

文章编号: 1007-4619(2007)06-0778-09

结合 SOM 神经网络和混合像元分解的 高光谱影像分类方法研究

徐宏根¹, 马洪超^{1,2}, 李德仁²

(1. 武汉大学 遥感信息工程学院, 湖北 武汉 430079; 2. 武汉大学 测绘遥感信息工程国家重点实验室, 湖北 武汉 430079)

摘要: 本文对 SOM 神经网络算法进行改进, 在标类的过程中采用 3 个策略加以控制, 对初始产生的自组织映射图进行调整。通过改进, 那些映射到可靠神经元的像素得到了很好的分类, 而那些映射到不可靠神经元的像素都被作为不可分像元而提取出来。继而, 从混合像元分解的角度来对这些不可分像元进行处理, 按类型分解的思想确定混合像元的类别, 实现对不可分像元的分类。将 SOM 神经网络和混合像元分解相结合的分类方法应用于高光谱图像的分类中, 通过实验表明了该方法能较好地改善分类效果, 提高分类精度。

关键词: 高光谱影像分类; SOM 神经网络; 混合像元分解

中图分类号: TP751.1 **文献标识码:** A

Research on the Classification Based on SOM and LSMA for Hyperspectral Image

XU Hong-gen¹, MA Hong-chao^{1,2}, LI De-ren²

(1. School of Remote Sensing and Information Engineering, Wuhan University, Hubei Wuhan 430079, China;
2. National Key Lab for Information Engineering in Surveying, Mapping and Remote Sensing,
Wuhan University, Hubei Wuhan 430079, China)

Abstract: In SOM algorithm it will create a map in output layer in which the cells are labeled class ID, e. g. 1, 2, 3, etc. It's curial for correctly classifying the data to make map. In this paper, we focus our interests on analyzing the map and the process of creating map to improve the SOM. We take three measures to change the map. We can classify the pure pixels and find the mixed pixels through the changed map. Furthermore, we can process the unclassified pixels from the view of linear spectral mixture analysis (LSMA). Furthermore, we consider the two constraints: unnegative and the sum one, so the constraint spectral mixture analysis (CSMA) is applied in this paper. After CSMA, we assign the class ID to the endmember which has largest proportion in the mixed pixel. So, the spectral unmixing classification based on category proportion is performed to the unclassified pixels. Thus, we can get the extreme classification combining the former results. The experiment shows that the classification combined SOM with LSMA can get better classification results and well improve the classification accuracy.

Key words: hyperspectral image; SOM neural network; linear spectral mixture analysis (LSMA)

1 引言

当前, 对高光谱图像的分类技术研究比较多。

归纳起来有: (1) 基于统计模型的分类, 如最大似然分类 (Maximum Likelihood Classification, MLC); (2) 光谱匹配分类, 如波谱角分类 (Spectral Angle Mapping, SAM); (3) 神经网络分类, 如自组织特征

收稿日期: 2005-12-16; 修订日期: 2007-01-02

基金项目: 国家 863 计划项目 (编号: 2003AA135010) 资助, 教育部国防基础科研项目 (编号: A1420060213) 资助。

作者简介: 徐宏根 (1979—), 男, 武汉大学摄影测量与遥感专业博士生。研究内容为遥感图像处理、神经网络、网格计算等。E-mail: honggen_xu@163.com

映射神经网络(Self-Organizing Map, SOM);(4)模糊模式分类技术;(5)光谱混合分析技术(Spectral Mixture Analysis, SMA)。对上述方法可以概括为全像元技术(Full-Pixel Techniques)分类和混合像元技术(Mixed-Pixel Techniques)分类^[1]。前3种为全像元技术,它假设图像上的每一像素都是由单一物质构成或主导的;后两种为混合像元技术,与全像元技术不同的是,它假设图像上的每一像素都是由多种物质构成的,发展的混合像元分解技术在高光谱图像的分析中得到了广泛的应用^[2-4]。

由于传统的基于统计模型分类需要假定各类服从正态分布,SAM不能较好地处理谱形相似而反射强度差异明显的地物的情况,BP网络收敛速度慢,易陷入局部最小值,且隐层数目和隐层节点确定困难,而SOM神经网络不需要数据符合一定的统计模型,且具有优良的聚类性能,抗噪能力强,因此有很多学者研究利用SOM神经网络来进行遥感图像分类^[5-7]。在文献[5]中讨论了SOM神经网络即使在某些输入节点受噪声影响较大的情况下,对最终分类影响也较小;在文献[6]中给出了SOM神经网络与经LVQ算法精细调整的分类结果的比较,发现经LVQ算法调整之后可以改善直接SOM分类效果。在文献[7]中指出对用于最后分类的SOM自组织图中,仍有少部分神经元不可分或属于两种或两种以上的类别,采用了按该神经元的最大类别数量确定其所属类别。

事实上,由于SOM神经网络在训练过程中初始连接权值的选择、初始网络训练样本及其进入训练的顺序及输出层的节点数(输出神经元),对分类结果都会有影响^[7,8]。而且在产生自组织映射图(即标类)的过程中,训练样本的纯净与否对最终分类也会有影响。本文从另外一个角度来改进SOM算法,即在标类的过程中采用3个策略加以控制,对初始产生的自组织映射图进行调整。通过改进,那些映射到标记为非0神经元(即可靠神经元)的像素得到了很好的分类,而那些映射到标记为0神经元(即不可靠神经元)的像素都被作为不可分像元保留。对这些不可分像元的处理,本文从混合像元分解的角度来考虑,按类型分解(Category Proportion)^[9,10]的思想确定混合像元的类别,实现对不可分像元的分类。将SOM神经网络分类和对不可分像元进行混合像元分解相结合的分类结果,即为最终分类结果。

2 SOM神经网络算法及其改进

SOM神经网络又称Kohonen网络,最先由Kohonen教授提出,SOM算法的更多细节见文献[11]。SOM神经网络可以认为是二层网络,一层是输入层,另一层是输出层。二层之间由一系列权值相互连接。一旦网络权值收敛或固定,输入向量将被映射到输出层的某个神经元上,这个过程就完成了多维数据的聚类。其原理如图1所示。

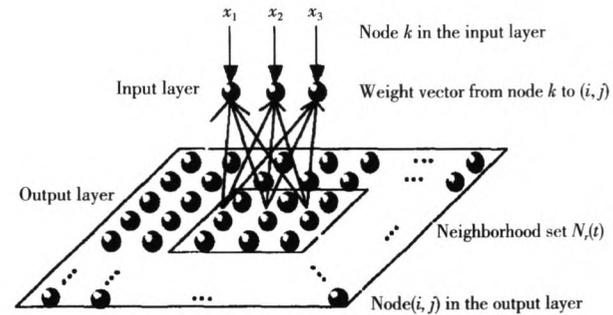


图1 SOM神经网络

Fig. 1 SOM Neural Network Configuration

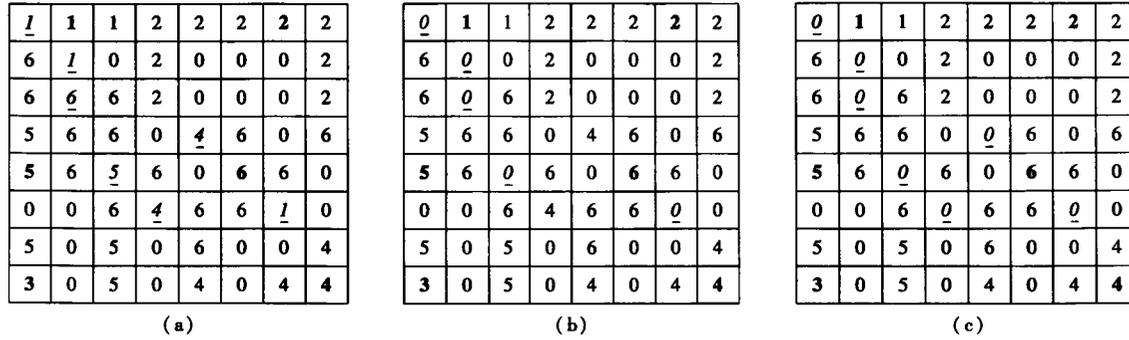
然而,它必须采用带监督的学习过程通过给输出层的神经元标类来执行分类,这个过程就是产生自组织映射图,确定自组织映射图对于正确地分类至关重要。通常在标类时采用多数投票的原则进行。

基于SOM神经网络算法的聚类原理,输入的数据越是相似,这些数据就会被映射到越靠近所产生的聚类中心,本文在标类的过程中采用了3个策略来改进算法,在自组织图中找出不可靠神经元,而映射到这些不可靠神经元的像素都被作为不可分像元提取出来,而其他像素经SOM神经网络进行分类。在标类的过程中,第一,未得到激活的神经元都标记为0。这里,未激活的神经元不是指在SOM网络的训练过程中,而是在标类过程中产生的死神经元,即没有训练样本映射到该神经元。第二,设置阈值来判定该神经元所属的类别。因为有可能某两个或多个类别的数据映射到这个神经元的数目相当,这时,不是采用通常的多数投票原则进行,而采用比值的方式进行判定,即类别中最大映射到这个神经元类别的数目与所有映射到这个神经元的数目的比值,如果该比值小于设定的阈值,则认为该神经元是不可靠神经元,标记为0。第三,分析产生的自组织图中,若某神经元与其4邻域神经元所标的类别都不相同,则将其认为是不可靠神经元,重新标记为0,

而最强响应的神经元(即聚类中心)除外。在标类的过程中有可能某些类别只会映射到单一一个神经元上,这个单一神经元也是该类别的最强响应神经元,该神经元应予以保留,而那些与4邻域标类都不相同的神经元,与SOM聚类会产生对输入模式的拓扑表达的原理^[12]相冲突,应该被作为不可靠神经

元,标记为0。

图2(a)–(c)为本文实验中产生的自组织映射图,输出神经元的大小是8×8。图中1,2,⋯,6表示各神经元标示的类别,黑体加粗的数字标示神经元为最强响应的神经元,斜体加下划线的数字标示神经元表示类别经过调整的神经元。



(a)

(b)

(c)

图2 自组织映射图

(a) 多数投票原则产生; (b) 采用了第一、二策略产生; (c) 最终产生的自组织映射图

Fig. 2 Self-organizing map

(a) The map by majority voting; (b) The map by our means; (c) The final map

改进 SOM 算法如下:

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。

1) 对神经元的权值向量 w_j 进行随机初始化, 初始值为小于 0.1 的非负值。

2) 等间隔从图像中充分选取初始网络训练样本, 构成样本集 ϕ , 对每一输入向量 $x (x \in \phi)$, 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:

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

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:

$$\begin{cases} w_{ij}(t+1) = w_{ij}(t) + \alpha(t)[x_i(t) - w_{ij}(t)], & j \in N_{c_j}(t) \\ w_{ij}(t+1) = w_{ij}(t), & j \notin N_{c_j}(t) \end{cases} \quad (2)$$

式中, j 是输出层神经元; $\alpha(t)$ 是学习速率, 随迭代次数 t 的增加而逐渐减少, 其初值一般设在 0.0—1.0 之间; $N_{c_j}(t)$ 是 t 时刻的获胜单元的侧反馈邻域, $N_{c_j}(t)$ 从大到小的过程是网络的有序化过程, $N_{c_j}(t)$ 到零以后是网络的收敛过程。

4) 输入新的向量, 重复步骤 2) 和 3), 直到达到预设的循环次数为止。本实验中选取 2500 次。当网络收敛后, 网络权值已经固定, 这时采取本文上述提到的 3 个策略来确定最终用于标类的特征映射图。

5) 输入训练样本数据。确保输入训练样本数据的各类别的像元数大致相当。

6) 假设 $w2[i][j]$ 表示记录第 i 类数据映射到第 j 个神经元的数目, $classID[j]$ 表示第 j 个神经元所标的类别, T 为阈值。取 $w2[i][j]$ 中映射到第 j 个神经元最大的记为 $w2[i_{max}][j]$, 即 $\max(w2[i][j])_{i=1, \dots, num} = w2[i_{max}][j]$, $\sum_{i=1}^{num} w2[i][j]$ 为映射到第 j 个神经元的总数, $i = 1, 2, \dots, num$ (num 为类别数), $j = 1, 2, \dots, nCells$ ($nCells$ 为输出层的神经元个数)。如果 $w2[i][j] = 0$, 则 $classID[j] = 0$; 如果 $w2[i_{max}][j] / \sum_{i=1}^{num} w2[i][j] \leq T$, 则 $classID[j] = 0$; 如果 $w2[i_{max}][j] / \sum_{i=1}^{num} w2[i][j] > T$, 则 $classID[j] = i_{max}$ 。

7) 找到各类别的最强响应的神经元(即各类别的聚类中心)。假设 $w3[i][j]$ 记为映射到第 j 个神经元的第 i 类数据的数目, 取 $w3[i][j]$ 中表示第 i 类数据映射到所有神经元的最大数为 $w3[i][j_{strong}]$, 即 $\max(w3[i][j])_{j=1, \dots, nCells} = w3[i][j_{strong}]$, $i = 1, 2, \dots, num$ (num 为类别数), $j = 1, 2, \dots, nCells$ ($nCells$ 为输出层的神经元个数), 若某个神经元的标类与其 4 邻域的标类都不相同, 则将其标记为 0, 最强神经元 j_{strong} 除外。这时, 固定网络权值和

输出层神经元的类别,输入原始数据进行分类即完成 SOM 神经网络的分类。通常 LVQ 算法会与 SOM 算法结合使用,对 SOM 粗调的网络权值进行精细调整。本文采用 LVQ1^[11]算法进行调整。

8) 输入训练样区的样本 x , 并找到使 $\|x - w_c\|$ 最小的输出神经元 c 。

9) 网络权值按下列方式进行:

$$w_c(t+1) = w_c(t) + \alpha(t)[x_i(i) - w_c(t)] \quad \text{如果 } x \text{ 被正确标类} \quad (3)$$

$$w_c(t+1) = w_c(t) - \alpha(t)[x_i(t) - w_c(t)] \quad \text{如果 } x \text{ 被错误标类} \quad (4)$$

$$w_i(t+1) = w_i(t) \quad \text{如果 } i \neq c \quad (5)$$

学习速率 $\alpha(t)$ 随迭代次数 t 递减,其初始值和计算方法同上。

10) 输入新的向量,重复步骤 8) 和 9), 直到达到预设的循环次数为止。本实验中选取 2500 次。固定精细调整的网络权值,采用步骤 5), 6), 7) 来对神经元进行标类,产生最终的用于分类的特征映射图,使得不可靠的神经元都被标为 0。这样,输入原始数据进行分类,那些映射到标记为非 0 的神经元的像素得到了分类,而映射到不可靠神经元的像素即为不可分像元。

3 混合像元分解

混合像元分解模型可以分为线性模型和非线性模型。有研究^[2]指出,在某些情况下非线性模型较线性模型能更好的对像元成分准确地估计,但是它有更多地参数需要估计,而这些参数很难得到。所以目前最常用的是线性模型。线性混合像元分解模型 (Linear Spectral Mixture Analysis, LSMA) 的原理是:

它假设组成混合像元的几种不同地物的光谱以线性的方式组合成混合像元的光谱,利用一个线性关系表达图像中每个像元内各地物的类型和成分比例。第 i 波段像元反射率 x_i 可以表达为:

$$x_i = \sum_{j=1}^n (a_{ij}f_j) + \varepsilon_i \quad (6)$$

式中, $i = 1, 2, \dots, m$, 表示波段数; $j = 1, 2, \dots, n$, 表示端元组分数,即类别数; x_i 表示混合像元的反射率; a_{ij} 表示第 i 个波段第 j 个端元组分的反射率; f_j 是该像元第 j 个端元组分的百分含量; ε_i 是第 i 波段的误差。写成矩阵形式有:

$$X = AF + \xi \quad (7)$$

在满足

$$0 \leq f_j \leq 1 \quad (8)$$

和

$$\sum_{j=1}^n f_j = 1 \quad (9)$$

的约束条件下,按最小二乘原理对式(6)或(7)求解 F 。用矩阵的方法求解可以表达为:

$$F = (A^T A)^{-1} A^T X \quad (10)$$

要保证式(10)的正确求解,要求波段数 m 大于端元组分数 n 。实验中,波段数 m 为 80,端元组分数 n 为 6。

用上述方法求解的各端元组分的百分含量 f_j 通常并不能满足式(8)和(9)的限制条件,即有可能出现 f_j 为负值或大于 1 的情况。这对其物理意义而言是不允许的。本文采用了带约束的光谱混合分析方法 (Constrained Spectral Mixture Analysis, CSMA)^[13] 来进一步加以约束。

CSMA 方法是通过梯度迭代求解式(7)的解,在式(8)和(9)约束条件下,构建新的目标函数:

$$E = \|\xi\|^2 + A_1 g_1(F) + A_2 g_2(F) \quad (11)$$

式中, $\|\xi\|^2$ 为式(2)误差矩阵 ξ 的二阶范数,即最小二乘误差, A_1 和 A_2 为常数, g_1 和 g_2 为约束条件式(3)和(4)的代价函数,有

$$g_1(F) = \sum_{i=1, f_i < 0}^n f_i^2, \frac{\partial g_1(F)}{\partial f_i} = \begin{cases} 2f_i & f_i < 0 \\ 0 & f_i > 0 \end{cases}$$

$$g_2(F) = \begin{cases} 0 & \sum_{i=0}^n f_i \leq 1 \\ \left(\sum_{i=1}^n f_i - 1 \right)^2 & \sum_{i=0}^n f_i > 1 \end{cases},$$

$$\frac{\partial g_2(F)}{\partial f_i} = \begin{cases} 0 & \sum_{i=1}^n f_i \leq 1 \\ 2 \left(\sum_{i=1}^n f_i - 1 \right) & \sum_{i=1}^n f_i > 1 \end{cases}$$

则其迭代式可写为:

$$\begin{aligned} f_i^{(t+1)} &= f_i^{(t)} - \delta \frac{\partial E}{\partial f_i} \\ &= f_i^{(t)} - \delta \left(\frac{\partial \|\xi\|^2}{\partial f_i} + A_1 \frac{\partial g_1(F)}{\partial f_i} + A_2 \frac{\partial g_2(F)}{\partial f_i} \right) \end{aligned} \quad (12)$$

式中, $f_i^{(t)}$ 为第 i 个端元组分第 t 次迭代的结果, δ 为一较小的常数, t 为迭代次数。要保证式(12)在较少的迭代情况下收敛,只需要选择适当的 δ, A_1, A_2 即可。由于 $\frac{\partial \|\xi\|^2}{\partial F} = M(F - F_0)$, 其中 F 为某一次迭代的各端元组分的百分含量, F_0 为按式(10)计算的初始各端元组分的百分含量,每次迭代过程中两者相差微

小。 M 为 m_{ij} 构成的矩阵, $m_{ij} = 2 \sum_{b=1}^m (A_{bi} \cdot A_{bj})$ 为一常数, A_{bi} 表示第 i 个端元组分第 b 个波段的反射率, A_{bj} 表示第 j 个端元组分第 b 个波段的反射率, 从人工选取的端元组分中获得, 为已知。 ($i, j = 1, 2, \dots, n, n$ 为端元组分数, m 为波段数)。因此, 只需要 δ, A_1, A_2 与 $M(F - F_0)$ 在数量级上满足一定关系就能使式(12)较快收敛。在实验中, $M(F - F_0)$ 的数量级为 10^6 , 本文选用的 δ, A_1, A_2 分别为 $8 \times 10^{-7}/(3t + 1), 1/(4t \times 10^{-5}), 1/(2t \times 10^{-5})$, t 从 1 开始, 每迭代一次加 1。迭代 30 次即可完成收敛。

对混合像元分解之后, 按类型分解的思想确定混合像元的类别, 即每一像元由其端元组分百分含量最大的来确定其所属类别。

4 实验与分析

4.1 数据

本文选用的实验数据是成像光谱仪 PHI 影像, 位于江苏省常州市夏桥地区, 获取于 1999 年 9 月。经度 $119^\circ 22' 11''$, 纬度 $31^\circ 41' 44''$ 。共有 80 个波段,

波长范围在 $0.42\text{—}0.85\mu\text{m}$, 图像大小为 346 像素 \times 512 像素。地面实测资料同步所得。如图 3(a) 所示为原始影像 66, 33, 11 波段组合, 图 3(b) 为原始影像立方体。参照地面实测资料进行样区的选择, 分为 6 类, 分别是水体 (water), 谷类 (cereal), 道路 (road), 土地 (soil), 建筑物 (building) 和树 (tree)。每类的光谱反射曲线如图 4 所示。表 1 给出了各类别所选样本的数目, 在精度评价中采用随机选取 400 个点来进行精度评价。实验中算法均在 GeoImager 软件平台用 VC++ 二次开发实现。

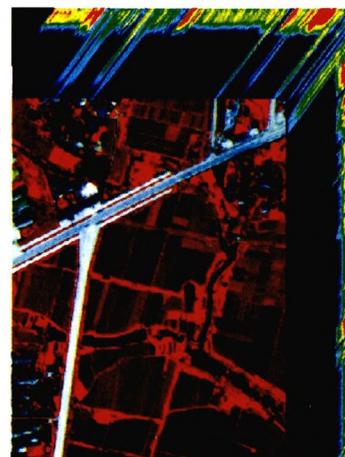
表 1 各类别的训练样本

Table 1 The Training Samples of Each Class

类名	各类的样本个数
水体	215
谷类	254
道路	216
土壤	366
建筑物	272
树	153
总样本数	1276



(a)



(b)

图 3 原始 PHI 数据

(a) 原始数据 66, 33, 11 波段组合; (b) 影像立方体

Fig. 3 PHI data

(a) RGB image with 66th, 33th, 11th band; (b) PHI image cube

4.2 数据预处理

本文实验数据先作了几何精纠正和辐射校正, 经定标转换为反射率的高光谱影像。考虑到高光谱影像波段数众多、信息量丰富且波段间有较大的相关性, 采用了 MNF 变换^[14], MNF 变换能够有效地减

少维数、去除噪声并使得有用的信息集中在前几个分量上。它比 PCA 主分量变换更有效, 在高光谱数据处理和分析上得到了广泛应用^[15]。更多的细节参看文献[14]。在本实验中, 取前 15 个分量用于 SOM 分类, 这样可以大大提高处理效率。而对采用混合像元分解来处理的不可分像元不应该用 MNF

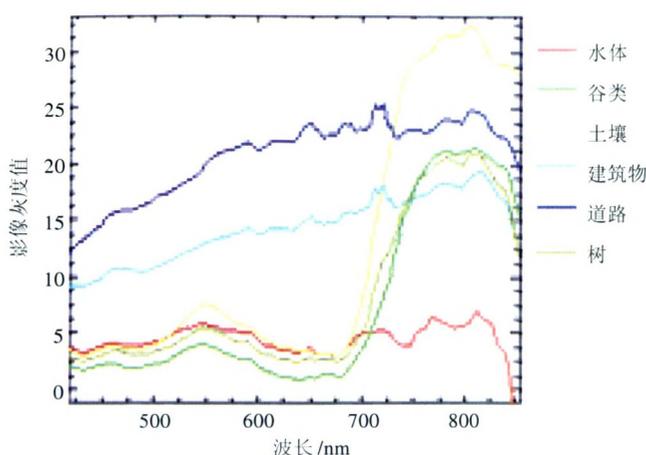


图 4 各类别的光谱响应曲线

Fig. 4 The Spectral Reflectivity Curve of Different Class

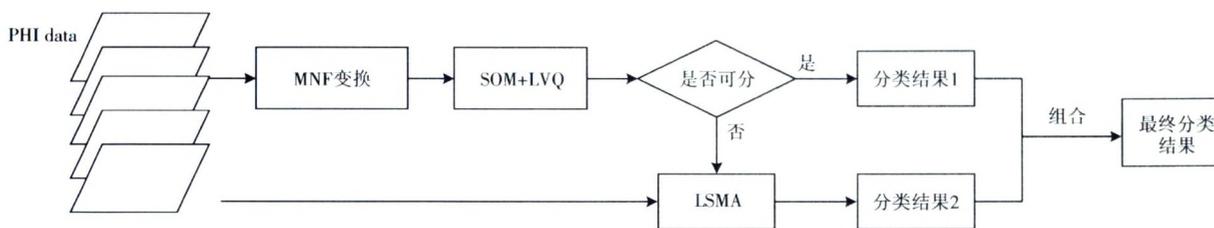


图 5 结合 SOM 神经网络和混合像元分解的分类方法流程图

Fig. 5 The flow of classification combined SOM and LSMA

在本文实验中,SOM 神经网络的输出层神经元大小为 8×8 ,初始学习率为 0.700,迭代次数为 2500 次,用于标类的阈值 T 取 0.5。对 SOM 神经网络进行训练的初始输入样本采用从图像中等间隔采样,训练后使网络收敛。对上述收敛的网络经 LVQ 算法精细调整,就是将所选 6 类的样本数据加载进去,再经过迭代训练,使网络权值得到微调。最终用于分类的自组织映射图,见图 2(c)。表 2 列出了经 SOM + LVQ 分类的各类别及不可分像元的数目。实验中在进行混合像元分解时,人工选取端元组分,即为上述用于 SOM 分类的训练样本,共 6 类。经过 MNF 变换后光谱的意义发生了变化,不适合采用混合像元分解进行。因此这些不可分像元在进行混合像元分解时没有进行 MNF 变换,采用的原始波段 80,其他参数在本文第 2 节中已有说明。本文随机选取了 9 个不可分像元通过混合像元分解得到了各类别的百分含量,并按照端元组分百分含量最大的来确定其所属类别,如表 3 所示。可以看到,这些不可分像元中至少有 2 种类别的百分含量比较接近,因此,从混合像元分解的角度来处理这些不可分像元是比较合理的。

变换来处理。

4.3 实验结果与分析

本文对原始数据采用 MNF 变换,继而采用本文改进的 SOM 算法进行分类,在 SOM 分类中利用产生的自组织映射图,将映射到标记为非 0 神经元的像素进行正确分类,而映射到标记为 0 神经元(不可靠神经元)的像素被认为是不可分像元。从而对原始数据进行了第一次的分类,同时也提取出了不可分像元。随后,从混和像元的角度出发,对这些不可分像元进行混和像元分解,按照端元组分百分含量最大的来确定其所属类别,得到了不可分像元的分类结果。将这两次分类结果进行合并即为最终的结果。本文所采用方法的流程图如图 5 所示。

表 2 SOM + LVQ 的分类结果

Table 2 The Classification Result by SOM + LVQ

类名	像素数	百分比/%
混合像元	14382	8.12
水体	6131	3.46
谷类	83759	47.28
道路	11215	6.33
土壤	21409	12.09
建筑物	9715	5.48
树	30541	17.24
总像素数	177152	

图 6(a) 给出了 SOM + LVQ 的分类结果,其中黑色代表不可分像元;图 6(b) 给出了经 SOM + LVQ 后的不可分像元的提取结果。图 7(a) — (c) 分别给出了结合 SOM + LVQ 和混和像元分解方法、最大似然分类(MLC)和波谱角分类的分类结果。在精度评价中,随机选取 400 个样本点进行分析。通过比较混淆矩阵,经 LVQ 算法调整的 SOM 神经网络与混合像元分解相结合的分类总体精度是 93.25%, Kappa 系数是 0.9036;MLC 的总体精度是 83.25%, Kappa 系数是 0.765;SAM 的总体精度是 85.25%, Kappa 系数是 0.789,见表 4—表 6。这个结果说明

表 3 选取的 9 个不可分像元由 LSMA 分解的结果
Table 3 The Proportions of 9 Unclassified Pixels by LSMA

影像坐标	水体的百分含量	谷类的百分含量	道路的百分含量	土壤的百分含量	建筑物的百分含量	树的百分含量	类别
(94,101)	-0.002604	0.146195	-0.001766	0.607614	0.259222	-0.002248	土地
(95,100)	-0.005820	0.684067	-0.005189	0.210081	0.137307	-0.005545	谷类
(84,145)	0.157559	0.381409	-0.003690	-0.003961	0.483768	-0.004145	建筑物
(46,146)	0.152712	0.060507	-0.000303	0.307834	0.481938	-0.000855	建筑物
(70,199)	0.696986	-0.011386	-0.010998	0.309122	0.057494	-0.011393	水体
(266,69)	0.115781	-0.005867	0.571300	0.352133	-0.007150	-0.007534	道路
(48,254)	-0.000369	0.152168	0.000578	0.417313	0.326084	0.104826	土地
(247,432)	-0.012583	0.654047	-0.011836	-0.012068	0.432799	-0.011882	谷类
(51,502)	-0.007318	0.523838	-0.006763	-0.006822	-0.006989	0.526436	树

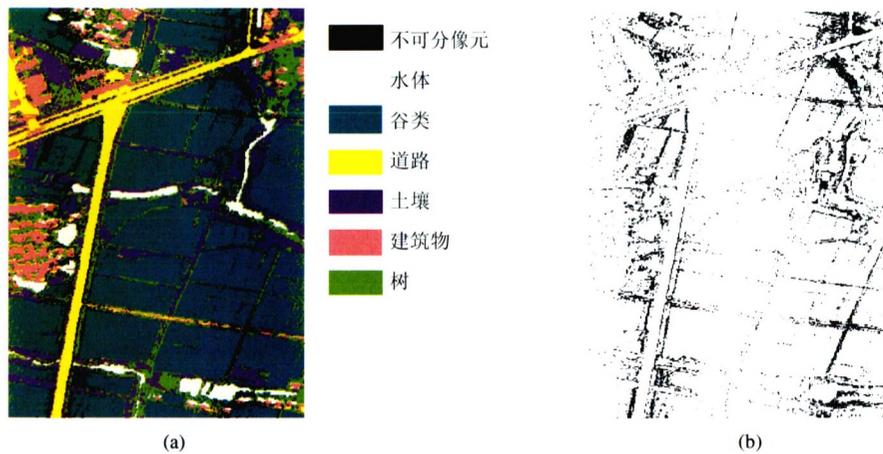


图 6 SOM+LVQ 处理结果

(a) SOM+LVQ 的分类结果; (b) 不可分像元的提取结果

Fig.6 The result of SOM and LVQ

(a) The classification of SOM and LVQ; (b) The extraction result of unclassified pixels

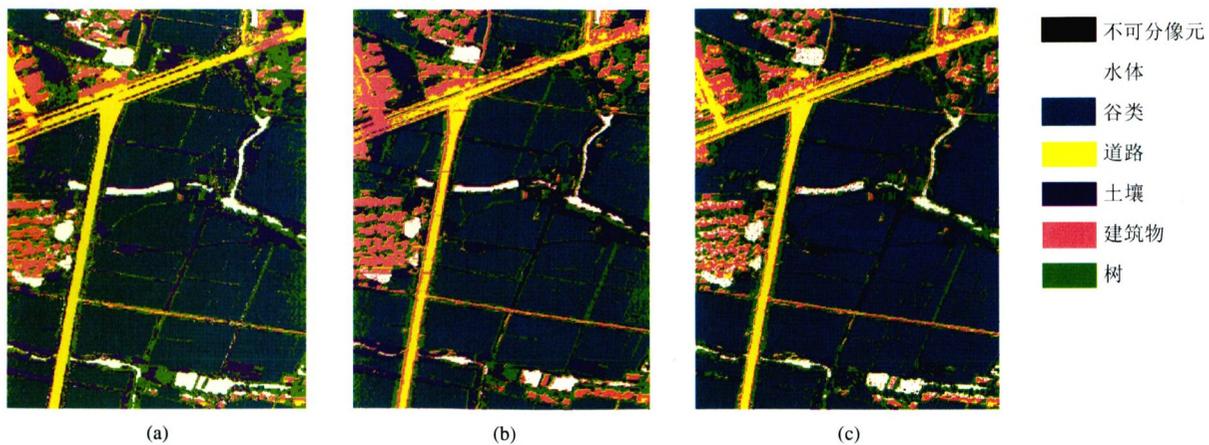


图 7 分类结果影像

(a) SOM+LVQ 最终分类结果; (b) MLC 分类结果; (c) SAM 分类结果

Fig.7 Classification result image

(a) The final classification of SOM and LVQ; (b) The classification of MLC; (c) The classification of SAM

表 4 SOM + LSMA 分类的混淆矩阵

Table 4 Confusion matrix for the classification combined SOM and LSMA

类别	水体	谷类	道路	土壤	建筑物	树	列和	用户精度/%
水体	19	0	0	0	0	1	20	95.00
谷类	0	191	0	3	0	0	194	98.45
道路	0	0	35	1	0	0	36	97.22
土壤	0	2	1	53	1	1	58	91.38
建筑物	0	0	3	1	22	1	27	81.48
树	0	4	2	3	3	53	65	81.54
行和	19	197	41	61	26	56	400	
生产者精度/%	100.00	96.95	85.37	86.89	84.62	94.64		

总精度 = 93.25% , Kappa 系数 = 0.9036

表 5 MLC 分类的混淆矩阵

Table 5 Confusion matrix for MLC classification

类别	水体	谷类	道路	土壤	建筑物	树	列和	用户精度/%
水体	15	0	0	0	3	2	20	75.00
谷类	0	185	1	5	0	3	194	95.36
道路	0	0	33	1	0	2	36	91.67
土壤	0	2	2	50	2	2	58	86.20
建筑物	0	0	3	3	19	2	27	70.37
树	3	9	6	13	3	31	65	47.69
行和	18	196	45	72	27	42	400	
生产者精度/%	83.33	94.39	73.33	69.44	70.37	73.81		

总精度 = 83.25% , Kappa 系数 = 0.765

表 6 SAM 分类的混淆矩阵

Table 6 Confusion matrix for SAM classification

类别	水体	谷类	道路	土壤	建筑物	树	列和	用户精度/%
水体	16	0	0	0	2	2	20	80.00
谷类	0	189	0	5	0	0	194	97.42
道路	0	0	35	1	0	0	36	97.22
土壤	0	2	2	51	1	2	58	87.93
建筑物	0	0	3	3	19	2	27	70.37
树	3	9	6	13	3	31	65	47.69
行和	19	200	46	73	25	37	400	
生产者精度/%	84.21	94.50	76.09	69.86	76.00	83.78		

总精度 = 85.25% , Kappa 系数 = 0.789

本文方法显著地提高了分类精度。

5 结 论

通过本文的实验研究,可以得出如下认识:

(1) 通过对 SOM 神经网络算法的改进,使得区分出自组织映射图中可靠神经元和不可靠神经元,对映射到可靠神经元的像素进行分类,而对映射到不可靠神经元的像素,即不可分像元,从混合像元分解角度进行混合像元分解来确定其所属类别,从而避免了直接用 SOM 对所有像元进行分类的不可靠性,使得分类结果更可靠。与 MLC 和 SAM 分类结果相比较,分类精度有很大提高。

(2) 本文提出的方法实际上是结合全像元技术和混合像元技术的分类的思想,能对匀质区域和混合像元区域分别处理,较好地避免了对混合像元和匀质区域的误分类。但是本文所提出的方法在 SOM 神经网络分类过程中对不可分像元的提取受限于 SOM 分类的结果,所以需要进一步研究如何准确地将混合像元区域和匀质区域分开,然后进行后续处理。

致 谢 感谢武汉大学测绘遥感信息国家重点实验室张良培教授提供的高光谱数据和指导。

参 考 文 献 (References)

- [1] Robert S Rand, Daniel M Keenan. A Spectral Mixture Process Conditioned by Gibbs-based Partitioning [J]. *IEEE Trans. Geoscience and Remote Sensing*, 2001, 39(7): 1421—1433.
- [2] Nirmal Keshava, John F Mustard. Spectral Unmixing [J]. *IEEE Signal Processing Magazine*, 2002: 44—57.
- [3] Chang C-I, Heinz D. Constrained Subpixel Detection for Remotely Sensed Images [J]. *IEEE Trans. Geoscience and Remote Sensing*, 2000, 38(3): 1144—1159.
- [4] Chang C-I. Target Signature-constrained Mixed Pixel Classification for Hyperspectral Imagery [J]. *IEEE Trans. Geoscience and Remote Sensing*, 2002, 40(5): 1065—1081.
- [5] Guo Y P. Unsupervised Classification of High Spectral Resolution Images Using the Kohonen Self-organization Neural Network [J]. *Journal of Infrared and Millimeter Waves*, 1994, 13(6): 409—417. [郭一平. 用 Kohonen 神经网络对高光谱分辨率图像进行无监督分类的研究 [J]. 红外与毫米波学报, 1994, 13(6): 409—417.]
- [6] HASI Bagan, Ma J W, Li Q Q, et al. Dimension Reduction of Self-organized Neural Network Classification for Multi-band Satellite Data [J]. *Geomatics Information Science of Wuhan University*, 2004, 29(5): 461—465. [哈斯巴干, 马建文, 李启青等. 多波段遥感数据的自组织神经网络降维分类研究 [J]. 武汉大学学报(信息科学版), 2004, 29(5): 461—465.]
- [7] Zhang Y S, Feng X Z, Ruan R Z, et al. Application of Kohonen Network in RS Image Classification [J]. *Journal of Remote Sensing*, 2004, 8(2): 178—184. [张友水, 冯学智, 阮仁宗等. Kohonen 神经网络在遥感影像分类中的应用研究 [J]. 遥感学报, 2004, 8(2): 178—184.]
- [8] Ji C Y. Crop Classification Method Using a Self-organizing Neural Network [R]. Interim Report on Crop Classification Using Neural Networks, 1999.
- [9] Matsumoto M, Terayama Y, Araki K. Image Classification Based on Category Proportion Estimation [J]. *Journal of Remote Sensing Society of Japan*, 1993, 13(2): 23—32.
- [10] Zhu S L. The Classification of Remotely-sensed Images with Mixels [J]. *Journal of Institute of Surveying and Mapping*, 1995, 12(4): 276—278. [朱述龙. 基于混合像元的遥感图像分类技术 [J]. 解放军测绘学院学报, 1995, 12(4): 276—278.]
- [11] Teuvo Kohonen. The Self-organizing Map [A]. Proceedings of the IEEE [C], 1990, 78(9): 1464—1481.
- [12] Simon Haykin. Neural Network [M]. [Simon Haykin 著. 叶世伟, 史忠植译. 神经网络原理 [M]. 北京: 机械工业出版社, 2004.]
- [13] Liu Z K, Cen S W. Spectral Mixture Analysis of Imaging Spectrometer Data [J]. *Remote Sensing of Environment (China)*, 1996, 11(1): 32—37. [刘政凯, 岑曙炜. 成像光谱遥感图像的有限光谱混合分析 [J]. 环境遥感, 1996, 11(1): 32—37.]
- [14] Green A A, Berman M, Switzer P, et al. A Transformation for Ordering Multispectral Data in Terms of Image Quality with Implications for Noise Removal [J]. *IEEE Trans. Geoscience and Remote Sensing*, 1988, 26: 65—74.
- [15] Tu T M, Huang P S, Chen P Y. Blind Separation of Spectral Signatures in Hyperspectral Imagery [A]. IEE Proc. -Vis. Image Signal Processing [C], 2001, 148(4): 217—225.