

一种基于 HMRF 模型的无监督图像分割算法

朱国普, 曾庆双, 屈彦呈, 王常虹, 沈博昌

(哈尔滨工业大学空间控制与惯性技术研究中心, 黑龙江哈尔滨, 150001)

摘 要: 研究了基于隐马尔可夫随机场 (HMRF) 模型的无监督图像分割问题. 对于每一阶模型的图像分割, 该算法充分利用了相邻模型之间的相关信息, 由此, 该算法克服了均值场算法对初始化条件要求非常苛刻的缺点. 而且, 针对无监督图像分割的模型选择问题提出了带惩罚项的误差平方和阶次判定准则. 实验结果证实本文提出的阶次判定准则优于伪似然信息准则 (PLIC), 并且, 该算法具有满意的分割结果.

关键词: 图像分割; HMRF 模型; 均值场算法; 模型选择

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2006) 02-0374-06

An Unsupervised Image Segmentation Algorithm Based on HMRF Model

ZHU Guo-pu, ZENG Qing-shuang, QU Yan-cheng, WANG Chang-hong, SHENG Bo-chang

(Space Control and Inertial Technology Research Center, Harbin Institute of Technology, Harbin, Heilongjiang 150001, China)

Abstract This paper presents a novel unsupervised image segmentation algorithm based on hidden Markov random field (HMRF) model. For each order model segmentation, the proposed algorithm makes use of the correlated information between adjacent models. Therefore, the algorithm avoids the drawback about that mean field algorithm is restricted by initial condition. Furthermore, in order to solve the model selection problems of unsupervised image segmentation, the sum of squared error criterion with penalty term is proposed. The experiment results testify that the proposed criterion is superior to the Pseudo-likelihood Information Criterion (PLIC), and it is shown that the performance of the segmentation is satisfied.

Key words HMRF model; image segmentation; mean field algorithm; model selection

1 引言

图像分割是计算机视觉研究的重要领域之一, 分割结果直接决定了高层视觉的处理效果. 在上世纪 70 年代末源于统计力学的马尔可夫随机场 (Markov random field, MRF) 理论开始应用于图像处理领域. MRF 通过描述图像相邻像素之间的相互关系, 有效地表达了图像的上下文信息. 自 1984 年以来, 在 S. Geman 和 D. Geman 所做的奠基性工作^[1]之上, 在图像处理领域中许多研究者开始不断地改进或者提出新的基于 HMRF 模型的图像分割算法, 其中代表性的文章有文献 [2, 3]. 近年来随着该领域研究的不断深入, 人们开始了基于 HMRF 模型的无监督图像分割算法的研究, 即模型选择问题的研究^[4-7]. 无监督图像分割算法的研究是基于 HMRF 模型的图像分割理论发展的必然趋势, 它使得这一分割理论更加体系化, 然而, 该算法的研究尚在初期阶段, 理论还不成熟. 本文进一步研究了基于 HMRF 模型的无监督图像分割问题, 首先, 提出了新的

分割算法, 新算法从最高阶次的模型开始分析, 通过从高阶模型向低阶模型传递初始化信息, 新算法克服了均值场算法对初始化条件要求非常苛刻的缺点, 实验结果证实新算法具有满意的分割结果. 其次, 针对模型选择问题提出了新的阶次判定准则, 其判定结果不受图像大小的影响, 实验结果证实新的准则优于 PLC 准则.

2 HMRF 模型

在图像分割中 HMRF 模型包含两个关键变量: 图像像素的灰度值 $Y = \{Y_i, i \in S\}$ 和对各像素所属分割区域进行标记的变量 $X = \{X_i, i \in S\}$, 其中 S 为二阶网格, i 表示网格 S 上的坐标. 不妨设图像具有 K 个分割区域, 则令集合 $L = \{l_1, l_2, \dots, l_k\}$ 为 X_i 的值域, 其中 l_k 表示第 k 个元素为 1, 其余元素皆为 0 的 K 维向量. 这里假设标记变量 X 服从离散的 MRF 分布, 则对标记变量 X 在其值域上的任一取值 x 有

$$P(x) = \frac{1}{Z} \exp\{-U(x, \beta)\} \quad (1)$$

收稿日期: 2004-07-16 修回日期: 2005-11-15

其中, $Z = \sum \exp\{-U(x, \beta)\}$ 是归一化因子, $U(x, \beta)$ 为依赖于参数 β 的能量函数; 再进一步假设可观测数据 Y 在 $X = x$ 条件下相互独立, 记 y 为变量 Y 在值域中的取值, 则其联合条件概率分布 $p(y | x)$ 为

$$p(y | x, \theta) = \prod_{i \in S} p(y_i | x_i, \theta) = \exp\left\{\sum_{i \in S} \lg p(y_i | x_i, \theta)\right\} \quad (2)$$

其中, 通常规定 $p(y_i | x_i, \theta)$ 服从高斯分布, θ 表示参数. 联合式 (1) 和式 (2), 我们建立了图像分割的 HMRF 模型.

3 均值场算法

均值场算法^[3,8,9]是一种应用广泛的基于 HMRF 模型的图像分割算法. 该算法在进行图像分割之前, 首先要设定分割区域的数目. 由于图像分割区域的数目对应于模型的阶次, 即 K 阶模型描述具有 K 个分割区域的图像, 因此, 均值场算法可被视为基于固定阶模型的图像分割算法.

基于 HMRF 模型的图像分割的最终任务是估计变量 X . 均值场算法的原理是利用 EM 算法^[10]迭代地估计 HMRF 模型的参数 $\phi = (\theta, \beta)$, 同时应用均值场理论解决参数估计过程中马尔可夫边缘场及条件场的计算问题, 最后, 在参数估计收敛时通过最大后验概率 (maximum a posteriori MAP) 估计恢复标记变量 X . 下面简要地介绍一下均值场算法.

首先, 对模型的进行参数估计. 模型的参数估计是一个迭代的过程, 每次迭代包括下面两个步骤, 其中 t 表示迭代次数.

(1) 应用均值场原理计算 MRF 均值: $\forall i \in S$, 有

$$\tilde{x}_i^{(t)} = \sum_{x_i} x_i P_{x_i}^{(t)}(x_i | y_i, \phi^{(t-1)}) \quad (3)$$

(2) 利用 EM 算法估计参数:

E 步: 计算条件概率: $\forall i \in S$, 有

$$P_{x_i}^{(t)}(x_i | y_i, \phi^{(t)}) = \frac{p(y_i | x_i, \theta^{(t-1)}) P_{x_i}^{(t-1)}(x_i | \beta^{(t-1)})}{\sum_{x_i} p(y_i | x_i, \theta^{(t-1)}) P_{x_i}^{(t-1)}(x_i | \beta^{(t-1)})} \quad (4)$$

M 步: 计算参数:

$$\theta^{(t)} = \arg \max_{\theta} \sum_{i \in S} \sum_{x_i} P_{x_i}^{(t-1)}(x_i | y_i, \phi^{(t-1)}) \log\{p(y_i | x_i, \theta)\} \quad (5)$$

$$\beta^{(t)} = \arg \max_{\beta} \sum_{i \in S} \sum_{x_i} P_{x_i}^{(t-1)}(x_i | y_i, \phi^{(t-1)}) \lg\{P_{x_i}^{(t-1)}(x_i | \beta)\} \quad (6)$$

然后, 在参数收敛时通过 MAP 估计恢复不可观测数据 X . 令 \hat{x} 为标记变量 X 的估计值, 则有

$$\hat{x}_i = \arg \max_x P_{x_i}^{(t-1)}(x_i | y_i, \phi), \forall i \in S \quad (7)$$

以上简要地介绍了均值场算法, 算法的具体内容可参看文献 [9].

4 HMRF 模型的阶次判定准则

均值场算法是基于固定阶模型的图像分割算法, 但在实际应用中图像的模型阶次是不确定的, 即图像分割区域的数目是未知的. 因此, 图像分割算法需要在图像分割过程中应用模型阶次判定准则来估计模型阶次.

目前, 在基于 HMRF 模型的图像分割领域中, PLIC 准则^[11,12]的提出引起了该领域研究者的关注, PLIC 准则是 BC (Bayesian information criterion) 准则的一种近似的形式, 在计算上相对容易实现. PLIC 准则的准则函数的表达式为

$$PLIC(\phi_k, K) = -\lg p_{x_i}^{(K)}(y | \phi_k) + 1/K \lg N \quad (8)$$

其中, ϕ_k 是模型阶次为 K 时的参数估计值, K' 为 K 阶模型中自由参数的个数, N 为图像中像素的个数. PLIC 准则规定使其准则函数达到最小值时的 K 值是模型的最佳阶次.

PLIC 准则函数的第一项为负对数似然函数, 第二项为惩罚项, 其作用是在各阶次模型负对数似然函数值相近的情况下使准则函数尽可能得选择阶次较小的模型. 但文献 [6] 指出负对数似然函数在准则函数中起主导作用, 其值往往偏大, 导致惩罚项的作用基本可以忽略, 因此判定的结果很可能接受阶次较高的模型. 实验进一步表明图像越大 (即图像的像素数目越多) 时, 负对数似然函数在准则函数中的主导作用越明显.

基于上述原因, 本文提出带惩罚项的误差平方和准则. 该准则借鉴于一种聚类问题的阶次判定准则^[11]. 首先, 考虑聚类问题, 其误差平方和函数是样本类别数 K 的单调递减函数. 如果给定的样本能形成 K 个分得很开的类, 即类内散度值很大, 而类间散度值很小, 则误差平方和函数值会随着 K 的增加而迅速减少, 直至 $K = K^*$ 时下降速度变得缓慢, 根据这个特征可以确定样本的类别数目.

相应地, 上述特征可以应用于基于 HMRF 模型的图像分割的阶次判定. 定义类条件概率

$$P(k | y, \phi_k) = \left\{ \sum_{i \in S} P_{x_i}^{(k)}(x_i = l_k^i | y_i, \phi_k) \right\} N \quad (9)$$

其中, K 为模型阶次, l_k^i 是 X_i 在值域 $L_k = \{l_1^k, \dots, l_k^k\}$ 中的取值, 同上, N 表示像素个数. $P(k | y, \phi_k)$ 表示被标记为 l_k^i 的像素数目 (第 k 个分割区域的面积) 与图像像素的总数目 (整个图像的面积) 的比值. 则, 带惩罚项的误差平方和准则的准则函数为

$$SSCE(y, \phi_k) = \sum_{k=1}^K P(k | y, \phi_k) \sigma_{k,k} + \lambda K \quad (10)$$

其中, λ 为惩罚项系数, $\sigma_{k,k}$ 表示在第阶模型中高斯分布函数 $p(y_i | x_i = l_k^i, \phi_k)$ 的方差估计, 也可以理解为在第个分割区域中像素灰度值的方差. 同样, 该准则规定使准则函数达到最小值时的 K 值是模型的最佳阶次. 准则函数的第一项类似于聚类中的误差平方和函数, 第二项为惩罚项, 其作用与 PLIC 准则函数中的惩罚项的作用是一致的, 但与像素个数无关. 系数 λ 根据经验确定, 但实验表明分割结果对的取值并不敏感, 具有较强的鲁棒性, 即一旦确定了 λ 该准则对一类大小不同的以及具有不同统计特征的图像实验均获得满意的结果.

5 基于 HMRF 模型的无监督图像分割算法

在基于 HMRF 模型的图像分割中, 含有模型阶次判定

的分割算法被称为无监督图像分割算法. 文献 [4, 5] 和 [10] 提了基于 HMRF 模型的无监督图像分割算法, 其算法步骤比较简单, 首先, 确定模型的备选阶次, 然后, 在这个范围内对每一阶的模型独立地进行初始化和参数估计, 最后, 根据阶次判定准则选出最佳阶次. 显然, 这种算法没有利用各阶次模型之间的相关信息. 而且, 均值场算法是个局部优化的算法, 该算法对初始化条件要求比较苛刻, 如果初始值选择不当, 会很大程度上影响分割的结果. 通常, 均值场算法的初始化过程采用聚类的方式^[3, 9], 而聚类算法本身就存在初始化问题, 如需要事先主观地设定聚类的初始均值和方差. 因此, 基于聚类的初始化方式不适宜解决具有高阶模型以及复杂统计特性的图像的分割问题.

受一种聚类算法^[12]的启发, 在基于 HMRF 模型的无监督图像分割过程中, 本文提出了一种新的算法对各阶次的备选模型进行初始化. 该算法从备选模型中最高阶次的模型开始分析, 模型阶次依次降低, 直到降至最低阶次的模型. 除了最高阶次的模型以外, 每一阶模型的初始化都充分利用了上一阶模型的分析结果. 下面介绍在备选模型中一般阶次模型的初始化过程 (最高阶次模型的初始化过程, 即整个算法的初始化过程, 将在下一节中介绍).

由于图像分割区域的数目对应于模型的阶次, 因此, 每降低一个模型阶次对应于减少一个分割区域. 依据这个原理, 模型的初始化过程包括两个步骤:

首先, 在当前模型中依据某种标准选择即将移出的区域. 新算法规定图像分割会在模型参数估计过程中或模型参数收敛后两种情况下, 由当前第 K 阶模型降至第 $K-1$ 阶模型, 并由第 K 阶模型的分割信息初始化第 $K-1$ 阶模型. 新算法在这两种情况下将采用不同的方式选择即将移出的区域. 在第一种情况下, 即模型参数估计过程中, 当上述定义的条件概率 $P(k|y, \phi_k)$ 的值足够小时, 则假定移出第 k 个区域不影响最终的分割结果. 定义

$$a_k = P(k|y, \phi_k) - \alpha K, k = 1, \dots, K \quad (11)$$

其中, (αK) 为衡量类条件概率是否足够小的阈值, α 为阈值系数, 其值由实验确定. 图像的平均分割区域的大小将随模型阶次的增加而递减, 因此, 在式 (11) 中设定阈值随着模型阶次的增加而递减. 当 $a_k \leq 0$ 时, 则认为类条件概率 $P(k|y, \phi_k)$ 足够的小, 第 k 个区域为即将移出的区域. 并且在该情况下, 当前第 K 阶模型不参与阶次判定. 在第二种情况下, 即参数估计收敛, 当前第 K 阶模型分析结束, 根据

$$k = \arg \min_{j \in \{1, \dots, k\}} \{P(j|y, \phi_k)\} \quad (12)$$

选择第 k 个区域 (即面积最小的分割区域) 为即将移出的区域.

然后, 把选出的第 k 个区域的信息分配给特性上相近的区域, 并从当前 K 阶模型中移出第 k 个区域, 随后利用余下 $K-1$ 个区域的信息去初始化 $K-1$ 阶模型. 在基于 HMRF 模型的图像分割中, 条件概率 $P_{\tilde{x}}(j|y, \phi_k)$ 是关键的

信息, 条件概率既能通过式 (5) 和式 (6) 估计出参数, 又能由式 (7) 获得最终分割结果. 因此, 不同于聚类算法, 新算法在初始化过程中利用信息的不是参数^[12] 而是条件概率. 下面进一步阐述初始化的第二个步骤, 首先, 第 $k+1$ 与第 $k-1$ 个区域是被选出的第 k 个区域的相邻区域, 比较这两个区域的条件概率的大小, 把第 k 个区域的条件概率值加到条件概率大的相邻区域中, 然后, 去除第 k 个区域, 最后, 把余下 $K-1$ 个区域的条件概率值作为初值赋给第 $k-1$ 阶模型的条件概率. 这里把初始化第 $k-1$ 阶模型的条件概率 $P_{\tilde{x}}(j|y, \phi_k)$ 的过程表示为 'Initialize $P_{\tilde{x}}(j|y, \phi_k)$ '. 为了更清楚的表述上述初始化过程, 附录里以伪代码形式描述了该过程.

以上讨论了基于 HMRF 模型的无监督图像分割算法的一些关键问题, 图 1 以伪代码的形式描述了整个算法. 其中, K_{max} 和 K_{min} 分别表示备选模型的最高和最低阶次, 参数 λ 和 α 的意义同上, ε 为算法迭代停止的控制参数, $SSEC(t)$ 表示第 t 次迭代时带惩罚项的误差平方和准则的函数值. 这里需要指出, 在图像分割中标记变量 X 一般要通过简单的变换以图像的形式来表示分割结果.

```

输入: 图像 Y, 控制参数  $K_{max}, K_{min}, \lambda, \alpha, \varepsilon$ 
 $t \leftarrow 0, SSEC(0) \leftarrow 0$ 
输出: 标记变量 X
初始化条件概率  $P_{\tilde{x}}(x|y, \phi^{K_{min}})$ 
for  $K = K_{max}$  to  $K_{min}$ 
do
 $t = t + 1$ 
 $a_k = P(k|y, \phi_k^{(t)}) - \alpha K, 1 < k < K$ 
for  $k = 1$  to  $K$ 
if  $a_k \leq 0$ 
Initialize( $P_{\tilde{x}}(x|y, \phi_k^{(t)}), k$ )
 $K = K - 1$ 
 $k = k - 1$ 
end if
end for
计算参数  $\phi_k^{(t)}$  (根据式 (5) 和式 (6))
计算条件概率  $P_{\tilde{x}}(x|y, \phi_k^{(t)})$  (根据式 (4))
while ( $\|SSEC(t) - SSEC(t-1)\| > \varepsilon \cdot SSEC(t)$ )
if  $K > K_{max}$ 
 $k = \arg \min_{j \in \{1, \dots, k\}} \{P(j|y, \phi_k^{(t)})\}, 1 < k < K$ 
Initialize( $P_{\tilde{x}}(x|y, \phi_k^{(t)}), k$ )
 $K = K - 1$ 
end if
end for
估计标记 X (根据式 (7))

```

图 1 基于 HMRF 模型的无监督图像分割算法

6 实验与结果分析

为了验证该算法的有效性,下面分别对人工合成图像与真实图像进行实验.实验采用 Potts模型^[9]描述变量 X 的分布,其中参数 β 描述 $X_i (i \in S)$ 之间的相关程度.通过求解式(6)无法获得参数 β 的解析解,但 β 的变动对于图像分割的影响并不明显,按文献[8]的建议,实验中参数 β 的值预先设定在 1.0~3.0之间.通过求解式(5),在第 t 步迭代过程中参数 $Q = \{(\mu_{kk}, \sigma_{kk}) | 1 \leq k \leq K\}$ 的估计公式如下:

$$\mu_{kk}^{(t)} = \frac{\sum_{i \in S} P_{x^{(t-1)}}(x_i = k | y_i, \phi_k^{(t-1)}) y_i}{\sum_{i \in S} P_{x^{(t-1)}}(x_i = k | y_i, \phi_k^{(t-1)})} \quad (13)$$

$$\sigma_{kk}^{(t)} = \frac{\sum_{i \in S} P_{x^{(t-1)}}(x_i = k | y_i, \phi_k^{(t-1)}) (y_i - \mu_{kk}^{(t)})^2}{\sum_{i \in S} P_{x^{(t-1)}}(x_i = k | y_i, \phi_k^{(t-1)})} \quad (14)$$

在下列实验中,设定控制参数 $\varepsilon = 0.01, \alpha = 0.1, \lambda = 70$ 模型的最高阶次 $K_{max} = 16$ 最低阶次 $K_{min} = 2$ 实验中可观测数据 $Y_i (i \in S)$ 的灰度级范围为 $[0, 255]$, 将其等分为 16个区间,根据灰度值的大小从 1到 16依次编号.如果 y_i 属于第 k 个区间,则令

$$P_x(x_i = j | y_i, \phi_{16}) = \begin{cases} 1 & j = k \\ 0 & 1 \leq j \leq 16, j \neq k \end{cases}$$

然后,计算 $\tilde{x}^{(0)}$

$$\tilde{x}_i^{(0)} = \sum_x x_i P_x(x_i | y_i, \phi_{16}), \forall i \in S$$

按照上述方式进行模型最高阶次的初始化过程,即整个程序的初始化过程.

下面首先对区域数目分别为 2, 3, 4且被高斯噪声污染的人工合成图像进行实验.

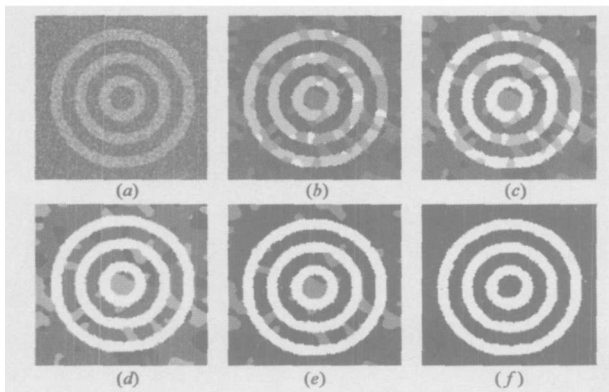


图 2 区域数目为 2 的人工合成图像的分割. (a)被噪声污染的图像; (b~f)分别为从 6阶模型至 2阶模型的分割图像

实验 1图 2(a)是被均值为 0和方差为 900的加性高斯噪声污染的图像,其大小为 122×122 (像素).在图 2中同时给出了从 6阶模型降至 2阶模型的分割过程中,图像在各阶次模型中的分割结果.将图 2中的各分割图像进行比较,可以发现相邻两图之间存在许多相似之处,这种现象体现了新算法进行信息传递的特征.根据带惩罚项的误

差平方和准则的阶次判定,图 2(f)是最终的分割结果.定义误差率为错分的图像像素个数与总的像素个数之比,该实验的误差率为 0.89%.

表 1给出在实验 1中参与阶次判定的各阶次模型的负对数似然函数值 $-\ln p_{\tilde{x}}(y | \phi_k)$ 、PLIC 准则函数值及带惩罚项的误差平方和准则函数值,在表中带惩罚项的误差平方和准则函数简称为‘SSEC 准则函数’.表格中底纹被填充的数据为各准则函数的最小值.

实验 2图 3(a)是被均值为零和方差为 900的加性高斯噪声污染的图像,其大小为 160×160 (像素).根据带惩罚项的误差平方和准则的阶次判定,图 3(b)是对图 3(a)进行分割的最终结果,误差率为 0.65%.

同上,表 2给出试验 2中准则函数的相关数据.




图 3 区域数目为 3 的人工合成图像的测试

实验 3图 4(a)是被均值为 0和方差为 400的加性高斯噪声污染的图像,其大小为 200×200 (像素).根据带惩罚项的误差平方和准则的阶次判定,图 4(b)是对图 4(a)进行分割的最终结果,误差率为 0.57%.




图 4 区域数目为 4 的人工合成图像的分割




图 5 狗肺的 PET 图像测试

同上,表 3 给出试验 3 中准则函数的有关数据.

实验 4 以上进行了三组人工合成图像的分割实验.为了显示该算法的实用性,这里给出一组真实图像的实验结果.图 5(a)是狗肺 PET 图像,其大小为 128×128 (像素).根据带惩罚项的误差平方和准则的阶次判定,图 5(b)是对图 5(a)进行分割的最终结果.

同上,表 3 给出试验 3 中准则函数的相关数据.

以上实验所给出的图表数据显示图像越大时负对数似然函数 $-\log_{\pi}(y | \phi_k)$ 在准则函数中的主导作用越突出,导致 PLC 准则基本上选择了阶次偏高的模型.而本文提出的带惩罚项的误差平方和准则不受图像大小的影响,三组人工合成图像的实验均得到了正确的结果,而且真实图像的实验亦得到了满意的结果.

表 1 试验 1 各阶次模型的准则函数值

函数	2(阶次)	3	4	5	6
负对数使然函数	69705.7	69704.5	69715.2	69689.0	69660.1
PLC 准则函数	69734.5	69747.7	69772.8	69761.1	69746.6
SSEC 准则函数	1025.41	1076.32	1128.98	1186.19	1244.40

表 2 试验 2 各阶次模型的准则函数值

函数	2(阶次)	3	4	5	6	7	8
负对数使然函数	126925	120316	120314	120272	120512	120496	120463
PLC 准则函数	126956	120361	120375	120348	120604	120603	120585
SSEC 准则函数	1810.2	1056.2	1119.0	1172.4	1244.2	1301.9	1357.6

表 3 试验 3 各阶次模型的准则函数值

函数	2(阶次)	3	4	5	6	7	8
负对数使然函数	196315	184034	173214	173157	173122	173058	172949
PLC 准则函数	196346	184082	173278	173237	173217	173170	173076
SSEC 准则函数	1495.4	893.96	653.53	715.30	776.39	836.67	895.94

表 4 试验 4 各阶次模型的准则函数值

函数	2(阶次)	3	4	5	6	7
负对数使然函数	61371	60121	59011	58243	5.7800	5.8210
PLC 准则函数	61400	60165	59069	58316	5.7887	5.8312
SSEC 准则函数	524.18	385.19	443.61	499.42	549.69	597.87

采用聚类的方式对各阶次的 HMRF 模型独立地进行初始化需要人为的设置一些聚类算法的参数,对于高阶模型,这些参数的设置比较困难,而且容易导致参数估计收敛到局部优化解.而本文提出的算法模型从最高阶次开始分析,阶次依次递减,每一阶次模型的分析都为下一阶次模型的分析提供适宜的初始化信息.实验验证这种初始化方式克服了均值场算法对初始化条件要求非常苛刻的缺

点,具有满意的分割结果.并且,算法避免了对某些无意义的模型阶次进行分析,从实验中可以看出实际参加阶次判定的模型数目要少于备选模型的数目,因此,减少了整个算法的计算量.

7 结论

本文提出一种新的基于 HMRF 模型的无监督图像分割算法,首先,该算法充分利用了各阶次模型之间的相关信息,使各阶次模型之间进行了信息传递,克服了均值场算法的初始化问题.其次,针对无监督图像分割的模型选择问题提出了带惩罚项的误差平方和准则.实验表明该算法具有令人满意的分割结果,并且本文提出的带惩罚项的误差平方和准则不受图像大小影响,具有良好的判定结果,实验证实该准则优于 PLC 准则.

附录:

图 6 给出模型初始化过程的伪代码描述.符号 'Initialize($P_{\tilde{x}}(x | y, \phi_k), k$)' 表示第 $K-1$ 阶模型的初始化过程,该过程对 $1 < k < K, k = 1$ 和 $k = K$ 三种情况分别进行了考虑.在不影响理解的情况下,图中多处用符号 $P(x | y)$ 表示条件概率函数 $P_{\tilde{x}}(x | y, \phi_k)$.

```

Initialize( $P_{\tilde{x}}(x | y, \phi_k), k$ ):
for  $i = 1$  to  $N$ 
  if  $1 < k < K$ 
    if  $P(x_i = \tilde{x}_{k+1}^k | y) > P(x_i = \tilde{x}_{k-1}^k | y)$ 
       $P(x_i = \tilde{x}_{k+1}^k | y) = P(x_i = \tilde{x}_{k+1}^k | y) + P(x_i = \tilde{x}_{k-1}^k | y)$ 
    else
       $P(x_i = \tilde{x}_{k-1}^k | y) = P(x_i = \tilde{x}_{k-1}^k | y) + P(x_i = \tilde{x}_k^k | y)$ 
    end if
  form  $m = 1$  to  $K - 1$ 
    if  $m < k$ 
       $P_{\tilde{x}}(x_i = \tilde{x}_{k+1}^k | y, \phi_k) = P_{\tilde{x}}(x_i = \tilde{x}_m^k | y, \phi_k)$ 
    else
       $P_{\tilde{x}}(x_i = \tilde{x}_{k+1}^k | y, \phi_k) = P_{\tilde{x}}(x_i = \tilde{x}_{m+1}^k | y, \phi_k)$ 
    end if
  end for
end for

```

图 6 图像的第 $K-1$ 模型的初始化过程

参考文献:

[1] S Geman, D Geman Stochastic relaxation, Gibbs distribution and the bayesian restoration of images[J]. IEEE Trans on Patten Analysis and Machine Intelligence, 1984 6 721- 741.

[2] J Besag On the statistical analysis of dirty picture[J]. J Royal Statistical Society, 1986 Series B, 48 259- 302.

[3] Jun Zhang The mean field theory in EM procedures for

- markov random fields[J]. IEEE Trans on Signal Processing 1992, 40: 2570-2583.
- [4] D Stanford, A Raftery. Approximate bayes factors for image segmentation: the pseudo likelihood information criterion (PLIC) [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2002, 24: 1517-1520.
- [5] F Forbes, N Peyrard. Hidden markov random field model selection criteria based on mean field-like approximations [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2003, 25: 1089-1100.
- [6] D Langan, J M odestino, J zhang. Cluster validation for unsupervised stochastic mode l based image segmentation [J]. IEEE Trans on Image Processing, 1998, 7: 180-195.
- [7] C D Elia, G Poggi, G Scapa. A Tree-structure markov random field model for bayesian image segmentation [J]. IEEE Trans on Image Processing, 2003, 12: 1259-1273.
- [8] Jun Zhang. The mean field theory in EM procedures for blind markov random field image restoration [J]. IEEE Trans on Image Processing, 1993, 2: 27-40.
- [9] G Celeux, F Forbes, N Peyrard. EM procedures using mean field-like approximations for markov mode l based image segmentation [J]. Pattern Recognition, 2003, 36: 131-144.
- [10] A Dempster, N Laird, D Rubin. Maximum likelihood estimation from incomplete data via the EM algorithm [J]. J Royal Statistical Society, 1977, Series B, 39: 1-38.
- [11] R O Duda, P E Hart, D G Strok. 李宏东, 等, 译. 模式分类 [M]. 北京: 北京电子工业出版社, 2003: 447-449.
- [12] M Figueiredo, A K Jain. Unsupervised learning of finite mixture models [J]. IEEE Trans Pattern Analysis and Machine Intelligence, 2002, 24: 381-396.

作者简介:



朱国普 男, 1979 年生于新疆石河子, 2002 年在吉林大学获得工学学士学位, 2004 年在哈尔滨工业大学获得工学硕士学位, 现为哈尔滨工业大学控制科学与工程系博士研究生, 主要研究方向为图像分割, 视频分割和视觉跟踪。

E-mail: zgp@hit.edu.cn



曾庆双 男, 1964 年生于吉林, 哈尔滨工业大学控制科学与工程系博士生导师, 主要研究方向为飞行器控制、惯性技术及视频监控。