

# 一种基于多层次 MRF 的多源图象融合算法

李士民 郭立 朱俊株

(中国科学技术大学电子科学与技术系, 合肥 230026)

**摘要** 图象融合技术的主要目的是将多种图象传感器数据中的互补信息组合起来,使形成的新图象更适合于计算机处理(如分割、特征提取和目标识别)等。在多层次 MRF 模型的基础上,提出了一种应用于多源图象分类的图象融合算法。该融合算法将定义在多层次图结构上的非线性因果 Markov 模型与贝叶斯 SMAP(sequential maximum a posteriori)最优化准则结合起来,克服了 MAP(maximum a posteriori)准则在多层次图结构上计算不合理的缺陷。该算法可应用于多源遥感图象中的信息融合,使像素分类更精确,并解决多源海量数据的富集表示。另外还利用合成图象与自然图象分别针对多层次 MRF 模型的改进及算法中最优化准则的不同进行了对比实验,结果表明,该算法具有许多优越性。

**关键词** 计算机图象处理(520·6040) 多源图象融合 多层次模型 序贯最大后验概率 图象分割  
**中图分类号**: TP391.41 TP751.1 **文献标识码**: A **文章编号**: 1006-8961(2003)02-0155-06

## A Multisource Image Fusion Method Based on Hierarchical Markov Random Field Model

LI Shi-min, GUO Li, ZHU Jun-zhu

(Dept. of Electronic Science and Technology, University of Science and Technology of China, Hefei 230026)

**Abstract** The main objective of the technique of image data fusion is combining or amalgamating information from multiple sensors such that the new images are more suitable for the purpose of the computer-processing tasks such as segmentation, feature extraction, and object recognition. This paper proposes a multisource image fusion algorithm based on hierarchical markov random field model. The algorithm defines the fused image as the hidden labels, and the multisource image can be defined as observation of the hidden labels. The hidden labels can be extended in the quadtree manner. In order to reduce the computational burden, this paper uses a hybrid structure which combines a spatial grid of a reduced size at the coarsest level with sub-tree below it, down to the finest level. The hidden labels can be estimated by a noniterative inference on sub-tree with ICM algorithm defined on the top of the hybrid structure. In order to circumvent the drawback of classical MAP criterion on the hierarchical graph structures, this algorithm combines nonlinear causal Markov model defined on hierarchical graph structures with bayesian SMAP criterion. This algorithm can applied to multi-source remote sensed image fusion, and can contribute to the correctness of image pixels labeling and the reduction of the multi-source image volume. The contrast experiments on syntheric and satellite images indicated the advantage of this algorithm relative to the classic algorithm.

**Keywords** Computer image processing, Multisource image fusion, Hierarchical MRF model, Sequential maximum a posteriori, Image segmentation

## 0 引言

随着成像技术的发展,图象数据可以从多个不同传感器获得。由于单独的图象传感器提供的信息往往

是有限的,因此通常需要其他的图象传感器提供辅助信息。国内外的研究现状表明,对于利用图象融合算法对多源遥感图象中像素进行分类,从而实现图象的分割这类问题,解决的主要途径包括统计模型、证据理论和神经网络。文献[1]、[2]利用同一组数据说明

了利用统计模型的结果是最优的. MRF 模型作为一种数据融合的数学模型已经被广泛应用于图象融合领域中, 它的优势在于利用 Gibbs 分布可以将不同分量的似然函数结合起来, 达到图象融合的目的.

为了对图象中的像素进行分类, 普遍采用的方法是利用 MRF 准则使能量函数(代价函数)最小化, 从而得到全局或局部最优的估计值. 使能量函数最小化的方法主要有模拟退火、ICM 算法(iterated conditional modes)、MPM 算法(modes of posterior marginals). 但是由于这些算法的随机性, 计算量普遍较大. 为了减少计算量, 文献[3]、[4]提出一种基于多层次 MRF 模型的图象融合算法, 该算法在四分树结构上, 引入了因果的概念, 从而得到了一种确定性的快速算法. 文献[5]又将该树型模型应用于多分辨率图象的融合, 但其缺点在于树型结构较主观, 从树的根节点向下看, 在较高分辨率的平面结构上, 不相关的节点都是相关的, 从而造成结果存在“块状”失真, 并且对于尺寸较大的图象, 树型结构的计算也较复杂. 文献[6]、[7]提出了一种“截断”的多层次 MRF 模型, 该模型是由一系列大小不同的平面结构组成, 各个层次的像素之间是由四分树结构联系的, 如图 1 所示, 相邻的平面大小相差 4 倍. 该结构能够较好地结合树型结构与平面网格结构的优点, 在降低计算量的同时, 也提高了融合的效果.




图 1 “截断”的多层次 MRF 模型

本文在“截断”的多层次 MRF 模型的基础上, 根据该多层次 MRF 模型的特点, 提出了一种新的多源图象数据融合方法, 进一步地提高了融合算法的效果.

## 1 多层次 MRF 模型

为了定义多层次 MRF 模型, 采用四分树结构. 图 1 所示为二级 MRF 模型, 模型中每一个节点表示图象中的一个像素点,  $S = (S^{(n)})_{n=0}^N$  表示整个多层次图,  $S^{(0)}$  是最低分辨率所有节点的集合.  $S^{(N)}$  为最高分

分辨率所有节点的集合. 随机向量  $X$  与  $Y$  分别表示该模型上各节点的实际值与观测值,  $x$  与  $y$  为随机向量  $X$  与  $Y$  的一个实例.  $x_s$  取值范围为  $\Lambda = \{1, \dots, M\}$ ,  $M$  为像点的类别总数. 对应于  $S^{(n)}$  中节点的观测值可以表示为  $X^{(n)} = (X_i)_{i \in S^{(n)}}$ . 在多源图象融合处理中, 实际图象中的每一个像点  $x_i$  对应的观测值  $y_i$  为序列  $(y_{i_1}, y_{i_2}, \dots, y_{i_k})$ , 其中  $k$  为图象传感器的数目. 由图 1 可见, 每一个节点  $j (j \in S^{(n)})$  都只有一个父节点  $\bar{j}$ , 每一个节点  $i (i \in S^{(n)})$  有 4 个子节点  $\{i\}$ .  $d(s)$  表示以  $s$  为根节点的所有后代(包括  $s$  节点),  $D(s)$  表示  $d(s)$  中除了  $s$  节点以外的所有节点.

进一步, 对  $(X, Y)$  有以下假设<sup>[3,4]</sup>:

(1) 层次间的马尔可夫性 序列  $(X^{(n)})_{n=0}^N$  是一阶自上向下的马尔可夫链

$$P(x^{(n)} | x^{(n-1)} \dots x^{(0)}) = P(x^{(n)} | x^{(n-1)}), \forall n \in \{1, \dots, N\}$$

(2) 层次间的转移概率

$$\begin{aligned} P(x^{(n)} | x^{(n-1)}) &= \prod_{i \in S^{(n)}} P(x_i | x_i) \\ &= \prod_{i \in S^{(n)}} g(x_i | x_i), \forall n \in \{1, \dots, N\} \end{aligned}$$

(3) 对于观察值  $Y$ , 可以证明<sup>[1]</sup>

$$P(y | x) = \prod_{i \in S} P(y_i | x_i) = \prod_{i \in S} f(y_i | x_i)$$

由以上定义可见, 除了  $S^{(0)}$  中为二阶邻域外, 在  $S^{(n)} (n \in \{1, \dots, N\})$  中的每一个节点都是通过父节点相关的. 根据贝叶斯原理, 后验条件概率分布  $P(x | y)$  可以有如下形式

$$\begin{aligned} P(x | y) &\propto \prod_{i \in S^{(0)}} g_i(x_i, x_{N(i)}) \times \prod_{i \in S^{(0)}} g(x_i | x_i) \times \\ &\quad \prod_{i \in S} f(y_i | x_i) \end{aligned} \quad (1)$$

其中, 函数  $g$  表示先验概率分布,  $f$  表示似然函数.

## 2 多源图象数据融合算法

### 2.1 贝叶斯估计

数据融合的目的是从观察值  $(Y^{(n)})_{n=0}^N$  中得到最有可能的  $(X^{(n)})_{n=0}^N$ , 根据贝叶斯估计的原理, 可以定义一个代价函数  $C_{\text{MAP}}$ , 使  $\hat{x}$  满足以下条件

$$\hat{x} = \underset{x}{\text{arg min}} E(C(X, x) | Y = y)$$

其中, 函数  $\varphi$  表示求满足极值条件时的  $x$ .

最大后验概率(MAP)是最常用的估计方法, 它的代价函数  $C$  定义为

$$C_{\text{MAP}}(x, \hat{x}) = 1 - \delta(\hat{x}, x) = 1 - \prod_{n=0}^N \delta(x^{(n)} - \hat{x}^{(n)})$$

其中,  $\delta$  是 Kronecker 函数. 估计值可以通过以下表达式

$$\hat{x} = \varphi(\max P(x|y)) = \varphi(\max P(x, y)) \quad (2)$$

由于采用的是多层次 MRF 模型,它没有考虑到不同层次节点对代价函数的影响是不同的,因此这里采用序贯最大后验概率(SMAP)所定义的代价函数

$$C_{\text{SMAP}}(x, \hat{x}) = \sum_{n=0}^N 2^{N-n} C^{(n)}(x, \hat{x})$$

其中,  $C^{(n)}(x, \hat{x}) = 1 - \prod_{i=0}^n \delta(x^{(i)} - \hat{x}^{(i)})$ . 在该代价函数中,每一层节点的代价函数都是不同的,分辨率越低,平面中的节点对代价函数影响就越大.

### 2.2 多分辨率图象数据融合算法

根据文献[3],[4],[6],对多层次 MRF 模型的求解可以基于一种半随机的方式. 将序贯最大后验概率(SMAP)中的代价函数引入该模型中,求解的算法思路如下

$$\begin{aligned} & \min_x E \left\{ \sum_{n=0}^N 2^{N-n} C^{(n)}(x, \hat{x}) \mid Y = y \right\} \\ & = \max_x \sum_{n=0}^N 2^{N-n} E \left[ \prod_{i=0}^n \delta(x^{(i)} - \hat{x}^{(i)}) \mid Y = y \right] \\ & = \max_x \sum_{n=0}^N 2^{N-n} P(x^{(n)} = \hat{x}^{(n)}, i \leq n \mid Y = y) \quad (3) \end{aligned}$$

根据文献[6],类似的有

$$\hat{x}^{(n)} \approx \varphi \max \left( \prod_{i \in S^{(n)}} P(x_i | x_{s(i)}) P(y_i | x_i) \right), s \in S^{(n)} \quad (4)$$

$$\begin{aligned} \hat{x}^{(n)} & \approx \varphi(\max(P(y^{(n)} | x^{(n)}) P(x^{(n)} | \hat{x}^{(n-1)}))) \quad (5) \\ & \forall n \in \{1, \dots, N\} \end{aligned}$$

其中,  $\partial(s)$  为节点  $s$  的二阶邻域.

对于具有因果结构的多层次 MRF 模型,具有以下性质

$$\begin{aligned} P(y^{(n)} | x^{(n)}) & = \prod_{i \in S^{(n)}} P(y_{s(i)} | x_i) \\ & = \begin{cases} \prod_{i \in S^{(n)}} f(y_i | x_i) \\ \prod_{i \in S^{(n)}} f(y_i | x_i) P(y_{D(i)} | x_i) \end{cases} \quad (6) \\ & \forall n \in \{0, \dots, N-1\} \end{aligned}$$

其中

$$P(y_{D(i)} | x_i) = \begin{cases} \prod_{i \in D(i)} \sum_{x_i} f(y_i | x_i) g(x_i | x_i) & s \in S^{(N-1)} \\ \prod_{i \in D(i)} \sum_{x_i} f(y_i | x_i) g(x_i | x_i) P(y_{D(i)} | x_i) & \end{cases}$$

因此,具体的融合计算步骤可以归纳如下:

对于节点  $(s \in S^{(N)})$ :

$$F_s(x_s) = \sum_{x_i} g(x_i | x_s) f(y_i | x_i) \quad (7)$$

其中,  $g(x_i | x_s)$  为先验条件概率分布,  $f(y_i | x_i)$  为似然函数.

对于节点  $(s \in S^{(n)}, n = N-1, \dots, 1)$ ,从式(6)可以得到

$$F_s(x_s) = \sum_{x_i} g(x_i | x_s) f(x_i | y_i) \prod_{i \in \partial(s)} F_i(x_i) \quad (8)$$

对于节点  $(s \in S^{(n)})$ ,由于在  $S^{(n)}$  上,不存在因果结构,因此不能够简单地利用确定性算法,采用 ICM(iterated conditional mode)算法来得到  $\hat{x}^{(n)}$ ,式(4)的计算形式如下

$$\begin{aligned} \hat{x}^{(n)} & \approx \max_x \left[ \prod_{i \in S^{(n)}} g(x_i | x_{s(i)}) \times \prod_{i \in S^{(n)}} f(y_i | x_i) \times \right. \\ & \left. \prod_{i \in \partial(s)} \prod_{i \in \partial(i)} F_i(x_i) \right], s \in S^{(n)} \quad (9) \end{aligned}$$

对于  $s \in S^{(n)}, n \in \{1, \dots, N\}$  可以从式(5)得到

$$\begin{aligned} \hat{x}_s & \approx \max_x [p(y_{s(i)} | x_i) P(x_i | \hat{x}_i)], s \in S^{(n)} \quad (10) \\ & \forall n \in \{1, \dots, N\} \end{aligned}$$

## 3 实验与分析

### 3.1 合成图象

分别利用合成图象与自然图象作为实验对象. 多层次 MRF 模型中,选定  $N=2$ ,并将上述算法定义为 SH-SMAP(semi-iterative inference). 首先使用大小为  $256 \times 256$  的合成图象来测试 SMAP 准则在该多层次模型上的应用效果,并与文献[3],[4]中介绍的 NH-ICM、H-MAP 和 SH-MPM 算法进行对比. 实验的目的在于利用图象恢复来检测该融合算法的有效性,并提供量化的比较结果. 合成图象中包含有 5 类灰度值不同的像素,原始图象如图 2(a)所示. 对原图象加入高斯白噪声,加入噪声的幅度分别增大,如图 2(b),(c)所示,其均值与方差均已知.

由于加入的是高斯白噪声,每个像点的似然函数可以定义为

$$f(y_i | x_i) = P(y_i | x_i) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(y_i - \mu)^2}{2\sigma^2}\right\}, \forall s \in S$$

对于四分树上的先验概率分布,采用文献[1]提出的 Potts 分布

$$g(x_i | x_i) = \begin{cases} \theta & x_i = x_i \\ \frac{1-\theta}{M-1} & x_i \neq x_i \end{cases}$$




图 2 合成图象

一般的,取  $\theta > \frac{1}{M}$ . 在实验中,取  $\theta$  值为 0.9.

在最低分辨率 MRF 中,由于不存在确定性算法,就必须定义先验联合分布  $g(x_i, x_{n(i)})$ . 这里仅考虑二阶邻域系统,也就是每个像点  $x_i$ ,必须考虑其 8 个邻接像点.

$$g(x_i, x_{n(i)}) = P(x_i | x_{n(i)}) = \prod_{l \in \mathcal{N}(i)} e^{-\frac{(x_i - x_l)^2}{2\sigma_l^2}}$$

其中,  $\alpha$  为相邻像点之间的相关系数. ICM 算法中的固定迭代次数取为 10. 在确定了先验概率分布与似然函数以后,就可以进行融合计算. 第 1 步,利用式(7)计算  $F_s(x_i), s \in S^{(2)}$ ; 第 2 步,利用式(8)计算  $F_s(x_i), s \in S^{(1)}$ , 其中  $f(y_i | x_i) \sim 1$ ; 第 3 步,利用式(9)计算  $\hat{x}_i^{(2)}$ ; 第 4 步,利用式(10)可以向下计算  $\hat{x}_i, s \in S^{(1,2)}$ , 从而实现了对污染图象的恢复.

图 3 和图 4 分别是对图 2(b)、图 2(c)应用

NH-ICM、H-MAP、SH-MPM 与 SH-SMAP 算法得到的结果. 表 1 是 4 种算法对原图的正确识别率及耗时. 由表 1 可以看出, NH-ICM 算法在噪声强度低的情况下,和其他算法的性能相差不大,但随着噪声强度的增加,该算法的性能急剧下降,而 H-MAP、SH-MPM 和 SH-SMAP 算法的性能差别不大,这表明多层次 MRF 模型对噪声有较高的鲁棒性. 在两种噪声强度下, SH-SMAP 与 SH-MPM 算法识别率都要比 H-MAP 算法高. SH-SMAP 与 SH-MPM 算法在两种噪声强度下的性能大致相同.

表 1 4 种算法的识别率

算法	正确分类概率(%)		耗时(s)	
	图 2(b)	图 2(c)	图 2(b)	图 2(c)
NH-ICM	87.9	74	15.7	16
H-MAP	95.2	90	18	19
SH-MPM	96.3	91.5	14.4	15.6
SH-SMAP	96.7	90.8	14.6	12




图 3 图 2(b)各算法结果图象




图 4 图 2(c)各算法结果图象

4 种算法中, H-MAP 算法的耗时最大(PIV 1.4GHz), 原因在于其树型多层次结构较复杂; 利用平面网格结构的 NH-ICM 算法的计算量仅次于 H-MAP 算法; SH-MPM 和 SH-SMAP 算法耗时较小, 说明计算量较少, 这也是“截断”的多层次模型的优点之一, 而其中 SH-SMAP 算法的计算量是最小的。

### 3.2 自然图象

实验数据采用两幅同一地区的不同通道图象(图 5), 图象数据大致分为 4 类, 分别是: 河流、城市、植被(包括森林与草地)、土壤。两幅图象大小为  $512 \times 512$ , 灰度级为 256。




图 5 实验图象

仅考虑有监督分割的问题, 为了简单起见, 认为

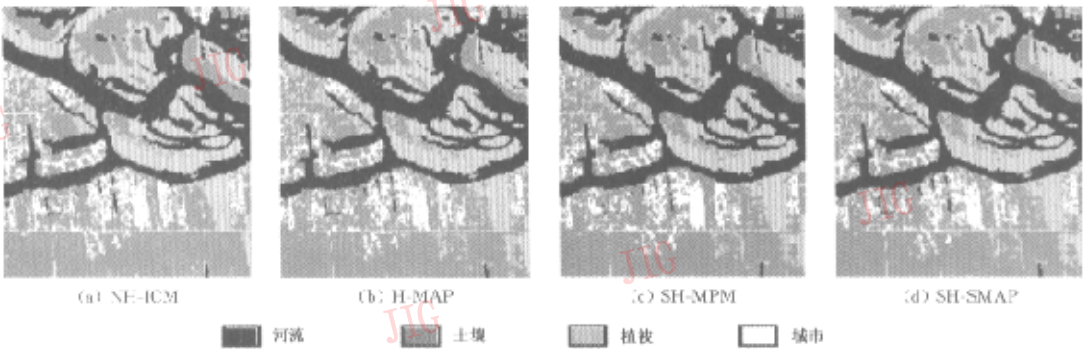


图 6 不同算法对图 5 的分类结果

每种像素类别都服从高斯分布, 对两幅图象进行随机采样, 并利用其中的一部分数据得到不同通道各个数据类别的均值和方差, 剩余的数据用来测试分割的效果。

这里两个通道是互不相关的, 对于模型中的每一个节点, 定义似然函数如下:

$$f(y_s | x_s) = P(y_s | x_s) = \exp\left(-\sum_{i=1}^2 \left(\frac{(y_i - \mu_i)^2}{2\sigma_i^2} + \log(\sigma_i)\right)\right), \forall s \in S$$

由于在以下例子中, 观察值  $y$  是不完整的, 即只有最高分辨率的观察值, 因此定义:  $f(y_s | x_s) = 1, s \in S^{(n)}, n \in \{0, 1, 2\}$ . 先验概率分布  $g(x_s, x_{n(s)})$  如上所述。

图 6 为采用 NH-ICM、H-MAP、SH-MPM 和 SH-SMAP 算法的实验结果。通过对实验数据的分析表明, 采用 SH-SMAP 算法较 NH-ICM、H-MAP 以及 SH-MPM 算法的识别率都有不同程度的提高。

表 2 4 种算法的对各个类别的识别率 (%)

算法	河流	草地	森林	城市
NH-ICM	91	87.5	90.5	91
H-MAP	92	90.5	94	95
SH-MPM	93.5	91	93	94
SH-SMAP	93	91.5	95.5	94.5

## 4 结 论

本文讨论了一种基于多层次 MRF 模型的多源数据融合算法, 并与传统的数据融合算法做了比较。通过对合成图象与实际遥感图象的实验说明了该算法的优越性。该算法利用多源图象的互补信息, 提高

了像素分类的准确性。在多源遥感图象与医学图象处理方面, 融合后生成的图象可大大减少存储容量。在目标识别处理方面, 多传感器信息融合后生成的图象可以提高目标识别的准确性与可靠性。本文采用的是有监督分类算法, 算法中先验参数(如  $\theta$ )为经验值, 而类别参数(如  $(\mu, \sigma)$ )是通过训练采样数据得到的。在实际分类时, 先验参数和类别参数往往

是未知的,因此我们正在设计一种针对该融合算法的参数估计算法,从而能够实现无监督的分类算法.

### 参 考 文 献

- 1 Charles A. Bouman and michael shapiro. A multiscale random field model for bayesian image segmentation[J]. IEEE. Trans. Image Processing, 1994, 3(2):162~177.
- 2 Solberg A., Taxt T., Jain A. A markov random fields model for classification of multisource satellite imagery[J]. IEEE Trans. Geoscience and Remote Sensing, 1996, 34(1):100~112.
- 3 Pérez P., Chardin A., Laferte J.M. Noniterative manipulation of discrete energy-based models for image analysis [J]. Pattern Recognition, 2000, 33(4):573~586.
- 4 Laferte J.M., Pérez P., Heitz F. Discrete markov modeling and inference on the quad-tree [J]. IEEE Transactions on Image Processing, 2000, 9(3):390~404.
- 5 Laferte J.M., Heitz F., Perez P. *et al.* Hierarchical statistical models for the fusion of multiresolution image data [A]. In: Proc. Int. Conf. Computer Vision [C], Cambridge, MA, USA, June 1995:908~913.
- 6 Chardin A., Perez P. Semi-iterative inference with hierarchical model [A]. In: Int. Conf. on image processing [C], Chicago, Illinois, USA, October 1998:630~634.
- 7 Chardin A., Perez P. Semi-iterative inference with hierarchical Energy based Models for Image Analysis [A]. In: Int. Workshop on Energy Minimization Methods in Computer Vision and Pattern Recognition [C], University of York, England: Springer Verlag, July 1999, 1654:83~98.



李士民 1976年生,中国科学技术大学博士研究生,研究方向为数据融合、信号检测、图象处理.



郭立 1946年生,中国科学技术大学电子科学与技术系主任,教授、博士生导师,主要研究方向为信号检测、图象处理等.发表论文40余篇.



朱俊株 1969年生,中国科学技术大学讲师、硕士,主要研究方向为图象识别.发表论文十余篇.