大量学习时间,学习容易陷入低谷而不能跳出,网络有时不收敛等一系列缺点^[2]。Ji, Ito 和 Omatu, Corttjo 分别对自组织神经网络在遥感分类中的应用进行了试验^[3-5]。Ji 指出 KSOFM(Kohonen Self-Organizing Feature Map Neural Network)学习能力与输入样本顺序有关^[3],Ito and Omatu 指出经典自组织学习算法将导致只有一个神经元被激活或没有任何神经元响应^[4]。

对几种自组织学习算法在遥感土地覆盖分类中的应用进行试验研究,包括简单竞争学习(Simple Competivite Learning),频率修正竞争学习(Frequency Sensitive Competitive Learning),Desieno 学习,Kohonen 算法,模糊竞争学习(Fuzzy Competivite Learning)各自组织学习算法。

2 自组织网络结构

自组织网络结构一般有两层组成。第一层为输入层次,它接收输入样本,第二层为竞争层,它对输入样本进行分类。这两层次的神经元之间进行全互连接^[6](图1)。即一层次的每个神经元与另一层次的每个神经元均连接。对每一连接,均赋有一个权值。 W_{ij} 对应于输入样本,形成权向量 W_i 。 O_i 表示 i 神经元输出结果,遥感数据 X 从输入层进入,送

入竞争层中每一神经元,在竞争层中,根据公式(1)选出胜者神经元 W ,各神经元的权向量 W_i 的修正




图1 自组织网络基本结构

Fig. 1 The basic structure of self-organizing network
具体见下面各算法。

$$E_i = \min_i E_i \quad (1)$$

$$E_i = \sum_j (X_j - W_{ij})^2 \quad (2)$$

2.1 简单竞争学习

简单竞争学习只允许单个胜者神经元出现,学习只发生在该胜者一个神经元上。算法简单描绘如下:

$X = \{x_1, x_2, \dots, x_n\}$ 表示输入向量, n 是向量 X 的维数(如光谱波段数)。

步骤1: 对竞争层中每一神经元的权向量系数 W_{ij} 初始化为 0—255.0 间的实数。

步骤2: 输入一学习样本向量 X , 计算它与竞争层中所有神经元的距离。

$$D_i = \sum_{j=0}^n (X_j(t) - W_{ij}(t))^2 \quad (3)$$

步骤 3: 选取 D_i 最小的神经元作为胜者神经元, 其权向量系数 W_{ij} 按下面修正:

$$W_{ij}(t+1) = W_{ij}(t) + \alpha(t) \times (X_j(t) - W_{ij}(t)) \quad (4)$$

其中: $\alpha(t)$ 为学习参数, $0 < \alpha(t) < 1.0$, t 为第 t 次学习。

步骤 4: 输入一新学习样本, 重复步骤 2、3 直至网络收敛。

2.2 频率修正竞争学习

频率修正竞争学习记住胜者神经元的活跃次数, 这一胜者频率信息用来解决简单竞争学习中某些神经元始终处于休眠状态问题, 使所有神经元学习的次数接近相等。

重写 2.1 中步骤 2, 计算 X 与竞争层中所有神经元的距离。

$$D_i = \left[\sum_{j=0}^{q-1} (X_j(t) - W_{ij}(t))^2 \right] \times C_i(t) \quad (5)$$

其中: $C_i(t)$ 为神经元 i 到 t 时的累计激活次数。

2.3 Desieno 学习

该方法也属于频率修正竞争学习方法, 其频率修正采用下面方法:

$$f_i(t+1) = f_i(t) + B(y_i - f_i(t)) \quad (6)$$

其中: $f_i(t)$ 为 t 时神经元 i 的频率, 胜者神经元 $y_i = 1$, 其它神经元为 $y_i = 0$, B 为一常数 $0 < B \ll 1$ 。

2.1 中步骤 2 改写为:

$$D_i = \left[\sum_{j=0}^{q-1} \| X_j(t) - W_{ij}(t) \| \right] - b_i(t) \quad (7)$$

b_i 为与频率 f_i 有关的修正系数

$$b_i(t) = C \left[\frac{1}{m} - f_i(t) \right] \quad (8)$$

其中: m 为竞争层神经元个数, C 是一衡量距离度和激活频率之间的重要程度常数。

上述 3 种学习方法仅允许单个胜者出现, 其更一般形式应为多个胜者出现, 学习发生在胜者集合域的各个神经元上, Kohonen 算法和模糊竞争学习就属于这种协同式学习方法。

2.4 Kohonen 算法

Kohonen 算法定义了胜者神经元的邻域, 将邻域中的神经元权向量向输入样本 X 靠拢。重写 2.1 步骤 3:

$$W_{ij}(t+1) = W_{ij}(t) + \alpha(t) \times h_{ii'}(\sigma(t))$$

$$\times (X_j(t) - W_{ij}(t)) \quad (9)$$

其中: $h_{ii'}$ 定义了一个胜者神经元 i' 的高斯邻域范围, $\sigma(t)$ 为 t 时刻高斯函数的方差。

$$h_{ii'} = \exp \left[-\frac{(i-i')^2}{2(\sigma(t))^2} \right] \quad (10)$$

2.5 模糊竞争学习

考虑到遥感数据中混合像元问题, 认为每一学习样本的光谱信息或多或少对每一类别都有贡献, 定义一个模糊隶属度函数 U_i 来度量样本 X 对各神经元 i 的隶属程度, 根据隶属度函数 U_i 的大小进行竞争层神经元权向量 W_{ij} 的修正。

重写 2.1 步骤 3:

$$W_{ij}(t+1) = W_{ij}(t) + \alpha(t) \times U_i^k \times (X_j(t) - W_{ij}(t)) \quad (11)$$

$$U_i(t) = \left[1 - \frac{D_i(t)}{\max_i D_i(t)} \right] \quad (12)$$

其中: k 为模糊化指数。

3 自组织网络在遥感分类中的方法和一般过程

遥感数据在实际操作中可分为监督和非监督分类两种方法, 一般来说非监督分类方法简单, 不需要分类类别的先验知识。监督分类需要大量训练样本和分类类别的先验知识。通常监督分类结果的精度要高于非监督分类。根据数学模型的应用分为参数分类和非参数分类方法, 参数分类假定数据服从一定分布模式; 非参数分类对数据分布无任何要求和假定。

在目前遥感应应用较多的是传统的统计模式识别方法(监督分类方法中的最大似然分类法, 最小距离法等和非监督分类中的等距离混合法, 循环集群法等)。最大似然法因有严密的理论基础, 对于呈正态分布的类别判别函数易于建立, 综合应用了每个类别在各波段中的均值, 方差以及各波段之间的协方差, 有较好的统计特性, 一直被认为是最先进的分类方法^[6], 但该监督参数分类方法在实际操作有不少难点, 分布参数的估计和分类类别的光谱类别数目确定和各类别的先验概率获得^[7], 尤其当存在类别光谱混淆时, 其固定形状的决策界面无法获得较高的分类精度。人工神经网络是以人脑思维方式为模型的基础上发展起来的。一般可分为: 前馈网络, 后馈网络, 自组织网络 3 大类。由人工神经网络构

成的分类器是非参数的,对参与分类的数据无统计分布要求的限制,尤其能够通过例子进行学习和概括的能力使在遥感监督分类中得到人们的重视^[8]。作为人工神经网络之一的自组织网络用上述 2 中学习算法来寻找最优参考矢量集合来对输入模式集合进行分类,每个参考矢量为两层神经元间的连接权向量,在学习过程中由于学习速率随时间的增大而逐渐趋于零,保证了学习过程是收敛的,当学习结束时每个 W_i 近似落入由神经元 i 对应类别的输入模式空间的中心,可认为该连接权向量得到了这个输入模式空间的概率结构,这一特性使得该网络具有较好的噪声抗干扰能力^[9],这种只向网络提供一些学习样本,网络根据上述算法将输入样本进行自组织划分为相应的模式类,是一种非监督学习方法。在非监督学习中,只是向网络提供一些学习样本,而不提供理想的输出。其分类属于非参数最邻近分类方法。这种非监督学习分类精度较低,网络不易稳定,这是过去非监督分类大家所公认事实。因此,在研究中采用非监督学习和监督学习相结合的方法,分类规则采用最邻近分类方法,即将像元分为与标准向量模式距离最小的那一类别中去。

3.1 非监督学习过程

首先根据 2 中各学习算法网络进行非监督学习类别样本。

3.2 监督学习过程

接着将已知类别的样本送入已经非监督学习好

的网络中,根据多数原则对每一神经元代表类别进行标识后,当一已知类别的学习样本提供给网络后,竞争层相互竞争产生胜者,如该神经元代表该类别,则将神经元权向量向该样本靠拢;否则远离该样本。具体采用下面奖惩公式完成监督学习过程,

如果 X 被正确分类

$$W_{ij}(t+1) = W_{ij}(t) + \alpha(t) \times (X_j(t) - W_{ij}(t)) \quad (13)$$

如果 X 被错误分类

$$W_{ij}(t+1) = W_{ij}(t) - \alpha(t) \times (X_j(t) - W_{ij}(t)) \quad (14)$$

对于非胜者神经元

$$W_{oj}(t+1) = W_{oj}(t) \quad (15)$$

4 数 据

试验区位于北京市房山区,东经 $115^{\circ}25'$ — $116^{\circ}15'$,北纬 $39^{\circ}30'$ — $39^{\circ}55'$ 。最近几年土地利用/覆盖类别变化较大,非农业用地扩展较为厉害。该区域的土地利用类别主要是耕地、林地、园地、城镇、工矿用地和农村居民点,以及水域和未利用土地。TM 影像是 1997 年 5 月 16 日,抽取了 490 行 \times 500 列作为研究区域,为减少数据量,将 TM1、2、3 波段进行主成分分析,将第一主成分和 4、5、7 波段进行网络学习和分类(表 1)。学习样本和精度检验样本根据土地利用详查图和 543 彩色合成影像目视解译形成(封四图版 I 图 2)。

表 1 类别学习样本统计特征

Table 1 The statistic character of learning sample

| | PC1 | | 4 | | 5 | | 7 | | 学习样本总数(像元) |
|-------|-------|-------|-------|-------|-------|--------|------|-------|------------|
| | 均值 | 方差 | 均值 | 方差 | 均值 | 方差 | 均值 | 方差 | |
| 耕地 | 64.0 | 257.4 | 102.1 | 290.1 | 76.4 | 1524.6 | 37.2 | 647.7 | 4942 |
| 开发区 | 108.8 | 82.7 | 91.4 | 86.2 | 170.6 | 394.3 | 97.4 | 99.2 | 331 |
| 林地 | 54.0 | 13.0 | 91.7 | 238.0 | 77.9 | 329.6 | 29.4 | 40.4 | 3249 |
| 未利用地 | 73.2 | 53.3 | 70.1 | 54.9 | 97.3 | 102.7 | 51.7 | 43.7 | 3932 |
| 果园 | 65.1 | 25.1 | 92.7 | 76.2 | 98.8 | 100 | 45.0 | 47.4 | 637 |
| 农村居民点 | 78.3 | 76.2 | 76.7 | 34.2 | 86.9 | 136.6 | 47.6 | 54.4 | 937 |
| 城镇 | 86.5 | 133.0 | 67.6 | 90.4 | 89.7 | 398.4 | 54.4 | 110.9 | 2055 |
| 水域 | 62.4 | 348.0 | 23.8 | 401.8 | 16.9 | 1097.6 | 11.8 | 427.3 | 444 |

Ji, Cortijo 研究表明在学习参数固定情况下,自组织网络分类性能取决于网络中神经元的数

目^[10],因此,各学习算法中网络神经元的数目一致,对它们的分类性能进行比较。各学习参数见表

2。同时也在同样参数条件下与最大似然法分类比较,为更好满足正态分布要求,在最大似然法分类中将耕地,未利用地和水域又各自细分两个光谱业类来进行分类。

表 2 各学习参数表

Table 2 The parameter of learning

| | |
|-------------------|------------------------------|
| 神经元数目 | 100 |
| 非监督学习次数 | 49581 |
| 监督学习次数 | 165270 |
| 非监督学习 $\alpha(t)$ | $0.3 \times (1 - t/49581)$ |
| 监督学习 $\alpha(t)$ | $0.02 \times (1 - t/165270)$ |

5 比较方法

进行不同分类器分类性能比较, Kappa 统计在遥感学界已经被广泛接受, Fitzgerald 和 Lees^[10]指出 Kappa 统计在评价不同分类器的分类精度上更具有统计上的辨析力, Stehman^[11]通过公式推导证明 Kappa 系数和总精度通过 Z 检验进行不同分类器分类性能的统计显著性检验,公式完全一样。因此采用总精度进行统计显著性检验,以简单的竞争学习为标准。

$$Z = \frac{\hat{p}_{c1} - \hat{p}_{c2}}{\sqrt{\frac{\hat{p}_{c1}(1 - \hat{p}_{c1})}{n_1} + \frac{\hat{p}_{c2}(1 - \hat{p}_{c2})}{n_2}}} \quad (16)$$

其中: n_1, n_2 为各分类器检验样本的个数, $\hat{p}_{c1}, \hat{p}_{c2}$ 为各分类器的总精度估计,其通过建立检验样本混淆矩阵(Confusion matrix)得到。

6 评价结果与结论

表 3 为各学习算法 Kappa 系数,总精度和 Z 值大小。在信度 0.05 之下, Z 值均都远小于 1.96,可见各学习算法在分类性能上不存在显著性差异。在研究中简单竞争学习算法的 100 个神经元都处于激活状态,只对上述几种算法采用非监督学习和监督学习相结合的方法进行遥感土地覆盖分类在分类性能上做简单比较,对各算法学习效率没有比较,其结果是在固定学习参数和学习次数,剩余参数通过反复试验调试情况下得出。在参数条件下,其与最大似然分类方法的比较达到显著性差异,但这并不意味着该比较是在几种自组织网络分类最佳条件下得到,因为自组织网络分类性能受神经元数目和各学

习参数影响。总之与最大似然分类方法相比,可以避免由于数据分布所带来的不必要工作(如类别光谱细分,样本的代表性选取等),对自组织网络分类,分类类别直接就是地物类别(信息类),可实现复杂的非线性关系,达到提高分类精度目的,但其参数的最优确定较为困难。至于其与最大似然分类方法详细比较及自组织网络如何在学习样本中发现光谱知识,尤其在高维遥感光谱数据中,提取各土地覆盖类别的模式类,自组织网络有极大的优越性,可与专家系统相结合,弥补遥感分类专家系统中知识获取困难的缺点,将在另文报道。因简单竞争学习在算法上较简单,其只涉及学习速率参数,因此自组织网络在遥感分类中应用可以采用简单竞争学习算法,封四图版 I 图 3 是在参数条件下的分类结果图。

表 3 各学习算法评价结果

Table 3 The assessment result of these algorithm

| 学习方法 | Kappa 系数 | 总精度 | Z 值 | 检验样本总数(像元) |
|------------|----------|-------|--------|------------|
| 简单竞争学习 | 0.848 | 0.878 | 0 | 18179 |
| 频率修正竞争学习 | 0.849 | 0.880 | 0.586 | 18179 |
| Desieno 学习 | 0.851 | 0.881 | 0.878 | 18179 |
| Kohonen 算法 | 0.850 | 0.880 | 0.586 | 18179 |
| 模糊竞争学习 | 0.850 | 0.880 | 0.586 | 18179 |
| 最大似然法 | 0.839 | 0.869 | -2.466 | 18179 |

参 考 文 献 (References)

- 1 Wang Yeqiao. The artificial neural network model in remote sensing and multi-resource geographical data classification. *Scientia Geographica Sinica*, 1997, (2): 105-111. (in Chinese) [王野乔. 遥感及多源地理数据分类中人工神经网络模型. 地理科学, 1997, (2): 105-111.]
- 2 Heermann P D, khazenie N. Classification of multispectral remote sensing data using a back propagation neural network. *IEEE Trans Geosci Remote Sensing*, 1992, (1): 81-88.
- 3 Ji C Y. Crop classification method using a self-organizing neural network. Interim report on crop classification using neural networks, 1997, 3.
- 4 Iio Y, Omatu S. Category classification method using a self-organizing neural network. *Int J Remote Sensing*, 1997, 18(4): 829-845.
- 5 Cortijo F J, Perez De La blanca N. A comparative study of some non parametric spectral classifiers. Applications to problems with high overlapping training sets. *Int J Remote sensing*, 1997, 18(6): 1259-1275.
- 6 Kohonen T. An introduction to neural computing. *Neural networks*, 1998, (1): 3-16.
- 7 Ince, F. Maximum likelihood classification: optimal or problematic? A

- comparison with the nearest neighbour classification. *Int. J. Remote Sensing*, 1987, **12**: 1829—1838.
- 8 Schalkoff, R. Pattern recognition; statistical, structural and neural approach. New York; Wiley 1992.
- 9 Kohonen T. Learning vector quantization for pattern recognition. Helsinki University of technology, Department of Technical Physics Technical Report, 1986.
- 10 Fitzgerald R W, Lees B G. Assessing the classification Accuracy of multisource Remote Sensing data. *Remote Sens Environ*, 1994, **47**: 362—368.
- 11 Stehman S V. Selecting and interpreting measures of thematic classification accuracy. *Remote Sens Environ*, 1997, **62**: 77—89.

作者简介

孙丹峰, 男, 1971 年生, 1998 年中国农业大学博士毕业后在该校土地资源系工作, 从事土地资源及利用遥感监测教学和研究工作。

Landcover Classification of Remote Sensing Imagery Using Self-organizing Neural Network

SUN Dan-Feng JI Chang-Yuan LIN Pei

(Land Resource Department, China Agricultural University, Beijing 100094)

Abstract In this paper, the implement and comparison of different self-organizing learning algorithm in landcover classification of Landsat TM imagery it is found that, with the combination of unsupervised and supervised learning method and the nearest neighbour principle, these algorithms have no significant difference in classification accuracy. The study result shows that the self-organizing network is an another method to classify the landcover type in remote sensing imagery by combining the unsupervised and supervised learning phase with the nearest neighbour principle. Because of the simplicity of the Simple Competitive Learning, the self-organizing network can use the Simple Competitive Learning algorithm in remotely sensed data classification.

Key words Self-organizing network, Unsupervised and Supervised learning, Kappa agreement coefficient, Overall accuracy, Z test




图 2 5,4,3 波段合成影像

图 3 分类结果图

遥感学报

(季刊 1997 年创刊)

1999 年 5 月 第 3 卷 第 2 期

JOURNAL OF REMOTE SENSING

(Quarterly, Started in 1997)

Vol. 3 No. 2 May 1999

编 辑 《遥感学报》编辑委员会

北京市安外大屯路中科院遥感所

邮政编码 100101

主 编 徐 冠 华

出 版 科 学 出 版 社

北京东黄城根北街 16 号

邮政编码: 100717

印刷装订 中国科学院印刷厂

总发行处 北京报刊发行局

订购处 全国各邮电局

国外总发行 中国国际图书贸易总公司

(中国书店)

北京 399 信箱

Editor: Editorial Board of Journal of

Remote Sensing

P. O. Box 9718, Beijing 100101, China

<http://www.irsa.ac.cn>; E-mail: kxs@irsa.irsa.ac.cn

Chief Editor: Xu Guanhua

Publisher: Science Press

16, Donghuangchenggenbeijie Street

Beijing 100717, China

Distributed Abroad: China International

Book Trading Corporation

(Guoji Shudian)

P. O. Box 399, Beijing, China

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. <http://www.cnki.net>