

FUZZY-ARTMAP 混合像元分解及其应用

潘建平

PAN Jian-ping

重庆交通大学 土木建筑学院,重庆 400074

School of Civil Engineering & Architecture, Chongqing Jiaotong University, Chongqing 400074, China

E-mail:pjp2222@sina.com

PAN Jian-ping.Pixel unmixing and its application based on FUZZY-ARTMAP. Computer Engineering and Applications, 2010,46(1):180–182.

Abstract: Subpixel is a difficulty for the development of quantitative remote sensing. The paper decomposes subpixel with fuzzy-
artmap for the ETM+ image, and gets vegetation fraction for every pixel. The test shows that result is satisfactory for application.

Key words: pixel unmixing; neural network; vegetation fraction; FUZZY-ARTMAP

摘要:对于定量遥感来说,混合像元是制约它深入发展的难点之一。针对中高分辨率图像 ETM+,采用 FUZZY ARTMAP 神经网络进行混合像元分解,获得像元中不同地物的含量,进而获得像元的植被覆盖度。该方法在某地区 ETM+图像的应用表明,试验结果能满足应用需求。

关键词:混合像元分解;神经网络;植被覆盖度;模糊 ARTMAP 神经网络

DOI:10.3778/j.issn.1002-8331.2010.01.053 **文章编号:**1002-8331(2010)01-0180-03 **文献标识码:**A **中图分类号:**TP391

单一像元中包含若干种地物基元,这就是混合像元。对于定量遥感来说,混合像元是制约它深入发展的难点之一。比如,在遥感分类中,无论把混合像元划分为哪一类,都是欠妥的,因为它不完全属于哪一类。鉴于这个原因,一些学者提出了混合像元分解方法,它认为混合像元是若干种地物的组合,利用适当的数学方法,将混合像元进行分解,获得像元中每种地物的含量或面积,进而为下一步的图像处理服务^[1-5]。

自适应共振理论是 S.Grossberg 于 1976 年通过发展认知信息处理理论建立起来的,并由此建立了一系列以 ART 认知理论为基础的分类学习和模式识别的应用模型。ART 神经网络属于自组织神经网络,在竞争学习过程中进行期望匹配。在遥感图像处理中,ART 神经网络在学习速度,适应性和非线性映射等性能上比传统统计分类方法和 BP 神经网络更有优势^[6]。

文章针对遥感图像中的混合像元,采用 FUZZY ARTMAP 神经网络,获得像元中不同地物的含量,进而获得像元的植被覆盖度。该方法在某地区 ETM+图像的应用表明,研究结果较好。

1 混合像元分解

混合像元分解是对像元中类型和含量进行分解计算,即算出混合像元内各个地物类型所占的面积比。从混合像元分解的物理机理出发,可以将混合像元分解模型分为三种:几何光学模型,非线性模型和线性模型。如最简单的线形模型原理是这

样的。

每一光谱波段中单一像元的反射率表示为它的组分特征反射率与它们各自含量的线性组合。于是,第 i 波段像元反射率 r_i 可以这样表达:

$$r_i = \sum_{j=1}^n (a_{ij}x_j) + e_i$$

其中, $i=1, 2, \dots, m, j=1, 2, \dots, n, a_{ij}$ 表示第 i 个波段第 j 个组分的反射率, x_j 是该像元第 j 个组分的含量。 e_i 是第 i 个波段的误差, m 表示波段数, n 表示选定的组分数。

对于该模型,有两个限制条件:(1) x_j 不能为负数或者大于 1。因为组分含量是正数,而且不可能超过 100%;(2)一个像元内,组分和为 1,即所有 x_j 的和为 1。

2 FUZZY-ARTMAP 原理

ARTMAP 由两个 ART1(分别为 ARTa 和 ARTb)加上一个映射域组成。映射域将两个 ART1 连接起来,对任意序列的输入都可以进行实时监督学习。其结构图 1 所示。FUZZY ARTMAP 是在 ARTMAP 中引入模糊理论,利用模糊理论中的 MIN 算子(\wedge 或称之为最小算子)取代 ART1 中的交算子(\cap),从而使 FUZZY ARTMAP 不仅能像 ART1 一样处理二值输入向量,还能稳定地学习连续输入向量。

FUZZY ARTMAP 的工作流程如下:(1)训练阶段。ARTa

基金项目:国家自然科学基金(the National Natural Science Foundation of China under Grant No.40701111);重庆市科学技术委员会自然科学基金项目(No.2006BB2411)。

作者简介:潘建平(1976-),男,博士,副教授,主要从事遥感图像处理、地理信息系统和地质灾害研究。

收稿日期:2009-01-08 **修回日期:**2009-03-17

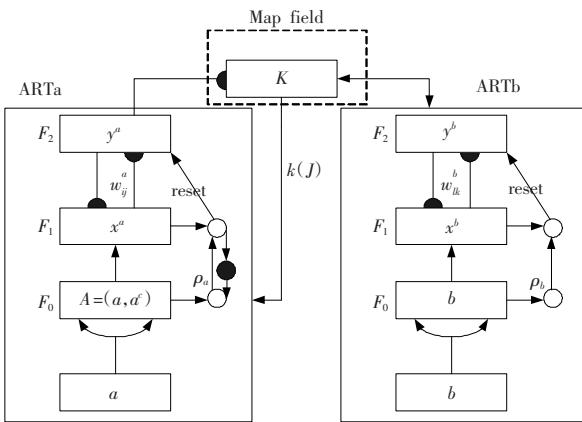


图 1 FUZZY ARTMAP 结构图

接收训练模式($a^{(p)}, b^{(p)}$)中的输入模式 $a^{(p)}$,而 ARTb 接收训练模式中的期望输出模式 $b^{(p)}$ 。(2)测试阶段。在进行判别时,由 ARTa 接收输入模式,从 ARTb 得到学习结果。映射域(Mapfield)的作用是:由它来控制 ARTa 分类与 ARTb 分类之间联想映射的学习。它控制 ARTa 的警戒参数,直到可以驱动系统去寻找更好的 ARTa 分类,或建立一个新的 ARTa 分类为止,这种控制过程出现在训练阶段。

3 基于 FUZZY ARTMAP 的混合像元分解原理设计与分析

FUZZY ARTMAP 混合像元分解是一种有监督学习的识别算法,该算法较为复杂,其变量和参数如表 1 所示。

表 1 FUZZY ARTMAP 参数表

参数	范围	本次实验值
ART _a 输入分量个数	M_a	6
ART _b 输入分量个数	M_b	5
选择参数	α (0, ∞)	10^{-6}
ART _a 基线警戒参数	$\bar{\rho}_a$ [0, 1]	0
ART _b 警戒参数	ρ_b [0, 1]	0.8
匹配追踪	ε ε 小	0.01
ART _a 编码节点个数	C_a	不断增加
ART _b 编码节点个数	C_b	不断增加
非约束节点信号	$T^{a,u}$	0.5
非约束节点信号	$T^{b,u}$	0.2
F_2^a 层激活节点的索引	J	$J=1, 2, \dots, C_a$
F_2^b 层激活节点的索引	K	$K=1, 2, \dots, C_b$
ART _a 警戒参数	ρ_a	
输入类 k 和编码节点 j 之间的联想	$K(j)=k$	$k=1, 2, \dots, C_b$

它包括训练和测试两个阶段,具体过程如下。

(1) FUZZY ARTMAP 的训练

在训练时,输入样本对($a^{(1)}, b^{(1)}$),($a^{(2)}, b^{(2)}$), \dots ,($a^{(n)}, b^{(n)}$)依次送入系统,每个 ARTa 输入用补码形式编码, $0 \leq a_i \leq 1$ 。 $a_i^c \equiv 1 - a_i$ 。 $I = A = (a, a^c)$,所以 $|A| = A$ 。相对于类的概率分布,输出 b 归一化为 1 ($\sum_{k=1}^L b_k = 1$)。初始时,所有的 LTM 变量赋值为 1,就是说 $w_{ij}^a = 1, w_{ik}^b = 1$ 。

步骤 1 开始训练: $n=1$ 。

$$\text{输入 } A_i = \begin{cases} a_i^{(1)} & 1 \leq i \leq M_a \\ 1 - a_i^{(1)} & M_a \leq i \leq 2M_a \end{cases}$$

输出 $b_l = b_l^{(1)} (l=1, 2, \dots, M_a)$ 。设 $C_a=1, C_b=1, J=1, K=1, k(1)=1$, 转到步骤 7。

步骤 2 计算 $F_1^a \leftrightarrow F_2^b$ 信号。

对于 $k=1, 2, \dots, C_b$:

$$T_k^b = \frac{\sum_{l=1}^{M_a} b_l \wedge w_{lk}^b}{\alpha + \sum_{l=1}^{M_a} w_{lk}^b}$$

步骤 3 ART_b 中选择类别 K :

① 约束节点: F_2^b 层节点中, 如果存在 $T_k^b \geq T^{b,u}, k=1, 2, \dots, C_b$, 让 K 成为 F_2^b 节点中最大输入值的最小序号, 即: $T_K^b = \max(T_1^b, T_2^b, \dots, T_{C_b}^b)$ 。 F_1^a 激励: $x_l^b = b_l \wedge w_{lk}^b (l=1, 2, \dots, M_b)$ 。

如果 $\sum_{l=1}^{M_b} x_l^b < \rho_b, T_K^b = 0$, 并转到步骤 3; 否则转到步骤 4。

② 非约束节点: 如果所有 F_2^b 层节点中都满足 $T_k^b < T^{b,u}, k=1, 2, \dots, C_b$, 则 $K=C_b+1$ 。节点 K 为新约束节点: $C_b=C_b+1$ 。转到步骤 4。

步骤 4 计算 $F_1^a \rightarrow F_2^a$ 信号。

对于 $j=1, 2, \dots, C_a$:

$$T_j^a = \frac{\sum_{i=1}^{2M_a} A_i \wedge w_{ij}^a}{\alpha + \sum_{i=1}^{2M_a} w_{ij}^a}$$

步骤 5 ART_a 中选择类别 J :

① 约束节点: F_2^a 层节点中, 如果存在 $T_j^a \geq T^{a,u}, j=1, 2, \dots, C_a$, 让 J 成为 F_2^a 节点中最大输入值的最小序号, 即: $T_J^a = \max(T_1^a, T_2^a, \dots, T_{C_a}^a)$, F_1^a 激励: $x_i^a \wedge w_{ij}^a (i=1, 2, \dots, 2M_a)$ 。

如果 $\sum_{i=1}^{2M_a} x_i^a < \rho_a M_a, T_J^a = 0$, 并转到步骤 5; 否则转到步骤 6。

② 非约束节点: 如果所有 F_2^a 层节点中都满足 $T_j^a < T^{a,u}, j=1, 2, \dots, C_a$, 则 $J=C_a+1$ 。

节点 J 为新约束节点: $C_b=C_b+1, k(J)=K$ 。

步骤 6 匹配追踪:

如果 $k(J)=K$, 则转到步骤 7;

如果 $k(J) \neq K$: (1) $\rho_a = \frac{1}{M_a} \left[\sum_{i=1}^{2M_a} x_i^a \right] - \varepsilon$; (2) $T_J^a = 0$; (3) 转到步骤 5。

步骤 7 谐振: 对于 $i=1, 2, \dots, 2M_a, l=1, 2, \dots, M_b$:

设旧权值 $w_{ij}^{(old)} = w_{ij}^a, w_{ik}^{(old)} = w_{ik}^b$

提高 $F_1^a \leftrightarrow F_2^a$ 权值 $w_{ij}^a = A_i \wedge w_{ij}^{(old)}$

提高 $F_1^b \leftrightarrow F_2^b$ 权值 $w_{ik}^b = b_l \wedge w_{ik}^{(old)}$

恢复 ART_a 的警戒参数 $\rho_a = \bar{\rho}_a$

步骤 8 下一个输入, $n=n+1$

$$\text{输入 } A_i = \begin{cases} a_i^{(n)} & 1 \leq i \leq M_a \\ 1 - a_i^{(n)} & M_a \leq i \leq 2M_a \end{cases}$$

输出 $b_l = b_l^{(n)}$ ($l=1, 2, \dots, M_a$)，转到步骤 2。

(2) FUZZY ARTMAP 的测试

在 FUZZY ARTMAP 测试时，ART_a 的输入 $a^{(1)}, a^{(2)}, \dots$ 呈现给训练好的系统，结果为像元组分含量。初始时 $n=0$ 。

测试步骤 1 新输入。 $n=n+1$ ；新输入 $-A_i = \begin{cases} a_i^{(n)} & 1 \leq i \leq M_a \\ 1-a_i^{(n)} & M_a \leq i \leq 2M_a \end{cases}$

测试步骤 2 计算 $F_1^a \rightarrow F_2^a$ 信号：

对于 $j=1, 2, \dots, C_a$ ：

$$T_j^a = \frac{\sum_{i=1}^{2M_a} A_i \wedge w_{ij}^a}{\alpha + \sum_{i=1}^{2M_a} w_{ij}^a}$$

测试步骤 3 ART_a 中选择类别 J 。让 J 成为 F_2^a 节点中最大输入值的最小序号，即 $T_j^a = \max\{T_1^a, T_2^a, \dots, T_{C_a}^a\}$ ；如果 $T_j^a < T^{a,u}$ ，转到测试步骤 1。

测试步骤 4 预测 ART_b 的类别 K 。 $K=k(J)$ 。

测试步骤 5 在 ART_b 中，产生归一化输出 x_b 。对于 $l=1, 2, \dots, M_b$ ：

$$x_l^b = \frac{w_{lK}^b}{\sum_{\lambda=1}^{M_b} w_{\lambda K}^b}$$

对于该文的试验，归一化输出向量 x_b 表示某一像元中不同组分的百分含量。

4 混合像元分解应用

试验采用的数据与第 3 章相同，处理图像为某地区的 ETM+ 图像，图像获取时间为 2000 年 1 月 2 日，图像大小为 503×463 ，其轨道号/景号为 122/44。验证图像为某地区相应的 IKONOS 图像，图像获取时间为 2001 年 12 月 20 日。

(1) 纯像元选择

在神经网络的学习阶段，需要利用地物的纯像元，训练网络中的权值。由于 ETM+ 图像分辨率较小，从中选择纯像元需要参照 IKONOS 图像。纯像元的选择按照以下方法进行：根据图像中地形和光谱信息，选择各个类别地物纯样本集合，再对这些集合进行纯化处理，得到地物的纯样本值。例如水体的纯样本应该选择水体中心局部区域，取出该区域像素的各个波段数据，选择光谱值相同的最多像素作为水体的纯样本值。

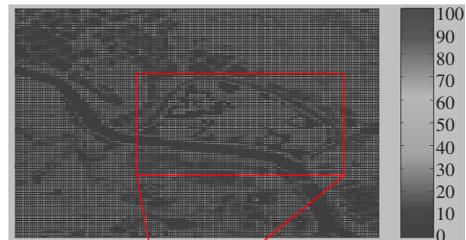
(2) 参数赋值

FUZZY ARTMAP 中的主要参数如表 1 所示。试验选择 ETM+ 遥感图像中空间分辨率为 30 米的 6 个波段，根据对图像目视分析，设置的像元组分有 5 个，分别为：林地，草地，居民地，水体和裸地，因此 $M_a=6, M_b=5$ 。 $F_1^a \rightarrow F_2^a$ 和 $F_1^b \rightarrow F_2^b$ 的非约束节点信号的赋值根据公式 $T^{a,u} = M_a / (\alpha + 2M_a), T^{b,u} = M_b / (\alpha + M_b)$ 计算。 α 根据经验，赋值为 10^{-6} 。 $\rho_a=0$ ，可获得最大的代码压缩量。 ε 根据经验，赋值为 0.01。 ρ_b 对计算效率和结果精度影响较大， ρ_b 越大，精度越大，计算效率降低，本次试验折中考虑，取值为 0.8 时效果较好。

(3) 试验结果

为了更好地表达和显示，利用 MATLAB 进行彩色图像显示，截取的局部图像具体结果如图 2。

(4) 分析



(a) 结果图



(b) 相应的 IKONOS 局部图

图 2 基于混合像元分解的植被覆盖度提取结果

①与 IKONOS 高分辨率图像对比可以看出，提取的植被区域与 IKONOS 图像中的植被部位非常吻合。利用目视进行定性比较，IKONOS 图像中植被覆盖度高处，计算结果相应增高，植被覆盖度低处，计算结果相应减小。

②利用局部区域进行误差估算，混合像元分解法比直接利用 NDVI 获得的结果更好，平均提高精度达到 5.325%。表明混合像元分解法可以有效地提取植被覆盖度。

③裸地和水体虽然没有植被，但是由于其光谱值也有波动，因此在纯样本不够多的时候，利用混合像元分解法会出现误差，总体来说，仍然比采用植被指数直接提取算法结果要好。

④与基于遥感分类的植被覆盖度提取方法^[7]相比，在居民地中神经网络获得的结果偏大。这是因为纯像元样本和种类有限。研究区地物复杂，即使对于居民地而言，由于不同房顶材料不同，其光谱反射率也不同，提取效果一般。因此对于复杂的同物异谱对象，混合像元分解法提取结果有待进一步提高，这也是将要继续进行的工作。

5 结论

将 FUZZY ARTMAP 神经网络引入混合像元分解提取植被覆盖度。提取结果表明，混合像元分解方法可以有效提取植被覆盖度。

但是对于光谱特征较复杂的地物，该方法有待提高。该方法与基于遥感分类的植被覆盖度提取方法相比，平均精度稍差，特别对于非植被区域，比如居民地和水体部分，由于同物异谱现象更复杂，效果一般。因此，对于地表覆盖分类较好的研究对象，利用基于遥感分类的植被覆盖度提取方法效果更好。

参考文献：

- [1] 李小文,王锦地.植被光学遥感模型与植被结构参数化[M].北京:科学出版社,1995.