

文章编号:1004-4213(2010)07-1289-8

基于各类各向异性的 EM-MAP-HMRF 多源遥感图像融合算法*

何贵青, 彭进业, 郝重阳

(西北工业大学 电子与信息工程研究所, 西安 710072)

摘要:为提高目标识别率,在目标图像融合过程中引入 Markov 随机场建立类别的先验分布模型,针对模型中参量 β 的选取问题,提出了基于各类各向异性的期望最大化-最大后验概率-多层次马尔可夫随机场集中式与分布式两种图像融合算法.实验证明,两种融合算法都既可以提高分类准确度,又能够增大抗噪能力,且二者又有不同的特色,可以根据实际要求(如,运算速度、分类准确度、计算负荷等)进行应用选择,用以提高对特定目标进行自动检测与识别的准确性.

关键词:图像融合;Markov 随机场;EM 算法;各类各向异性;分布式融合;集中式融合

中图分类号:TP751.1

文献标识码:A

doi:10.3788/gzxb20103907.1289

0 引言

随着空间技术与遥感技术的飞速发展,各种不同来源并具有不同特点的对地观测数据大幅度增长.与此同时,用户对信息的需求正从静态非实时向动态实时转化.然而大数据量对于实时或准实时的数据处理以及存储、传输等都是一项严峻的挑战.国内外研究表明,基于图像融合技术的多源遥感图像特征层分类融合处理是解决图像数据海量化和图像存储和传输矛盾的有效途径.

本文利用多层次马尔可夫随机场(Hierarchical Markov Random Field, HMRF)对图像进行建模,结合 Bayes 分类理论,将分类问题转化为最大后验概率(Maximum A Prior Probability, MAP)的问题,随后利用不完全数据中经典的期望最大化(Expectation-Maximization, EM)算法进行参量估计,并重点探讨了先验分布模型参量 β 的选取方法,基于此,提出了基于各类各向异性的 EM-MAP-HMRF 集中式与分布式两种遥感图像融合算法.合成图像与真实遥感图像的实验结果表明,两种算法都既可以明显提高分类准确度,又能够显著加强对噪音的抗干扰能力.

1 HMRF 图像模型

定义图像 S 是 $M \times N$ 的二维栅格系统,记作

$S = \{(i, j) : 1 \leq i \leq M, 1 \leq j \leq N\}$, $N = \{N_{ij} : (i, j) \in L, N_{kl} \subseteq S\}$ 是 S 上的一个邻域系统,一个随机场分布 X 为栅格结构 S 上的 MRF,当且仅当对于一个邻域系统 N , X 满足^[1]

$$P(x) > 0, \forall x \in \chi; P(x_i | x_{S-\{i\}}) = P(x_i | x_{N_i})$$

其中, χ 是 X 的配置空间, x_{N_i} 是 x_i 邻域的随机分布.

在 MRF 模型框架下,采用一个模型对整幅真实图像进行描述有时并不能很好的反映遥感图像的复杂性.因此实际应用中多采用 HMRF 模型对图像进行描述^[2-4].

1) 标号场先验模型

标号场为隐随机场,用以描述像素的局部相关属性,由于(Multi-level Logistic, MLL)多层逻辑模型计算简单,常被应用于模型区域或纹理区域^[5-8].下面根据 Hammersly-Clifford 定理描述的 MRF 与 GRF 的对等性给出先验模型一般性表达式^[1]

$$\pi(x) = P(X=x) = \frac{1}{Z} \exp(-U(x)/T) \quad (1)$$

式中, $Z = \sum_{x \in \chi} \exp(-U(x)/T)$ 是概率分布归一化因子,称为配分函数, χ 是 X 的配置空间; T 表示温度;能量函数 $U(x) = \sum_{c \in C} \beta V_c(x)$, $V_c(x)$ 称为与簇 c 相关的势函数; β 是标号场的模型参量.

2) 图像场模型

人类视觉系统对图像中的一阶统计特性(均值)和二阶统计特性(方差和协方差)很敏感,而对图像中的三阶或更高阶统计特性不敏感.因此,目前大多数文献都采用具体的概率密度函数——高斯分布对图像进行建模^[9-18].下面给出基于高斯密度函数的

* 国家教育部博士点基金(20040699015)和西北工业大学青年科技创新基金(5210102-0800-M016206)资助

Tel: 029-88431211 Email: guiqing_he@nwpu.edu.cn

收稿日期: 2008-11-24

修回日期: 2009-03-04

图像场模型. 假设像素的灰度服从高斯分布, 则以标号场为条件的图像模型描述为

$$f(y|\omega_s) = \frac{1}{\sqrt{2\pi}\sigma_{\omega_s}} \exp\left[-\frac{(y-\mu_{\omega_s})^2}{2\sigma_{\omega_s}^2}\right] \quad (2)$$

式中, 高斯模型参量为 $\theta_{\omega_s} = (\mu_{\omega_s}, \sigma_{\omega_s})$, $\mu_{\omega_s}, \sigma_{\omega_s}$ 分别表示类别标号为 ω_s 的区域内的均值和方差.

至此, 能够利用不同的图像特征实现目标分类的 HMRF 图像模型已经建立, 其中, 不仅利用了像素的光谱信息, 又考虑到邻域像素间存在的依赖关系, 因此该模型能够充分利用图像数据所提供的空间与光谱两方面的信息.

2 MAP-MRF 框架

S. Geman 和 D. Geman 建立了基于 MRF 和最大后验概率的图像复原和边缘提取的 MAP-MRF 框架理论^[19]. 当 ω 符合 MRF 分布, MAP 方法就是由最大后验概率估计 $\hat{\omega}$ 来近似图像的真实分类 ω , 即

$$\hat{\omega} = \arg \max_{\omega \in \chi} P(\omega|y) \quad (3)$$

式中, χ 是 ω 的配置空间.

由贝叶斯准则

$$P(\omega|y) = \frac{P(\omega, y)}{P(y)} = \frac{P(y|\omega) \cdot P(\omega)}{P(y)} \quad (4)$$

式中, y 表示观测到的图像灰度, 在图像确定的情况下, 上式中的分母 $P(y)$ 可以认为是一个常量, 即在计算中可以不考虑 $P(y)$, 因此, MAP 估计 $\hat{\omega}$ 可以表示为

$$\hat{\omega} = \arg \max_{\omega \in \chi} (P(y|\omega) \cdot P(\omega)) \quad (5)$$

显然, 解决 MAP-MRF 问题首先需要确定条件概率 $P(y|\omega)$ 以及 ω 的先验概率 $P(\omega)$ 的模型, 进而根据 MAP-MRF 框架结合优化算法便可最终获取最优解.

基于 MAP-MRF 分类方法的重要影响力在于: 每一个 MRF 的形式化描述都可以转化为一个能量函数的最小化问题. 另一方面, 这种方法的主要困难在于组合优化算法的复杂性, 尤其是基于 HMRF 模型的遥感图像处理过程通常是一项非常艰巨的非线性优化问题. 因此, 后文将考虑如下的计算思路: 基于统计模型对图像进行非监督分类的模型参量估计问题, 转化为通过 EM 算法从不完整数据中估计模型参量的问题.

3 EM 算法与参量估计

3.1 EM 算法

具体到图像分类领域, 可以将 y 理解为观测到的图像灰度, ω 表示图像的类别标号, 属不可观测

量. 因此 y 称为不完全数据, $x = (y, \omega)$ 称为完全数据. 解决不完全数据问题的一个经典方法是 EM 算法. 该算法是一种递归地解决不完全数据参量估计的最大似然方法, 其最大的优点是收敛过程平滑且对扰动不敏感. EM 算法包括

$$E \text{ 步: } Q(\Phi|\hat{\Phi}^{(t)}) = E[\log p(x|\Phi)|y; \hat{\Phi}^{(t)}] \quad (6)$$

$$M \text{ 步: } \hat{\Phi}^{(t+1)} = \operatorname{argmax}_{\Phi} Q(\Phi|\hat{\Phi}^{(t)}) \quad (7)$$

式中, t 为当前迭代次数.

3.2 参量估计

对于本文基于 HMRF 的图像模型, 底层图像场的参量为 $\theta_{\omega_s} = (\mu_{\omega_s}, \sigma_{\omega_s})$, 可以使用 EM 算法寻找模型参量的极大似然估计. 比较而言, 顶层标号场模型参量 β 的计算、选择始终是一个难点问题, 一般情况下采取多次尝试、人工选定的方式进行选取, 然后整幅图像数据共用一个选定的 β ^[20-23]. 采用相同的参量 β 进行计算, 等同于假设待分类图像是各类各向同性的, 而事实上对于图像数据的不同类别及不同方向, 采用不同的 β 才能获得好的分类结果, 尤其对于遥感图像, 因其本身存在着多种特性各异的地物目标, 而且在图像生成过程中还有噪音成分加入, 因此, 各类各向异性的自适应 β 的研究很有意义.

为了表述方便, 现将基于 MLL 模型的能量函数及其相应的势函数表达式改写为^[24]

$$U(x) = \sum_{k=1}^K \sum_{d=1}^D \beta_{k,d} V_c(x) \quad (8)$$

式中, $V_c(x) = \begin{cases} -1 & x_i = x_j \\ 1 & \text{其它} \end{cases}$, $\beta_{k,d}$ 是标号场的模型

参量, 下标 k, d 分别表示类别和邻域的不同方向, D 为方向数. 对于 8-邻域系统, 方向数 D 为 4, 即 $d = 0^\circ, d = 45^\circ, d = 90^\circ, d = 135^\circ$ 共 4 个不同的方向, 分别对应于不同方向的像素对构成的不同的簇. 由此, 各类各向异性的自适应 $\beta_{k,d}$ 的定义式为

$$\beta_{k,d} = \sqrt{\frac{\sum_{i=1}^{M \times N} \left(\sum_{m \in N_i^d} (\omega_{ik}^i - \omega_{mk}^i) \right)^2}{N/c}} \quad (k=1, 2, \dots, K, 1 \leq i \leq M \times N) \quad (9)$$

式中, N_i^d 表示图像 S 中像素 i 的 d 方向邻域; $\omega_{ik}^i, \omega_{mk}^i$ 分别表示像素 i 及其 d 方向上的邻域像素 m 属于类 k 的后验概率. 由于像素的后验概率是图像光谱信息与空间信息的综合与提炼, 某一像素与其邻域像素同属某类的后验概率之差能够反映图像光谱与空间二维信息的变化, 因此, 各类各向异性的 $\beta_{k,d}$ 的定义更加真实地描述了实际的图像数据. 此外, 式(9)中的 c 表示调整系数, 以适用于不同要求的图像处理, 例如, 对于重度噪音污染的图像处理要求 β 较大, 相反, 对于保持空间细节成分的则要求 β 较小,

因此设置调整系数 c 是合理有效的,此举可使自适应 β 更具适用性与通用性。

4 基于各类各向异性的 EM-MAP-HMRF 集中式与分布式遥感图像融合算法

4.1 EM-MAP-HMRF 分类算法

图像的分类就是将图像中的每个像素点赋予有限类别集中的一组标号的过程. 定义图像的像素观察值向量 $y = \{y_s; s \in S\}$ 和隐藏值向量 $\omega = (\omega_{s_1}, \omega_{s_2}, \dots, \omega_{s_{M \times N}})$, 其中 ω_{s_i} 是一个指示像素点 y_{s_i} 类别的向量, 假设图像分为 K 类, 则对于某个类别 $k (1 \leq k \leq K)$, $\omega_k = e_k$, 其中 e_k 代表第 k 个分量为 1、其他分量为 0 的单位向量. $\Phi = (\Phi_y, \Phi_\omega)$ 代表参量集合, $\hat{\omega}_{ik}^t$ 表示在第 t 次迭代过程中像素点 i 属于类别 k 的隶属度估计值, 式中

$$\sum_{k=1}^K \hat{\omega}_{ik}^t = 1, \text{ 且 } 0 \leq \hat{\omega}_{ik}^t \leq 1$$

Zhang^[25] 提出的 EM-MAP-HMRF 分类算法的实现步骤

Step1 初始化过程: 设置初始类别标号 $\hat{\omega}^0 = \{\hat{\omega}_{ik}^0 | i = 1, 2, \dots, M \times N; k = 1, 2, \dots, K\}$; 设置初始参量 $\hat{\Phi}_k^0 = (\hat{\Phi}_{y,k}^0, \hat{\Phi}_{\omega,k}^0) = (\hat{\mu}_k^0, \hat{\sigma}_k^0, 0)$; 置迭代次数 $t = 0$.

Step2 应用 EM 算法得到图像场的估计参量

$$\hat{\mu}_k^t = \frac{1}{\hat{N}_k^{t-1}} \sum_{i=1}^{M \times N} \hat{\omega}_{ik}^{t-1} y_i \quad (10)$$

$$\hat{\sigma}_k^t = \sqrt{\frac{1}{\hat{N}_k^{t-1}} \sum_{i=1}^{M \times N} \hat{\omega}_{ik}^{t-1} (y_i - \hat{\mu}_k^t)^2} \quad (11)$$

式中, $\hat{N}_k^{t-1} = \sum_{i=1}^{M \times N} \hat{\omega}_{ik}^{t-1}$

Step3 应用(9)式计算各类各向异性的标号场参量 β 的估计值.

Step4 扫描整幅图像, $i = 1, 2, \dots, M \times N$, 根据式(14)计算 $\hat{\omega}_{ik}^t$

$$\hat{\omega}_{ik}^t \triangleq f(\omega_i = e_k | y_i; \hat{\Phi}^{t-1}) = \frac{f(y_i | \omega_i = e_k; \hat{\Phi}^{t-1}) f(\omega_i = e_k; \hat{\Phi}^{t-1})}{\sum_{j=1}^K f(y_i | \omega_i = e_j; \hat{\Phi}^{t-1}) f(\omega_i = e_j; \hat{\Phi}^{t-1})} \quad (12)$$

式(12)中, 条件概率密度函数 $f(y_i | \omega_i = e_k)$ 如式(2), ω 是一个 MRF 并服从 Gibbs 分布, 根据 Zhang 的均值场近似理论^[25], 有

$$f(\omega_i = e_k) = \frac{\exp[\hat{\beta}_{k,d}^t \hat{\delta}_i^{t-1}(k)]}{\sum_{k=1}^K \exp[\hat{\beta}_{k,d}^t \hat{\delta}_i^{t-1}(k)]} \quad (13)$$

式(13)中, $\hat{\delta}_i^{t-1}(k) = \sum_{j \in N_i} \hat{\omega}_{jk}^{t-1}(k)$, $\hat{\beta}_{k,d}^t$ 为 Step3 得到的参量估计值.

由此, 将(13)与(2)代入(12)可以得到式(14)

$$\hat{\omega}_{ik}^t = \frac{\exp\left[\hat{\beta}_{k,d}^t \hat{\delta}_i^{t-1}(k) - \ln \sqrt{2\pi} \hat{\sigma}_k^{t-1} - \frac{(y_i - \hat{\mu}_k^{t-1})^2}{2(\hat{\sigma}_k^{t-1})^2}\right]}{\sum_{k=1}^K \exp\left[\hat{\beta}_{k,d}^t \hat{\delta}_i^{t-1}(k) - \ln \sqrt{2\pi} \hat{\sigma}_k^{t-1} - \frac{(y_i - \hat{\mu}_k^{t-1})^2}{2(\hat{\sigma}_k^{t-1})^2}\right]} \quad (14)$$

Step5 如果参量值的变化小于某个事先设定的阈值, 或者迭代次数到达了实现设定的值, 则结束迭代, 跳转到 Step6, 否则回到 Step2, 且置迭代次数 $t = t + 1$.

Step6 在每个像素点 $i = 1, 2, \dots, M \times N$, 根据 $\omega_i^* = \arg \max_k \hat{\omega}_{ik}^t$ 赋给每个像素点相应的类别标号.

式中 $\hat{\omega}_{ik}^{\text{end}}$ 表示迭代结束时的类别标号的估计.

显然, 图像中各个像素点 y_i 对所有类别 k 实施“软判决”, 它刻画了像素点与各个类别的相似程度. 当在 EM 算法的前一次迭代步骤中使用的是“硬判决”而非“软判决”的时候, 该算法就退化为 Besag^[25] 提出的非监督的 ICM 迭代算法.

4.2 基于各类各向异性的 EM-MAP-HMRF 集中式与分布式遥感图像融合算法

根据数据融合的相关理论, 分布式与集中式是特征层融合通常采用的两种结构. 本文则基于各类各向异性的自适应 β 因子, 提出 EM-MAP-HMRF 集中式与分布式两种特征层融合算法, 二者各有优缺点, 实际应用当中, 应根据系统的条件与处理要求选择合适的融合模型.

4.2.1 集中式融合

在多传感器数据特征融合当中, 假设前端存在 P 个信源的图像, 且各信源的图像数据相互独立, 则融合模型前端图像的联合概率将表示为 P 个条件概率的乘积, 因此 EM-MAP-HMRF 分类算法的流程不变, 只需将 Step4 中的式(14)改写为

$$\hat{\omega}_{ik}^t = \frac{\exp\left\{\hat{\beta}_{k,d}^{t-1} \hat{\delta}_i^{t-1}(k) - \sum_{p=1}^P [\ln \sqrt{2\pi} \hat{\sigma}_{p,k}^{t-1} + \frac{y_{p,i} - \hat{\mu}_{p,k}^{t-1}}{2(\hat{\sigma}_{p,k}^{t-1})^2}]\right\}}{\sum_{k=1}^K \exp\left\{\hat{\beta}_{k,d}^{t-1} \hat{\delta}_i^{t-1}(k) - \sum_{p=1}^P [\ln \sqrt{2\pi} \hat{\sigma}_{p,k}^{t-1} + \frac{(y_{p,i} - \hat{\mu}_{p,k}^{t-1})^2}{2(\hat{\sigma}_{p,k}^{t-1})^2}]\right\}} \quad (15)$$

式中, $1 \leq p \leq P, 1 \leq k \leq K, 1 \leq i \leq M \times N$.

此外, 在重估参量的时候需要针对每幅图像进行估计.

4.2.2 分布式融合

基于各类各向异性的 EM-MAP-HMRF 模型的分布式特征融合需要对每幅图像分别进行分类, 得到 P 个图像相对于类别 $k (1 \leq k \leq K)$ 的隶属度矢

量集合. 在融合节点上, 根据下面的方法融合各图像的隶属度矢量. 记第 p ($1 \leq p \leq P$) 幅图像中像素点 i 的灰度值为 g_{p_i} , 由各类各向异性的 EM-MAP-HMRF 算法得到的隶属度矢量为 $\omega_{p_i}^* = \{\omega_{p_{i1}}^*, \omega_{p_{i2}}^*, \dots, \omega_{p_{iK}}^*\}$, 式中 $\omega_{p_{i,k}}^*$ 表示第 p 幅图像中像素 i 对应于第 k 类的隶属度. 则像素点 i 的灰度值计算为

$$g_{p_i} = \sum_{k=1}^K \omega_{p_{i,k}}^* \hat{\mu}_{p_{i,k}} \quad (16)$$

式中 $\hat{\mu}_{p_{i,k}}$ 表示第 p 幅图像中像素点 i 经过分类得到的第 k 类的参量(均值)估计值. 采用均值法对这 P 幅图像在融合节点进行融合, 融合后的图像灰度值为

$$g_{f_i} = \frac{1}{P} \sum_{p=1}^P g_{p_i} \quad (17)$$

最后再对融合后的图像进行一次各类各向异性的 EM-MAP-HMRF 分类便得到最终的结果.

4.3 实验与分析

通常情况下, 实际遥感图像类别先验知识是不可知的, 为了验证本文所提算法的融合性能并对比证明该算法的优越性, 本文设计了两组实验, 其中第一组采用人工合成的仿真图像, 以此对算法在理想情况下的性能进行定量的分析, 第二组采用真实的遥感图像, 进一步从主观视觉角度验证算法的有效性.

图 1(a) 是人工合成的灰度图像, 其大小为 128×128 , 且根据灰度值可分为 3 类. 图 2(b)、(c) 分别为对图 1(a) 加高斯白噪声 $N(0, 0.056)$ 、 $N(0, 0.256)$ 的图像.

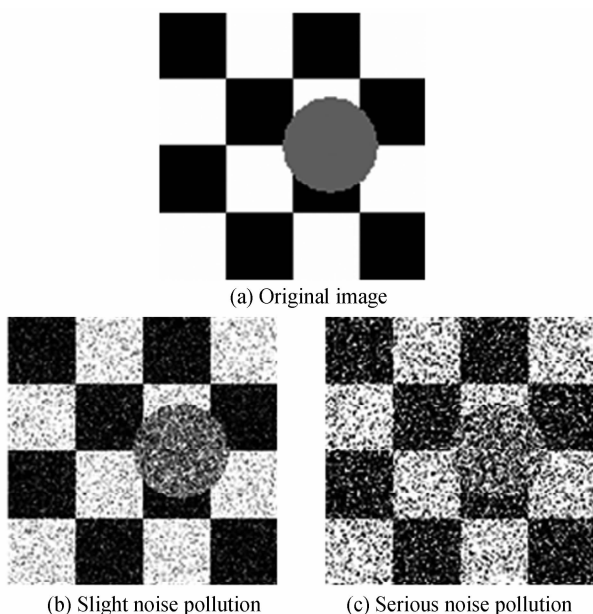


图 1 原始图像及其加噪图像

Fig. 1 Original image and its polluted images by different noises

对图 1(b)、(c) 分别采用基于 MAP-HMRF 的

三种迭代算法—SA 算法^[27]、非监督的 ICM 算法^[28]和 EM 算法^[25], 并相应的记作 SA-MAP-HMRF 算法、UICM-MAP-HMRF 算法和 EM-MAP-HMRF 算法, 其分类结果图如图 2(a)、(b)、(c); 进一步应用本文提出的基于各类各向异性的 EM-MAP-HMRF 集中式与分布式两种融合算法, 并分别记作

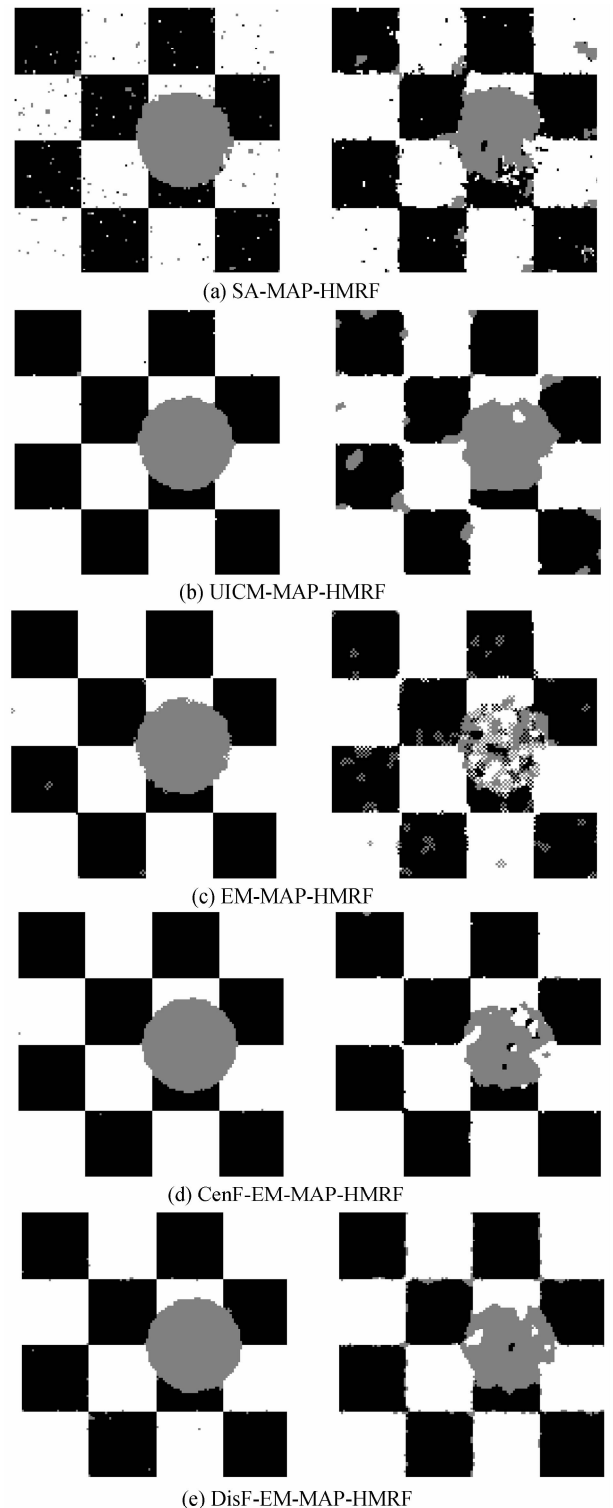


图 2 各算法分类结果

Fig. 2 Classification results of different algorithms where each pair of figures correspond to slight and serious noise pollution respectively

CenF-EM-MAP-HMRF 算法和 DisF-EM-MAP-HMRF 算法,其分类结果图如图 2(d)和(e).图 2 中左右图像分别对应轻微噪音污染和严重噪音污染两种情况.由于该组实验中人工合成图像的真实对象是完全清楚的,所以可以对各算法的分类性能进行精确的定量分析并对比显示本文算法融合性能的优越性^[26].实验中,为了对比的公平性,每种算法都采

用相同的初始类别标号,且本文算法使用的融合图像取自给定噪音水平下的两幅图像.

表 1 分别给出了不同噪音水平下各算法的分类准确度定量比较结果,由分类结果图像(图 2(a)~(e))以及分类结果统计评价数据(表 1)可以得出结论:

表 1 不同噪音水平下的分类准确度与 kappa 系数的比较

Table 1 Comparison of kappa coefficient and classification accuracy on different noises

	Slight noise		Serious noise pollution	
	Pollution classification accuracy/(%)	Kappa Coefficient	Pollution classification accuracy/(%)	Kappa Coefficient
SA-MAP-HMRF algorithm	97.638	0.959 93	92.285	0.868 51
UICM-MAP-HMRF algorithm	99.634	0.993 73	95.233	0.919 42
EM-MAP=HMRF algorithm	99.487	0.991 23	91.742	0.854 98
CenF-EM-MAP-HMRF algorithm	99.878	0.99791	96.790	0.944 11
DisF-EM-MAP-HMRF algorithm	99.573	0.992 70	96.545	0.940 80

1)当合成图像受到轻微噪音污染时,各算法都能有较高的分类准确度;随着噪音水平的增加,各算法的正确分类率开始降低,其中,SA-MAP-HMRF 算法与 EM-MAP - HMRF 算法下降最为明显,这是由于 SA-MAP-HMRF 算法采用模拟退火迭代策略,其迭代周期与降温过程都非常长,因此在一定的迭代次数后一般不能达到满意的效果,而 EM-MAP - HMRF 算法由于整幅图像采用相同的 β 值,因此在去噪与细节保持两者之间不能取得很好的平衡,尤其当噪音污染严重时,上述平衡更加难以获取.

2)UICM-MAP-HMRF 算法分类准确度较高,这是由于该算法中的 ICM 迭代具有以下特点,即,与 SA 算法比较,ICM 算法能很快收敛到稳定值,但不能保证收敛到全局最优解,因为初始值的选取对 ICM 所能收敛到的稳定解有着重要影响,如果合理选取初始值,该算法能达到非常满意的分类结果^[29].本文借鉴文献^[29]的思想,选用 ML 估计作为初始值,取得了较好的效果.

3)本文提出的集中式和分布式两种融合方案都

能进一步提高图像的分类准确度,尤其当噪音污染程度逐步严重时,该两种融合方案的分类性能更具明显优势. UICM-MAP-HMRF 算法在边界处误分类的面积较大,斜边界判断得不好,而本文两种算法均能将误分类面积大大减少,边界也更平滑、精确,并且,噪音水平越高,分类准确度越优越.这是由于融合模型能够降低单幅图像因噪音引起的不确定性,从而产生出比单一图像更精确、更完整、更可靠的估计和判断.此外,集中式融合结构的准确度最高,因为其融合中心可以得到最完整的信息,但计算负担较重,融合节点的代价较高,融合结果对外界扰动很敏感;而分布式融合结构则依赖于各个节点,具有较快的实时处理能力,适合于并行处理来提高分类速度与效率.

4)限于篇幅,表 2 仅列举严重噪音污染下应用本文提出的集中式与分布式两种融合算法得到的 β 值,显然,本文算法的 β 因子具有各类各向异性.具体应用中, β 初始值的选取直接影响分类结果的好坏; β 值增大,则邻域信息加强,去噪能力增加,但图

表 2 严重噪音污染情况下得到的 β 值(k, d 分别表示类别和邻域的不同方向)

Table 2 β values of serious noise polluted

(a) Concentrative fusion solution

$\beta_{k,d}$	$d=1$	$d=2$	$d=3$	$d=4$	$d=5$	$d=6$	$d=7$	$d=8$
$k=1$	2.263 7	1.672 8	2.239 6	1.667 3	2.263 7	1.672 8	2.239 6	1.667 3
$k=2$	1.253 7	1.003 2	1.202 6	0.944 9	1.253 7	1.003 2	1.202 6	0.944 9
$k=3$	2.316 1	1.728 4	2.274 8	1.684 1	2.316 1	1.728 4	2.274 8	1.684 1

(b) Distributive fusion solution

$\beta_{k,d}$	$d=1$	$d=2$	$d=3$	$d=4$	$d=5$	$d=6$	$d=7$	$d=8$
$k=1$	1.742 6	1.308 3	1.745 6	1.255 2	1.742 6	1.308 3	1.745 6	1.255 2
$k=2$	0.861 7	0.694 0	0.871 1	0.672 2	0.861 7	0.694 0	0.871 1	0.672 2
$k=3$	1.782 5	1.342 3	1.794 3	1.287 7	1.782 5	1.342 3	1.794 3	1.287 7

像细节不易保持; β 值减小则情况反之.在本文的几种对比算法中, β 值通过反复试验、人工选定的经验方式选一定值,本文算法则设定初始值 $\beta=0$,无需尝试不同的 β 值,只要按照式(9)利用每次迭代中得到的后验概率进行自动计算即可,从而得到自适应的各类各向异性的 β 值.由上述图2(a)~(e)以及表1的主、客观结果容易看出该策略更符合实际的图像数据特征,进而分类性能更加优越.

图3是对两幅真实遥感图像应用本文提出的两种融合算法进行融合的结果.其中,图3(a)、(b)分别为 300×300 大小的同一地区 SAR 图像和 TM 近红外通道图像,图3(c)、(d)分别为对图3(a)、(b)应




图3 SAR图像与TM图像的特征融合
Fig.3 Feature fusion of SAR image and TM image

用 UICM-MAP-HMRF 算法进行单独分类的结果,图3(e)、(f)为应用 EM-MAP-HMRF 算法对图3(a)、(b)进行单独分类的结果,图3(g)、(h)则是使用本文提出的 CenF-EM-MAP-HMRF 算法和 DisF-EM-MAP-HMRF 算法进行处理的结果.

由图3可以看出,SAR图像具有较高的空间分辨率和丰富的纹理信息;而TM图像虽然空间分辨率不高,但具有较高的光谱分辨率,适合于分类、变化检测等实际应用.因此,可以综合二者各自的特色信息,取长补短,以得到比单一图像更精确、更完整、更可靠的估计和判断.图3(c)、(d)和(e)、(f)只能利用单幅图像的信息进行分类,而本文提出的集中式和分布式两种方案均能充分利用两幅图像的信息,因此,分类融合的结果图3(g)和(h)的细节信息均比TM图像更丰富,这是因为提取了SAR图像特征的缘故,同时分类融合结果的分类准确度远远大于SAR分类图,这是因为在SAR图像中特征区别不明显的地方,在TM图中表现出了很大的类别可分性.因此本文提出的两种融合算法均能综合考虑SAR图像的纹理特征和TM图像的光谱信息对分类的贡献,提高了分类准确度,实际应用中,可以根据运算速度、分类准确度、计算负荷等系统条件和处理要求具体选择合适的融合模型.

5 结论

MRF利用类别的空间相关性来提高地物的分类准确度;HMRF模型更好地反映了遥感图像的复杂性;EM算法是解决图像非监督分类中参量估计不完全数据问题的经典方法;MAP框架基于Bayes理论将分类问题转化为能量函数的最小化问题;先验分布参量 β 通过最大化后验概率进行自适应获取,具有各类各向异性,更符合地物特征复杂的遥感图像.鉴于此,提出了各类各向异性的EM-MAP-HMRF集中式与分布式遥感图像融合算法.实验表明,两种融合算法都既可以明显提高分类准确度,又能够增大抗噪能力,可以根据实际要求(如,运算速度、分类准确度、计算负荷等)应用于多源遥感图像特征融合系统中,用以增加地物分类的可靠性,并最终提高对特定遥感目标进行自动检测与识别的准确性与有效性.

参考文献

- [1] WAI-KI C, MICHAEL K N. Markov chains: models, algorithms and applications[M]. Springer, 2006.
- [2] DANG M, GOVAERT G. Spatial fuzzy clustering using EM and markov random fields [J]. *System Research and Information Systems*, 1998, (8): 183-202.
- [3] GUO Xiao-wei, TIAN Zheng, LIU Bao-li. A fast algorithm for hidden markov tree training in image denoising[J]. *Journal*

- of Northwestern Polytechnical University, 2004, **22**(4): 457-462.
- 郭小卫,田铮,刘保利.小波域隐 Markov 树模型的图像去噪快速算法[J].西北工业大学学报,2004,**22**(4):457-462.
- [4] DERIN H, ELLIOTT H. Modeling and segmentation of noisy and textured images using gibbs random fields [C]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 1987, **9**(1): 39-55.
- [5] DENG H, CLAUSI D A. Unsupervised image segmentation using a simple MRF model with a new implementation scheme [J]. *Pattern Recognition*, 2004, **37**(12): 2323-2335.
- [6] XU X, LI D, SUN H. Multiscale SAR image segmentation using a double markov random field model[C]. *Proceedings of IEEE 7th International Symposium on Signal Processing and its Applications*, 2003, **1**: 349-352.
- [7] MANJUNATH B S, CHELLAPPA R. A markov random field model-based approach to image interpretation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1992, **14**(6): 606-615.
- [8] YAMRON J P, CARP I, GILLICK L, et al. A hidden markov model approach to text segmentation and event tracking [C]. *Proceedings of the IEEE International conference on Acoustics, Speech and Signal Processing*, 1998, **1**: 333-336.
- [9] LI Xu-chao, ZHU Shan-an. A survey of the markov random field method for image segmentation[J]. *Journal of Image and Graphics*, 2007, **12**(5): 789-798.
- 李旭超,朱善安.图像分割中的马尔可夫随机场方法综述[J].中国图像图形学报,2007,**12**(5):789-798.
- [10] ZHANG J, MODESTINO J W, LANGAN D A. Maximum-likelihood parameter estimation for unsupervised stochastic model-based image segmentation[C]. *IEEE Transactions on Image Processing*, 1994, **3**(4): 404-420.
- [11] ZHANG J. The mean field theory in EM procedures for markov random fields [J]. *IEEE Transactions on Signal Processing*, 1992, **40**(10): 2570-2583.
- [12] ZHANG Y, BRADY M, SMITH S. Segmentation of brain mr images through a hidden markov random field model and the expectation maximization algorithm [J]. *IEEE Transactions on Medical Imaging*, 2001, **20**(1): 45-47.
- [13] WANG J P. Stochastic relaxation on partitions with connected components and its application to image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1998, **20**(6): 619-636.
- [14] BIEMACKI C, CELEUX G, GOVAERT G. Assessing a mixture model for clustering with the integrated completed likelihood[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, **22**(7): 719-725.
- [15] COMER M L, DELP E J. The EM/MPM algorithm for segmentation of textured images analysis and further experimental result [J]. *IEEE Transactions on Image Processing*, 2000, **9**(10): 1731-1744.
- [16] YU Peng, ZHANG Zhen-long, HOU Zhi-qun. Textured image segmentation based on gauss markov random field mixture model [J]. *Acta Geodaetica Et Cartographica Sinica*, 2006, **35**(3): 224-228.
- 余鹏,张震龙,侯至群.基于高斯马尔可夫随机场混合模型的纹理图像分割[J].测绘学报,2006,**35**(3):224-228.
- [17] LIU Xiao-yun, WANG Zhen-song, CHEN Wu-fan, et al. Remote sensing images hierarchical clustering using markov random field and generalized gaussian mixture models[J]. *Journal of Remote Sensing*, 2007, **11**(6): 838-844.
- 刘晓云,王振松,陈武凡,等.基于 MRF 随机场和广义混合模型的遥感图像分级聚类[J].遥感学报,2007,**11**(6):838-844.
- [18] CHEN Yun-jie, WANG Shun-feng, WANG Li. Brian MR images segmentation based on anisotropic gibbs random field and gauss mixture model[J]. *Journal of Computer-Aided Design and Computer Graphics*, 2007, **19**(12): 1550-1563.
- 陈允杰,王顺凤,王利,等.基于各向异性 Gibbs 随机场与高斯混合模型的脑 MR 图像分割算法[J].计算机辅助设计与图形学学报,2007,**19**(12):1550-1563.
- [19] GEMAN S, GEMAN D. Stochastic relaxation, gibbs distribution and the bayesian restoration of images[J]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 1984, **6**(6): 721-741.
- [20] WON C S, DERIN H. Unsupervised segmentation of noisy and texture image using markov random fields[J]. *Graphical Models and Image Processing*, 1992, **54**(4): 308-328.
- [21] BLEKAS K, LIKASK A, GALATSANOS N P, et al. A spatially constrained mixture model for image segmentation [J]. *IEEE Transactions on Neural Networks*, 2005, **16**(2): 494-498.
- [22] ZHANG B B, ZHANG C S, YI X. Competitive EM algorithm for finite mixture models[J]. *Pattern Recognition*, 2004, **37**(1): 131-144.
- [23] ZHANG Y Y, BRADY M, SMITH S. Segmentation of brain MR images through a hidden markov random field model and the expectation-maximization algorithm [J]. *IEEE Transactions on Medical Image*, 2001, **20**(1): 45-57.
- [24] NIKOU C, GALATSANOS N P, LIKAS A C. A class-adaptive spatially variant mixture model for image segmentation[J]. *IEEE Transactions on Image Processing*, 2007, **16**(4): 1121-1130.
- [25] ZHANG J, MODESTINO J W, LANGAN D A. Maximum-likelihood parameter estimation for unsupervised stochastic model-based image segmentation[J]. *IEEE Transactions on Image Processing*, 1994, **3**(4): 404-420.
- [26] LANKOACDE O, HAYAT M. M, SANTHANAM B. Speckle reduction of sar images using a physically based markov random field model and simulated annealing [C]. *SPIE*, 2005, **5808**: 210-221.
- [27] YAN He, PAN Ying-jun, WU Gang et al. Study on remote sensing image classification based on fractal theory and ridgelet neural network[J]. *Acta Photonica Sinica*, 2007, **36**(6): 342-345.
- 闫河,潘英俊,吴刚,等.基于分形脊波神经网络的遥感图像分类研究[J].光子学报,2007,**36**(6):342-345.
- [28] ZHANG Cui, LI Su-dan, WANG Zheng-zhi. SAR image segmentation based on markov random field model [J]. *Remote Sensing Technology and Application*, 2001, **16**(1): 66-6.
- 张翠,酆苏丹,王正志.基于 MRF 的 SAR 图像分割方法[J].遥感技术与应用,2001,**16**(1):66-68.
- [29] BESAG J. On the statistical analysis of dirty pictures[J]. *Journal of Royal Statistical Society(B)*, 1986, **48**(3): 259-302.

An EM-MAP-HMRF Multi-sensor Image Fusion Algorithm Based on Non-homogeneous Class and Direction

HE Gui-qing, PENG Jin-ye, HAO Chong-yang

(*Institute of Electronic & Information Engineering, Northwestern Polytechnical University, Xi'an 710072, China*)

Abstract: In order to improve the target identification, Markov random field (MRF) is introduced in the target fusion process to build prior probability model of a class. Then aiming at selecting model parameter β , an EM-MAP-HMRF feature-level fusion algorithm is proposed based on non-homogeneous class and direction. HMRF is divided into centric and distributed-based fusion schemes. The simulations show that the two new fusion algorithms can improve the classification accuracy, and enhance the ability to anti-interference. However, they have different advantages. The two new schemes can be used in various fusion systems for different applications and improve the effectiveness of detection and identification for specific targets.

Key words: Image fusion; Markov random field; EM algorithm; Non-homogeneous class and direction; Centric fusion; Distributed fusion



HE Gui-qing was born in 1977. She works as a lecturer and Ph. D. degree candidate, and her research interests focus on image processing, data fusion and pattern recognition.