

文章编号: 1007-4619(2007)01-0020-07

一种端元变化的神经网络混合像元分解方法

吴 柯, 张良培, 李平湘

(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: 遥感图像中普遍存在着混合像元, 对混合像元进行分解是遥感图像处理中的难点, 在端元 (Endmember) 个数不变的情况下, 往往得到的分解结果精度不高。本文基于 fuzzy ARTMAP 神经网络, 提出一种基于端元变化的神经网络混合像元分解模型。首先利用混合像元与纯净端元之间的光谱相似性, 判断出混合像元包含的端元个数及类别, 然后结合 fuzzy ARTMAP 神经网络进行分解。实验结果表明: 本文提出的方法比传统的线性混合模型及 fuzzy ARTMAP 神经网络模型的精度要高, 而且更加符合实际情况。

关键词: 混合像元; 端元变化; 线性模型; 神经网络; Fuzzy ARTMAP; 影像分类

中图分类号: TP751.1 **文献标识码:** A

A Neural Network Method of Selective Endmember for Pixel Unmixing

WU Ke ZHANG Liangpei LI Pingxiang

(State Key Laboratory for Information Engineering in Surveying, Mapping and Remote Sensing, Hubei Wuhan University, Hubei Wuhan 430079, China)

Abstract Remote sensing images contain a lot of mixed image pixels but it is difficult to classify these pixels. If the number of pixel's endmember is regarded as unchangeable, the traditional pixel unmixing algorithm cannot get a good result. In this paper we develop a new method of selective endmembers for pixel unmixing based on the fuzzy ARTMAP neural network, which firstly compares the pixel's spectral to the conference one and then gets the number of endmember. When it is taken into account, we use an ARTMAP neural network to extract subpixel information. Finally, the experimental results show that the selective endmember algorithm has been improved over conventional ANN algorithms and conventional linear algorithms.

Key words mixed pixel; selective endmember; linear algorithm; ANN; Fuzzy ARTMAP; image classification

1 引 言

由于地球卫星的空间分辨率及地表的复杂多样性, 在一幅遥感图像中有许多像元都包含有若干表面覆盖类 (标准地物)^[1], 这类像元称为混合像元。对这类像元的分类, 即混合像元分解问题, 是遥感图像分类中的一个难点。目前处理混合像元分解的方法有: 线性波谱分离法^[2], 混合像元组分信息盲分解方

法^[3], 端元自动提取迭代分解法^[4], 基于小波特征的投影分解法^[5], 高斯混合识别分析^[6]及回归与决策树模型^[7]等, 以上这些方法在分解过程中, 端元个数始终固定, 得到的分解结果会存在较大误差。

Fuzzy ARTMAP 是一种自组织产生认知编码的神经网络理论, 它通过自组织反馈功能, 实现增量式学习, 使系统能够迅速地兼顾适应性和稳定性, 从而克服了传统 BP 神经网络算法简单、不易收敛以及自适应、自归一能力有限的缺点。近年来, Fuzzy

收稿日期: 2005-12-06; 修订日期: 2006-04-20

基金项目: 国家自然科学基金项目 (编号: 40471088, 40523005)、国家 973 项目 (编号: 2006CB701302) 和地理空间信息工程国家测绘局重点实验室课题资助。

作者简介: 吴 柯 (1981—), 男, 武汉大学测绘遥感信息工程国家重点实验室博士研究生。研究方向为神经网络、遥感图像处理等。
E-mail: tingke2000@126.com.

©1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

ARTMAP神经网络已经得到了广泛的应用^[8],但是在遥感影像的混合像元分解中,应用得比较少。

传统的混合像元分解,采用所有端元进行分解,实际上,大多数影像区域或混合像元只是由全部影像端元中的几种所组成。因此,如果在混合像元分解过程中,只由相关的影像端元进行分解,则会相应的提高分类的精度。本文在 Fuzzy ARTMAP神经网络模型的基础上,提出一种端元变化的混合像元分解模型,动态的调整相关端元进行混合像元分解,希望能够提高分解精度,降低误差。

2 Fuzzy ARTMAP神经网络分解模型

Fuzzy ARTMAP的基本结构如图 1所示,它可以分为 ART_a和 ART_b两个模块,每个模块分别由输入层 F₀、比较层 F₁以及识别层 F₂三层组成。ART_a和 ART_b两者通过一个映射域 F^{ab}连接起来,实现输入模式 a和输入模式 b的映射关系。F^{ab}的神经网络数目与 ART_b的竞争层(F₂^b)中的神经元数目一致,因为 F^{ab}与 F₂^b是一对一的对应关系;ART_a的竞争层(F₂^a)和 F^{ab}之间采用互连结构连接,连接的权值设为 Z。那么 F^{ab}神经元状态值: X^{ab} = Y^b ∧ Z。模块 ART_a通过学习 F₀^a层的输入样本向量集 A而获得 F₂^a层的原型类别向量;ART_b通过学习 F₀^b层的目标类别向量集 b而获得 F₂^b层的原型类别向量。F₂^a、F₂^b与 F^{ab}之间通过关联连接权 w_{ij}和 w_{jk}连接起来,其强度值随学习过程而调整。中间映射层 F^{ab}通过匹配

规则检验 a和 b的匹配度,当满足匹配条件,修改权值 Z并反向训练 ART_a,否则增加 ART_a的警戒系数 ρ_a,以增加 F₂^a的神经元,知道满足中间映射域匹配规则。Fuzzy ARTMAP映射机制通过自动调节 ρ_a,从而调节 F₂^a神经元,使得 F₂^a与 F₂^b之间通过 F^{ab}取得映射关系。正是由于 ARTMAP模型本身具有高度映射和自组织的能力,并且兼顾了可塑性和稳定性的特点,因此,对于包含复杂地学属性的遥感影像分类或信息提取问题的应用研究,ARTMAP方法更能发挥其优势^[9,10],利用该模型来对遥感影像进行混合像元分解,处理一些高度复杂,不规则的映射关系,无疑是一个非常实用的方法。其基本的算法步骤^[11]为:(1)网络初始化:对应于分解的样本影像,在两个模块 ART_a和 ART_b的输入层中,分别输入波段数和纯净地物类型个数。(2)输入样本对,开始训练:对于两个 ART模块均采用相似的训练方式,判定函数为 $T_j(x) = \frac{|x \wedge w_j|}{\alpha + |w_j|}$ (此处 α > 0 为选择参数,是自己定义, w_j是对应的权值向量, x是输入的向量),利用此函数选择竞争获胜的节点,从而对应获胜节点的层被激发,完成一次的训练。(3)获胜并发生谐振的节点所对应的权值矢量学习更新,在满足警戒阈值 ρ_a的条件下,达到期望的精度。(4)测试:通过输入到 ART_a的向量,即每个波段的值,利用映射函数在 ART_b中得到输出,输出的 4个不同分量的值,相加的和等于 1,代表混合像元中不同成分的组分量。

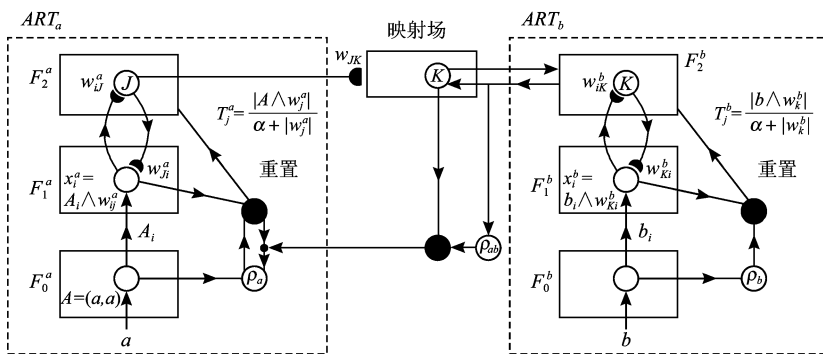


图 1 ARTMAP结构图

Fig 1 The architecture of ARTMAP

3 端元变化的分解模型

的,对每个像元采用统一的标准,即选取纯净端元的个数 N是固定不变的。但实际上,不同的混合像元包含端元的个数及类别是变化的。因此,为了取得更好的分解效果,对每个像元采用不同的取值 N,根

据 N 的不同, 动态的调整神经网络的输出层个数, 显然, 如何确定 N 值的大小是关键。

考虑交叉相关光谱匹配^[12]技术, 计算像元光谱和参考光谱(端元)之间的响应值, 来判断两光谱之间的相似程度, 从而保证与参考光谱相似程度最高的组分入选。响应系数等于两光谱之间的协方差除以它们各自方差的积:

$$r = \frac{\sum (R_r - \bar{R}_r)(R_i - \bar{R}_i)}{\sqrt{\left[\sum (R_r - \bar{R}_r)^2 \right] \left[\sum (R_i - \bar{R}_i)^2 \right]}}$$

式中, R_r , R_i 分别为参考光谱和像元光谱。由协方差的性质可知, 上式等同于

$$r = \frac{n \sum R_r R_i - \sum R_r \sum R_i}{\sqrt{\left[n \sum R_r^2 - \left(\sum R_r \right)^2 \right] \cdot \left[n \sum R_i^2 - \left(\sum R_i \right)^2 \right]}} \quad (1)$$

式中, n 为两光谱对应波段数。

像元光谱和参考光谱(端元)之间的响应值, 相当于是前者对后者的投影, 由公式(1)计算所有像元的光谱在参考光谱上的投影值, 通过比较得到最大投影值 r_{max} 和相应的端元光谱矢量 A_{max} , 那么 A_{max} 作为与该像元相似性最高的端元光谱, 可为该像元的首选端元。如果把 r_{max} 看作是端元 A_{max} 对混合像元 ρ 的贡献, 那么剩余端元对 ρ 的贡献可表示为:

$$\rho_r = \rho - r_{max} A_{max} \quad (2)$$

将公式(1)中的 R_r 用 ρ_r 来代替, 继续比较像元中的剩余端元, 找出最大的投影值及端元光谱矢量, 依次对式(1)和(2)进行迭代。这个过程实际上是将端元对像元响应的贡献率进行排序, 找出像元中包含的不同的端元成分, 迭代满足一定条件中止, 即: ρ_r 的某分量是负值; 或者是 $\Delta \rho$ 变化很小。

$$\Delta \rho = \rho_r^{(k+1)} - \rho_r^{(k)} \quad (3)$$

式中, $\rho_r^{(k+1)}$ 和 $\rho_r^{(k)}$ 分别是第 $k+1$ 和 k 次迭代后的像元反应值。

实验表明, 某些混合像元即使只经过一次迭代, ρ_r 就满足中止条件。这是由于选取的端元光谱矢量之间是非正交的。因此, 将式(2)调整为(4):

$$\rho_r = \rho - \eta r_{max} A_{max} \quad (4)$$

这里的 η 作为一个调整系数, 取值为 $(0, 1)$ 。它在一定程度上影响着端元个数 N , η 取得过大, 像元只经过少数迭代就满足中止条件, 这显然不符合要求; η 取得过小, 端元个数保持不变, 光谱响应值的计算无意义。经过多次实验, $\eta=0.65$ 时, 可以较好的满足实际情况。

结合第 2 节中 ARTMAP 神经网络分解模型, 这里给出本文方法的具体流程: 首先在遥感影像中选取 N 个不同的纯净端元, 以其光谱值作为参考光谱, 用公式(1)计算图像中每一个像元对于不同参考光谱的响应值 r 并对不同的 r 值进行排序, 排序的过程实际上就是利用公式(1)和(2)进行迭代的过程, 当满足一定的迭代条件后, 选择合适的调整系数 η , 通过公式(4)获得该像元所包含的端元个数; 然后利用不同 fuzzy ARTMAP 神经网络模型对影像中不同端元的像元进行处理, 网络输出端的个数等于对应像元的端元数目, 最后把处理完的结果进行合并, 输出分解的组成成分影像。

4 实 验

4.1 实验影像

选取长江三峡地区的 ETM 影像作为实验数据, 该影像有 6 个波段, 获取时间为 2002 年 4 月, 采用 1, 2, 3 波段真彩色合成, 如图 2 所示。影像中的端元数目可以从影像 MNF 变化后的特征值分布转折点的情况大致确定^[13]。在 ENVI 平台下对原始数据进行 MNF 处理, 得到特征值如图 3。可见大致有 4 个独立成分, 经过实地调查, 分别为: 长江、居民地、植被和湖泊。这里, 由于湖泊水质与长江差别较大, 故单独作为一类。



图 2 原始影像

Fig 2 Original image

4.2 实验过程及分析

通过目视判读, 在原始影像上依次选取长江, 居民地, 植被和湖泊 4 类纯净的端元, 并获取它们的光谱值。利用线性模型进行混合像元分解的结果如图 4 所示。

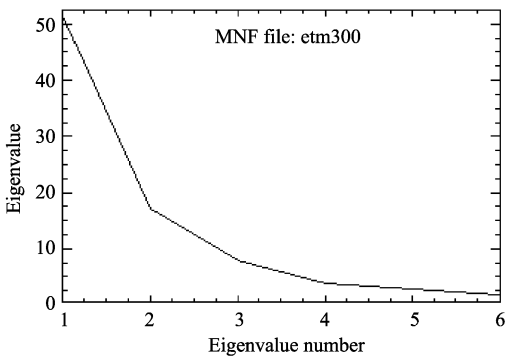


图 3 MNF变化后的特征值

Fig 3 The eigenvalue after MNF transform

直接利用 fuzzy ARTMAP进行混合像元分解,令 fuzzy ARTMAP网络模型的选择参数 $\alpha = 10^{-6}$, ART_a 的初始域值 $\rho_a = 0$, ART_b 警戒参数 $\rho_b = 0.8$, 匹配参数 $\epsilon = 0.01$ 。网络的训练采用模拟数据进行,即:利用随机产生的一组 0 到 1 之间的随机量,作为组成

分比,依次与所提取的 4 类纯净端元光谱值相乘之后求和,以得到的光谱矢量作为网络的输入,以随机产生值作为输出。当训练达到一定次数,权值收敛后,训练完毕。然后对整幅影像进行处理,分解结果如图 5 所示。

在本文方法中,首先利用交叉光谱匹配技术,获得原始影像中各像元所包含的地物类别个数,保持 fuzzy ARTMAP网络模型的参数不变,分成以下 4 种情况来考虑:(1)端元个数 $N=1$ 时,当然这样的像元属于少数,直接将其对应的组成成分赋值为 1,其余的赋值为 0。(2)端元个数 $N=2$ 时,同样是利用模拟数据来训练网络,但网络的输出端变成 2 个,且对应不同的类别,有 6 种不同的组成方式来进行训练和测试。(3)端元个数 $N=3$ 时,网络输出端变为 3,对应不同的类别,有 4 种组成的方式来进行训练和测试。(4)端元个数 $N=4$ 时,表示端元数目是饱和的,网络模型的算法和原始算法一致。最终分解结果如图 6 所示。




图 4 线性分解

(a) 长江; (b) 居民地; (c) 植被; (d) 湖泊

Fig 4 The results of linear unmixing

(a) Changjiang river; (b) Urban land; (c) Vegetation; (d) lake




图 5 Fuzzy ARTMAP分解结果

(a) 长江; (b) 居民地; (c) 植被; (d) 湖泊

Fig 5 The unmixing results of Fuzzy ARTMAP

(a) Changjiang river; (b) Urban land; (c) Vegetation; (d) lake

图 4、5 和 6 中的 (a)、(b)、(c)、(d) 分别为长江、居民地、植被、湖泊的组成成分影像, 在组成成分图像中, 越亮的部分代表该地物所占的组分比例高, 反之代表所占的组分比例低。为了方便比较, 所选取的纯净端元是一致的。从目视效果比较上来看, 线性混合模型的分解结果不如后两种方法的分解结果, 例如从图 4(b) 和图 5(b) 中对“居民地”分解的组成成分影像的比较可以看出, 基于线性模型的分解结果, 根本就没有把居民地和植被两个不同的端元成分区分出来, 对植被覆盖较多的地区分解出来的结果却与居民地的相似, 这显然不符合实际情况, 而基于 ARTMAP 神经网络方法得出的结果是, 大片植被地区包含居民地的组分比较少, 区分明显, 较好地反映了实际情况。作者认为这里有两方面的原因, 一是, 选择纯净端元存在误差, 由于是人为地选择纯净端元, 线性混合模型过于简单, 对初始条件的要求比较

高, 当纯净端元选择不太准确的时候, 误差也比较大, 而神经网络模型有自适应、自调节的特点, 并且是一个迭代的过程, 因此, 利用神经网络分解的结果要好些; 二是, 事实上在遥感影像中, 各种地物的反射率一般是通过非线性形式加以组合的, 因此利用线性模型去解决非线性的问题, 分解结果会存在着比较大的误差, 而文献 [14] 中认为: 如果参考端元相同, 神经网络模型的分解结果会好于线性混合的分解结果, 这一点在图中也得到了证实。在加入了端元可变的的信息后, 对于图像中的每一个像元都剔除了相似性最小的端元类别, 得到的端元组成更加准确, 在混合像元越多的区域, 分解的效果越好。例如对图 5(d) 和图 6(d) 中“湖泊”分解的组成成分影像进行比较, 图 5(d) 中显示的亮度高的地区表示所占湖泊的组分比高, 但是实际上有些地区并不是湖泊, 而是由植被、土壤等其他类别组成的, 因此在这




图 6 本文方法分解结果

(a) 长江; (b) 居民地; (c) 植被; (d) 湖泊

Fig 6 The unm ixing results of this method

(a) Changjiang river; (b) Urban land; (c) Vegetation; (d) lake

种混合情况比较复杂的区域,直接利用神经网络的方法来分解的误差是比较明显的,从图 6(d)中得到的结果可看出,利用端元可变的神经网络方法来分解效果要比图 5(d)好。

对于 4 幅组成成分影像上近似认为是纯净端元的区域,比如长江,三种方法的分解结果在区域和数值上基本相同。但对于是混合像元的区域,图 6 的结果明显要好于图 4 和图 5 的结果。在利用端元变化的方法得到的结果中,影像上不含有该类端元的区域值为 0,而利用线性分解模型和直接利用神经网络得到的区域值均不为 0。作者在图 6(a)的高亮区(长江)随机选择了 400 个点,统计所得各类平均组成分值见表 1。

这是由于传统线性模型及神经网络模型对混合像元进行无区别分解,所以每类端元对混合像元都表现出一定的贡献。而可变端元的分解方法结合了

表 1 分解结果

Table 1 The results of unm ixing

	长江	居民地	植被	湖泊
线性模型	0.82178	0.03130	0.03315	0.11377
Fuzzy ARTMAP	0.83568	0.03977	0.01213	0.11242
本方法	0.90370	0	0	0.09630

光谱信息和空间信息,动态地调整端元个数,在分解过程中去除了不相关的端元,因而取得了更好的结果。从目视解译和实地调查看,端元可变的混合像元分解方法更符合实际情况。

在整幅影像上取 RMSE 对三种方法做定量比较,结果见表 2。结果表明:利用本文提出来的方法比传统线性方法和 fuzzy ARTMAP 神经网络模型的分解方法得出来的结果要好,获得的 4 种端元类别

表 2 误差比较
Table 2 The comparison of RM SE

	长江	居民地	植被	湖泊
线性模型	0.0811	0.3150	0.2845	0.1249
Fuzzy ARTMAP	0.0653	0.1258	0.2476	0.1013
本方法	0.0610	0.0986	0.1013	0.1002

的均方误差都是最小的,有效的证明了方法的适用性。

5 结 论

本文提出了一种端元变化的神经网络混合像元分解方法,实验证明,利用光谱匹配技术,将端元可变性与 Fuzzy ARTMAP神经网络结合起来对遥感影像进行分解,能够提高混合像元的分解精度,特别是对于一些混合情况比较复杂的区域,效果显著。而且 Fuzzy ARTMAP神经网络本身也具有结构简单,计算量小以及适应性强的特点,和传统的线性模型方法相比,在遥感影像的处理上具有更大的优越性。

参 考 文 献 (References)

- [1] Zhu S L, Zhang Z. Acquisition and Analysis of Remote Sensing [M]. Beijing: Science Press, 2000. [朱述龙,张占. 遥感图像获取与分析[M]. 北京: 科学出版社, 2000.]
- [2] Ichoku Charles, Kamali Amon. A Review of Mixture Modeling Techniques for Sub Pixel Land Cover Estimation [J]. Remote Sensing Review, 1996, **13**: 161-186.
- [3] Fan W J, Xu X R. Pixel Unmixing Based on Blind Signals Separation [J]. Progress in Natural Science, 2005, **15**(8): 993-999. [范闻捷,徐希孺. 混合像元组分信息的盲分解方法[J]. 自然科学进展, 2005, **15**(8): 993-999.]
- [4] Wu B, Zhang L P, Li P X. Automatic Extraction of Endmember from Hyperspectral Imagery by Iterative Unmixing [J]. Journal of Remote Sensing, 2005, **9**(3): 286-293. [吴波,张良培,李平湘. 高光谱端元自动提取的迭代分解方法[J]. 遥感学报, 2005, **9**(3): 286-293.]
- [5] Wu B, Zhang L P, Li P X. Projective Iterative Unmixing of Hyperspectral Image Based on Spectral Domain Wavelet Feature [J]. Acta Electronica Sinica, 2005, **33**(11): 13-16. [吴波,张良培,李平湘. 基于光谱维小波特征的高光谱混合像元投影迭代分解[J]. 电子学报, 2005, **33**(11): 13-16.]
- [6] Ju J, Kolaczky E D, Gopal S. Gaussian Mixture Discriminant Analysis and Sub-pixel Land Cover Characterization in Remote Sensing [J]. Remote Sensing of Environment, 2003, **84**: 550-560.
- [7] DeFries R, Townshend J, Hansen M. Continuous Fields of Vegetation Characteristics at the Global Scale at 1-km Resolution [J]. Journal of Geophysical Research, 1999, **104**: 16911-16923.
- [8] Gallant S I. Network Learning and Expert Systems [M]. New York: The MIT Press, 1992.
- [9] Carpenter G A, Gajam N, Gopals et al. ART Neural Networks for Remote Sensing Vegetation Classification from Landsat TM and Terrain Data [J]. IEEE Transactions on Geoscience and Remote Sensing, 1997, **35**(2): 308-325.
- [10] Gopal S, Fischer M M. Fuzzy ARTMAP: A Neural Classifier for Multi-spectral Image Classification [A]. Recent Developments in Spatial Analysis [C]. Berlin: Springer-Verlag, 1997.
- [11] Carpenter G, Gopal S, Macomber S et al. A Neural Network Method for Mixture Estimation for Vegetation Mapping [J]. Remote Sensing of Environment, 1999, **70**: 138-152.
- [12] Plaza A, Martinez P, Perez R. A Quantitative and Comparative Analysis of Endmember Extraction Algorithms From Hyperspectral Data [J]. IEEE Trans Geoscience and Remote Sensing, 2004, **42**(3): 650-663.
- [13] Tu T M, Huang P S, Chen P Y. Blind Separation of Spectral Signatures in Hyperspectral Imagery [J]. IEEE Proc Vis Image Signal Process, 2001, **148**(4): 217-225.
- [14] Liu W, Gopal S, Woodcock C. ARTMAP Multisensor/Resolution Framework for Land Cover Characterization [A]. The 4th International Conference on Information Fusion, Montreal, Canada [C], 7-10 August, 2001, WC2-11-WC2-16.