

基于证据马尔可夫随机场模型的图像分割

张喆^{1,2}, 韩德强^{1,2†}, 杨艺^{3,4}

(1. 西安交通大学 智能网络与网络安全教育部重点实验室, 西安 710049; 2. 西安交通大学 电子与信息工程学院, 西安 710049; 3. 西安交通大学 机械振动与强度国家重点实验室, 西安 710049; 4. 西安交通大学 航天航空学院, 西安 710049)

摘要: 图像分割是计算机视觉中的经典问题,在许多领域都有重要应用. 由于图像信息存在不确定性,难以获得精确的分割结果,为应对图像分割中的不确定性问题,将证据理论这一不确定性建模与推理工具与马尔可夫随机场相结合,提出证据马尔可夫随机场(EMRF)模型,并基于此提出新的图像分割算法. EMRF 利用证据标号场描述像素标号的含混性,以证据距离描述相邻像素间的标号关系,利用条件迭代模型(ICM)算法进行优化. 实验结果表明,EMRF 相较于传统马尔可夫随机场、模糊马尔可夫随机场和传统的基于证据理论的方法,能获得更好的分割效果.

关键词: 图像分割; 证据理论; 证据马尔可夫随机场

中图分类号: TP273

文献标志码: A

Image segmentation based on evidential Markov random field model

ZHANG Zhe^{1,2}, HAN De-qiang^{1,2†}, YANG Yi^{3,4}

(1. Ministry of Education Key Lab for Intelligent Networks and Network Security, Xi'an Jiaotong University, Xi'an 710049, China; 2. School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 3. State Key Laboratory of Mechanical Vibration and Strength, Xi'an Jiaotong University, Xi'an 710049, China; 4. School of Aerospace, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Image segmentation is a classical problem in computer vision and has been widely used in many fields. Due to the uncertainty in images, it is difficult to obtain a precise segmentation result. To deal with the problem of the uncertainty encountered in the image segmentation, an evidential Markov random field(EMRF) model is designed, which combines the evidence theory, a powerful tool for modeling and reasoning uncertainty, with the Markov random field. Based on EMRF, a novel image segmentation algorithm is proposed. EMRF uses evidential label field to describe the ambiguity of labels and distance of evidence to describe the relationship between labels of the neighboring pixels. The iterated conditional modes(ICM) algorithm is used for optimization. Experimental results show that the proposed algorithm can provide a better segmentation result against traditional MRF, fuzzy MRF(FMRF) and traditional evidential approaches.

Keywords: image segmentation; evidence theory; evidential Markov random field

0 引言

图像分割是计算机视觉中一项基本却又具挑战性的问题^[1]. 分析和理解一幅图像时,通常关注有相似特征的特定区域,图像分割即是图像划分为具有各自不同相似特征区域的过程,是计算机视觉中阶、高阶处理的前提和基础. 图像分割广泛应用于遥感图像分析和医学图像分析等领域,如植被检测^[2]、核磁共振脑组织分析^[3]和基于遥感图像分割的飞行器

监测等^[4].

由于在界定图像边界、区域和纹理等图像特征时存在不确定性,在图像分割中准确地标记像素是一项具有挑战性的工作. 早期的方法包括阈值法^[5]、基于边缘的方法^[6]、基于区域的方法^[7]和混合方法^[8]等. 这些方法中像素被独立地进行分割判别,由于忽视了相邻像素间的相关性而无法获得满意的分割结果. 针对这一问题,马尔可夫随机场(MRF)模型应运

收稿日期: 2016-07-13; 修回日期: 2016-09-30.

基金项目: 国家 973 计划项目(2013CB329405); 国家自然科学基金项目(61573275, 61671370); 陕西省科技计划项目(2013KJXX-46); 中央高校基本科研业务费专项资金项目(xjj2016066, xjj2014122).

作者简介: 张喆(1991—),女,博士生,从事图像处理、不确定性推理的研究; 韩德强(1980—),男,教授,博士生导师,从事信息融合、模式分类等研究.

†通讯作者. E-mail: deqhan@mail.xjtu.edu.cn

而生,并引发广泛的关注^[9-11].然而,传统MRF在每步迭代过程中被视作一种硬分割方法,由于图像中噪声的影响和相邻区域在交界处的高度相似性,像素类别通常是含混的,无法明确地指出其分割归属,MRF在中间步骤中的硬分割易造成信息的丢失.为了避免在中间步骤出现硬分割,Salzenstein等^[12]提出模糊马尔可夫随机场(FMRF)模型,使用模糊隶属函数描述像素标号.该方法在某些情况中得到比传统MRF更好的分割结果.实际上,像素标号存在的不确定性更多地是含混性而非模糊性.Dempster-Shafer(D-S)证据理论^[13-14]正是处理含混性的有力的理论工具和方法,适用于描述图像分割过程中的不确定性.Bendjebbour等^[15]曾提出在马尔可夫随机场中使用D-S融合模型来分割多源图像,当只有一个证据源时,可看作是对单幅图像的分割.但是Bendjebbour使用证据理论是为了代替传统MRF方法中的贝叶斯框架,并非对分割中的含混性建模.迄今为止,虽然已提出许多分割方法,但仍较少有普遍适用的方法.

针对图像分割中的不确定性问题,本文首先利用证据理论对传统的基于概率框架的MRF进行改造,提出一种证据马尔可夫随机场(EMRF)模型.模型中提出证据标号场,使用证据距离定义标号场中的势函数,最终利用EMRF设计实现图像分割算法.实验结果表明,相较于传统的MRF、FMRF和基于证据理论的方法,所提出的方法分割效果更为理想.

1 图像分割与马尔可夫随机场

单色图像的分割算法通常基于像素强度的不连续性或相似性^[16].基于不连续性的方法(如基于边缘信息^[6]),根据强度的剧烈变化分割图像.基于相似性的方法(如阈值法^[5]和基于区域的方法^[7]),根据事先定义的标准将一幅图像分割为几个内部相似的区域.目前,基于统计模型的方法(事实上是基于相似性)引起了广泛关注,其中MRF模型是最具影响力的方法.

1.1 图像分割基础及传统MRF方法

图像分割的基本问题是将一幅图像 R 划分为几个子区域 R_1, R_2, \dots, R_n ,并满足以下条件^[16]:

- 1) $\bigcup_{i=1}^n R_i = R$;
- 2) R_i 是一个连通集, $i = 1, 2, \dots, n$;
- 3) $\forall i, j$, 若 $i \neq j$, 则满足 $R_i \cap R_j = \emptyset$;
- 4) $Q(R_i) = \text{TRUE}$, $i = 1, 2, \dots, n$, 即分割子区域 R_i 中的像素应满足预定义的逻辑属性 Q ;
- 5) 对于任何相邻区域 R_i 和 R_j , 满足 $Q(R_i \cup R_j) = \text{FALSE}$, 即相邻分割子区域不应满足同一逻辑属

性 Q .

通常, Q 是一个复合表达式, 若 R_i 中像素灰度的平均值小于 μ_i 且标准差大于 σ_i , 则 $Q(R_i) = \text{TRUE}$. 考虑一幅 $N \times M$ 的图像, 被分割为 l 个区域, 图像的像素集为 $S = \{(i, j) | 1 \leq i \leq N, 1 \leq j \leq M\}$. MRF模型中, 通常用两个随机场描述图像, 一个是标号场 $X = \{x_s | s \in S\}$, $x_s \in \{1, 2, \dots, l\}$, 用先验分布描述像素局部相关性; 另一个是观测场 $Y = \{y_s | s \in S\}$, 用条件分布函数描述观测数据的分布.

设 $\Omega = \{x = (x_1, x_2, \dots, x_{MN})\}$ 是所有可能分割的集合, 邻域系统 $\delta = \{\delta(s) | s \in S\}$ 满足以下特性:

- 1) $\delta(s) \subset S$;
- 2) $s \notin \delta(s)$;
- 3) $\forall s, r \in S, s \in \delta(r) \Leftrightarrow r \in \delta(s)$.

若子集 $c \subseteq S$ 中的每对元素均满足特性3), 则称 c 为一个基团. 常见的邻域类型有四近邻和八近邻, 图1给出了这两种邻域类型(中心像素为目标像素, 周围像素为其邻域像素)及其相应的基团示意图.

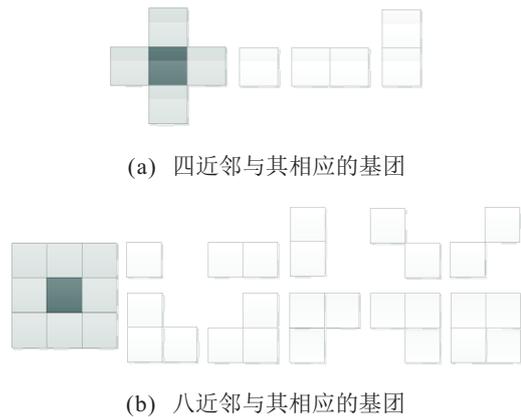


图1 两种邻域类型及其相应的基团

一个随机场 X 称作关于 δ 的MRF, 当且仅当 X 满足以下特性:

- 1) $P(X = x) > 0, \forall x \in \Omega$;
- 2) $P(X_s = x_s | X_r = x_r, \forall r \neq s) = P(X_s = x_s | X_r = x_r, \forall r \in \delta(s))$.

根据特性2), 像素标号之间的相关性取决于定义在 S 上的邻域系统 δ .

为了从观测场 Y 中估计最佳标号 \hat{x} , 根据贝叶斯法则, 可用最大后验概率(MAP)估计将图像分割问题转化为求解最大后验概率问题, 即

$$\hat{x} = \arg \max P_{X|Y}(x|y), \quad (1)$$

其中 $P_{X|Y}(x|y) = P_X(x)P_{Y|X}(y|x)/P_Y(y)$. 因为观测场给定, $P_Y(y)$ 为常数, 所以

$$P_{X|Y}(x|y) \propto P_X(x)P_{Y|X}(y|x),$$

且有

$$\hat{x} = \arg \max [P_X(x)P_{Y|X}(y|x)]. \quad (2)$$

由于标号场 X 是一个 MRF, 文献 [17] 证明了 MRF 和 Gibbs 分布的等价性, 标号场的先验分布 $P_X(x)$ 可以由 Gibbs 分布表示为

$$P_X(x) = Z^{-1}[\exp(-U_1(x)/T)]. \quad (3)$$

其中: $Z = \sum_x [\exp(-U_1(x)/T)]$ 为归一化常数; T 为常数; $U_1(x) = \sum_{c \in C} V_c(x)$ 为定义在 δ 中基团上的先验能量函数, C 为基团的集合, $V_c(\cdot)$ 为定义在基团 c 上的势能函数. 常用的标号场模型有 Ising 模型、Potts 模型和 MLL 模型, 这里介绍 Potts 模型的势能函数, 有

$$V_{\{s,t\}}(x) = \begin{cases} 0, & x_s = x_t; \\ \beta, & x_s \neq x_t. \end{cases} \quad (4)$$

其中 β 为一个正参数. 标号场中标号相同的基团越多, 先验能量 $U_1(x)$ 越小.

对于观测场模型, 通常利用高斯函数描述图像的灰度属性, 假设每一种标号 x_s ($x_s \in \{1, 2, \dots, l\}$) 的像素灰度值服从均值为 μ_{x_s} 、标准差为 σ_{x_s} 的高斯分布

$$P(y_s|x_s) = \frac{1}{\sqrt{2\pi}\sigma_{x_s}} \exp\left\{-\frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2}\right\}. \quad (5)$$

假设各像素的观测随机变量分布在给定标号场 x 下相互独立, 似然函数 $P_{Y|X}(y|x) = \prod_{s \in S} P(y_s|x_s)$, 则似然能量函数 $U_2(x, y) = -\ln(P_{Y|X}(y|x))$ 表示为

$$U_2(x, y) = \sum_{s \in S} \left(\ln(\sqrt{2\pi}\sigma_{x_s}) + \frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2} \right). \quad (6)$$

对式(2)两边取对数, 有

$$\ln \hat{x} = \arg \max [-U_1(x)/T - \ln Z - U_2(x, y)]. \quad (7)$$

估计最佳标号场 \hat{x} 的问题最终转化为求最小全局能量 $U(x, y)$ 对应的标号场问题, 即

$$\begin{aligned} \hat{x} &= \arg \min U(x, y) = \\ & \arg \min [U_1(x) + U_2(x, y)]. \end{aligned} \quad (8)$$

能量函数通常是非凸的, 求解易出现局部极值问题. 常用的算法有 ICM(iterated conditional model) 算法^[17] 和 SA(simulated annealing) 算法^[18].

1.2 模糊MRF图像分割方法

图像在获取、传输和存储等过程中易引入噪声, 且相邻区域在交界处具有高度相似性, 很难清晰地判断区域边界附近像素的标号, 这些不确定性使得准确标记像素极具挑战性. 通常, 基于 MRF 的图像分割方法以迭代的方式实现, 在迭代过程中, 每个像素被赋

予一个硬标号, 因此 MRF 在实现过程中为硬判决, 可能造成信息的损失.

Pieczynski 将模糊理论与 MRF 方法相结合提出模糊 MRF(FMRF) 图像分割方法^[12], 试图减小 MRF 方法在迭代过程中因硬判决造成的影响. FMRF 方法的实现步骤简要概述如下.

Step 1: 初始化硬标号场;

Step 2: 估计观测场参数(每种硬标号下像素的灰度均值 u_i 和标准差 σ_i);

Step 3: 将硬标号场模糊化, 通过优化算法更新模糊标号场;

Step 4: 由最大隶属度准则对每个像素进行硬标记;

Step 5: 重复 Step 2 ~ Step 4 直到收敛.

在 Step 3 中, 通过给每个标号赋予一个向量 $x_s = (x_{s1}, x_{s2}, \dots, x_{sl}) \in [0, 1]^l$ 来实现模糊化. 其中: $(x_{s1} + x_{s2} + \dots + x_{sl}) = 1$, x_{si} 表示像素 s 属于硬标号类别 i 的隶属度. 因此, 定义在模糊标号场上的势能函数 $V_{\{s,t\}}(x)$ 可表示为像素间模糊标号的欧氏距离

$$V_{\{s,t\}}(x) = \beta \|x_s - x_t\|. \quad (9)$$

FMRF 假设每种硬标号类别的像素灰度服从高斯分布, 概率密度函数 $P(y_s|x_s)$ 根据硬标号类别的分布与其在模糊标号 x_s 上相应隶属度求得, 即

$$\begin{aligned} P_{Y|X}(y_s|x_s) &= \\ & \frac{1}{\sqrt{2\pi}\sqrt{x_{s1}\sigma_1^2 + \dots + x_{sl}\sigma_l^2}} e^{\left\{-\frac{[y_s - (x_{s1}u_1 + \dots + x_{sl}u_l)]^2}{2(x_{s1}\sigma_1^2 + \dots + x_{sl}\sigma_l^2)}\right\}}, \end{aligned} \quad (10)$$

其中 u_i 和 σ_i 分别为 Step 2 估计出的均值和标准差.

图像分割中的不确定性本质上是含混性(Ambiguity)问题(无法明确像素属于哪个单类团), 而不完全是模糊问题(明确定义的缺失), 因此引入处理含混性问题的理论与方法会更合理有效, 证据理论正是处理应对含混性问题的强力工具.

2 基于证据理论和MRF的图像分割方法

Dempster-Shafer 证据理论^[13-14] 也称作信度函数理论, 是对不完全信息和含混信息建模与推理的理论框架. 本节利用证据理论提出证据 MFR(EMRF) 模型, 并基于该模型提出一种新的图像分割方法. 首先, 简要回顾证据理论的基本概念.

2.1 证据理论基础

在证据理论中, 辨识框架(FOD) Θ 中的元素是互斥且完备的. 2^Θ 表示 FOD 的幂集, 将从 2^Θ 映射到 $[0, 1]$ 的函数 m 定义为一个基本置信分配(BBA, 也称

作 mass 函数), 满足

$$\sum_{A \subseteq \Theta} m(A) = 1, m(\emptyset) = 0. \quad (11)$$

若 $m(A) > 0$, 则 A 称作一个焦点. 当 A 的势为 1 时, A 为一个单点焦点; 当 A 的势大于 1 时, A 称作混合焦点. 似真函数 (Pl) 和信任函数 (Bel) 分别定义为

$$Pl(A) = \sum_{A \cap B \neq \emptyset} m(B), \quad (12)$$

$$Bel(A) = \sum_{B \subseteq A} m(B). \quad (13)$$

Dempster 组合规则^[14]为

$$m(A) = \begin{cases} 0, & A = \emptyset; \\ \frac{1}{1-K} \sum_{B \cap C = A} m_1(B)m_2(C), & A \neq \emptyset. \end{cases} \quad (14)$$

其中 $K = \sum_{B \cap C = \emptyset} m_1(B)m_2(C)$ 表示冲突.

证据距离用来描述两个 BBA 的相似度, 最常用的是 Jousselme 定义的距离^[19], 即

$$d_J(m_i, m_j) = \sqrt{0.5(m_i - m_j)D(m_i - m_j)}, \quad (15)$$

其中 m_i 和 m_j 是两个定义在 Θ 上的 BBA. 当 Θ 中元素个数为 n 时, Jaccard 矩阵 D 是一个 $2^n \times 2^n$ 的矩阵, 元素 D 定义为 $D(A, B) = |A \cap B|/|A \cup B|$, 其中 $|\cdot|$ 表示势. 两个证据越接近, 距离 $d_J(m_i, m_j)$ 越小.

为将证据转化为概率以实现进一步的单点决策, Smets 定义了 pignistic 概率转化, 将 mass 函数转化为概率测度 BetP, 即

$$BetP(\theta) \triangleq \sum_{\theta \in A} \frac{m(A)}{|A|}, \forall \theta \in \Theta, \quad (16)$$

其中 $|A|$ 表示 A 的势.

Bendjebbour 曾提出一种基于证据理论的图像分割方法^[15], 分别针对标号场和观测场构造证据体 M_0^B, M_y^B . 利用证据组合 $M^B[x] = M_0^B \oplus M_y^B[x] \propto \sum_{a \cap b = x} (M_0^B[a] \oplus M_y^B[b])$ 代替传统 MRF 方法中的贝叶斯框架, 其中 x, a, b 都是标号场 $X = \{x_s | x_s \in 2^\Theta, s \in S\}$ 的实现, 即包含含混类的硬标号场, $[a \cap b = x] \Leftrightarrow [\forall s \in S, a_s \cap b_s = x_s]$. 在具体实现时, Bendjebbour 为便于算法实现没有考虑含混类别的先验知识, 其标号场完全等同于传统 MRF 方法的硬标号场, 因此无法解决像素标号的含混性这一更本质的图像分割不确定性问题.

2.2 证据 MRF 图像分割方法

为了更好地解决像素标号的含混性, 以更细致、准确地描述相邻像素的标号关系, 本文基于证据理论

提出证据 MRF (EMRF) 标号场模型, 并在贝叶斯框架的基础上, 提出一种新的图像分割方法.

2.2.1 证据标号场和先验模型

考虑到图像分割中的不确定性本质上是含混性, 在 EMRF 中, 定义证据标号场 $M = \{m_s | s \in S\}$, 对应于 MRF 模型中的 X . 像素 s 的标号为一个定义在辨识框架 $\Theta = \{\theta_1, \theta_2, \dots, \theta_l\} (1 < l < MN)$ 上的证据随机集, 即向量表示的 BBA: $m_s = (m_{s1}, \dots, m_{sr})$, $r = 2^l$, 其中 $m_{sj} = m_s(A_j)$, $A_j \subseteq \Theta$. 当 A_j 为混合焦点 (势大于 1) 时, m_{sj} 描述了无法明确像素属于 A_j 中哪个单类团的程度, 即标号的含混性.

当 $P(M = m) \geq 0$, 且像素 s 的证据标号只与 s 的邻域 $\delta(s)$ 有关时, 证据标号场为证据马尔可夫随机场. 先验分布 $P_M(m)$ 可由吉布斯分布表示为

$$P_M(m) = Z^{-1} [\exp(-U_1(m)/T)]. \quad (17)$$

其中: $Z = \sum_m [\exp(-U_1(m)/T)]$ 为归一化常数, T 为常数, $U_1(m) = \sum_{c \in C} V_c(m)$ 为定义在 δ 中基团的先验能量函数, C 为基团的集合, $V_c(\cdot)$ 为定义在基团 c 上的势能函数. 这里, 只考虑八邻域系统中的双点基团, 势能函数的定义为

$$V_{\{s,t\}}(m) = \beta \times d(m_s, m_t). \quad (18)$$

其中: β 为参数, $d(m_s, m_t)$ 为两像素对应证据标号的证据距离. 相比在硬标号场下定义势能函数时只考虑标号相同与否, EMRF 根据证据标号的相似度定义势能函数, 更细致、准确地描述了基团内像素的标号关系.

2.2.2 证据观测场分布

对于一幅给定的图像, 需要考虑选用什么样的函数去逼近像素标号与特征的联合分布. 如果所选函数能很好地逼近真实分布, 则有利于分割. 这里, 假设概率密度函数 $P(y_s | m_s)$ 服从高斯分布, 即

$$P(y_s | m_s) = \frac{1}{\sqrt{2\pi}\sigma_{m_s}} \exp \left\{ -\frac{(y_s - \mu_{m_s})^2}{2\sigma_{m_s}^2} \right\}, \quad (19)$$

其中 μ_{m_s} 和 σ_{m_s} 分别是标号为 $m_s = (m_{s1}, m_{s2}, \dots, m_{sr})$ 像素的灰度均值和标准差. 假设各像素的观测随机变量分布在给定标号场 m 下相互独立, 似然函数 $P_{Y|M}(y|m) = \prod_{s \in S} P(y_s | m_s)$, 则似然能量函数为

$$U_2(m, y) = \sum_{s \in S} \left(\ln(\sqrt{2\pi}\sigma_{m_s}) + \frac{(y_s - \mu_{m_s})^2}{2\sigma_{m_s}^2} \right). \quad (20)$$

2.2.3 基于EMRF模型的分割算法

与MRF方法相同,EMRF在贝叶斯框架内通过估计最大后验概率 $P_{M|Y}(m|y)$ 实现分割. 最大后验概率的估计可以转化为如下最小全局能量函数估计:

$$\hat{m} = \arg \min[U_1(m) + U_2(m, y)]. \quad (21)$$

式(18)中参数 β 实际上控制了全局能量中 U_1 与 U_2 之间的权重. 更注重邻域信息时, β 设定较大; 更注重特征信息时, β 设定较小.

为了获得最佳证据标号 \hat{m} , 采用一种简单易实现的ICM优化算法^[17]. 基于EMRF的图像分割算法步骤概述如下.

Step 1: 参考ECM算法^[20] 初始化信度划分的方法, 初始化EMRF的证据标号场;

Step 2: 对证据标号场中的BBA进行量化;

Step 3: 从Step 2生成的标号中选择一组证据标号类型用于更新标号场, 记作 $L = \{l_1, l_2, \dots, l_n\}$, 其中 n 表示有 n 种证据标号类型;

Step 4: 计算每一个像素在 L 中每种证据标号下的局部能量;

Step 5: 将每一个像素的证据标号更新为Step 4中局部能量最小的标号类型;

Step 6: 重复Step 4 ~ Step 5, 直到算法收敛或达到最大迭代次数;

Step 7: 将证据标号经Pignistic概率转化得到硬标号, 即将每个像素 i 标记为有最大 $\text{Bet}P_i(\{\theta_k\})$ 的类别 θ_k , 完成分割.

证据标号随机变量 $m_s = (m_{s1}, \dots, m_{sr})$ 中的元素 m_{sj} 是实数, 可以在 $[0, 1]$ 内任意取值. 算法在具体实现时, 这样的任意实数使算法无法实现, 因此, 在Step 2使 m_{sj} 量化到集合 $\{0, 0.2, 0.4, 0.6, 0.8, 1\}$ 中的值. 由于本文针对的分割问题不需要对噪声进行识别, 而事实上噪声像素不属于任何一个区域, EMRF在初始化证据标号场时, 噪声像素的BBA在空集分量上会被赋予较大的值, 将 m_{s1} 置为0, 而噪声像素标号会在更新时结合其邻域信息标记为最可能的类别. 当 $j \neq 1, r$ 时, 量化方法可以描述为

$$m_{sj} = \begin{cases} 0, & m_{sj} \in [0, 0.1); \\ 0.2, & m_{sj} \in [0.1, 0.3); \\ 0.4, & m_{sj} \in [0.3, 0.5); \\ 0.6, & m_{sj} \in [0.5, 0.7); \\ 0.8, & m_{sj} \in [0.7, 1]. \end{cases} \quad (22)$$

为满足BBA的归一性 $\sum_{i=1}^r m_{si} = 1$, 将 m_{sr} 量化为

$$m_{sr} = 1 - \sum_{i=1}^{r-1} m_{si}.$$

完成Step 6, 即迭代收敛或达到最大迭代次数后, 可得证据标号的最终迭代结果. 为了完成分割, 需要在Step 7中将证据标号通过概率转换的方式实现硬决策. 直观地, EMRF算法的流程Step 1 ~ Step 7如图2所示, 其中“迭代终止条件”即为Step 6中的“算法收敛或达到最大迭代次数”.

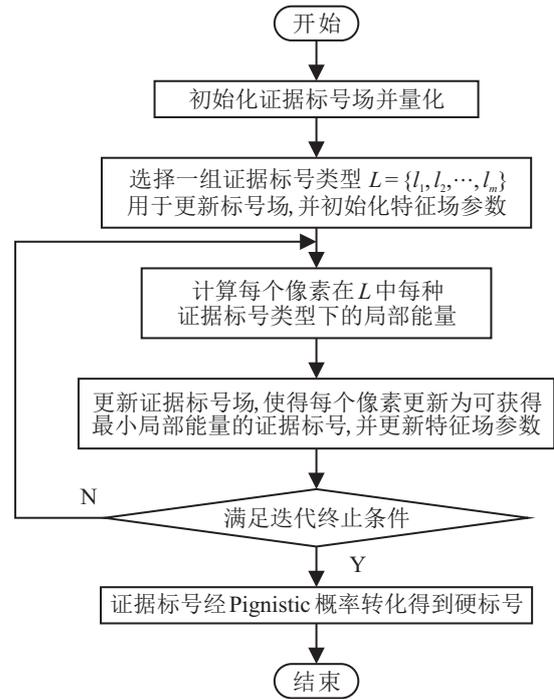


图2 EMRF算法流程

Step 2中, 可增加 m_{sj} 的量化阶数, 如将其量化到集合 $\{0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1\}$ 中的值, 随之生成的证据标号 m_s 类型增多, 即在Step 3中 n 值增大, 使得算法在执行Step 4时需要更多的运行时间. 在保证实验效果的前提下, 应优先考虑阶数较少的量化方法, 本文采用式(22)的量化方法.

3 实验结果

为验证EMRF算法更适用于解决图像分割中的不确定问题, 分别用MRF、FMRF、Bendjebbour和EMRF方法在5幅不同类型的图像上进行比较实验, 实验结果如图3 ~ 图7所示.

图3(a)、图4(a)和图5(a)是真实场景下的图像, 分别为人脑核磁共振图像、指纹图像和Circuit图像. 图6(a)和图7(a)为人工图像, 分别为加入强度为40的高斯噪声的Rice图像和模拟海冰特征的人工图像. 这4种分割算法都需要估计参数 β , 文献[21,12,15]分别对MRF、FMRF和Bendjebbour的模型中 β 的估计方法进行了讨论. 实验中, 针对算法比较时参数 β 的

选择问题,人工选取各算法的最优 β 值,即令 β 以0.1为增量进行实验,从中选取最优分割结果对应的 β 值.此外,为了定量地评估分割结果的质量,给出标准分割结果(标记真值),标记真值均由人工标定获得.算法的分割错误率可以通过逐一对比分割结果图像与标准分割图像的像素标号获得,表1给出了各算法在各实验图上的分割错误率.

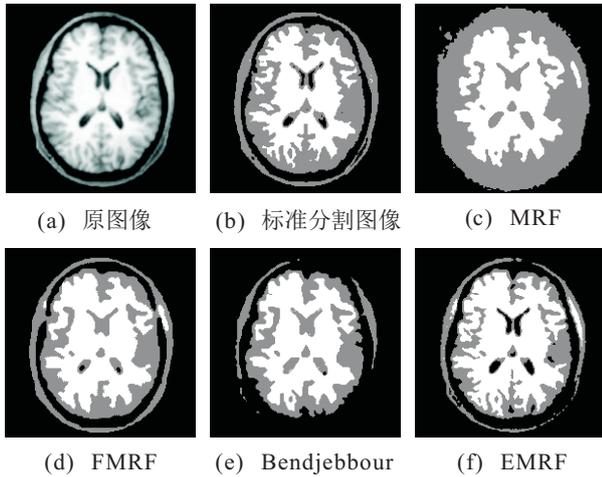


图3 人脑核磁共振图像的分割结果

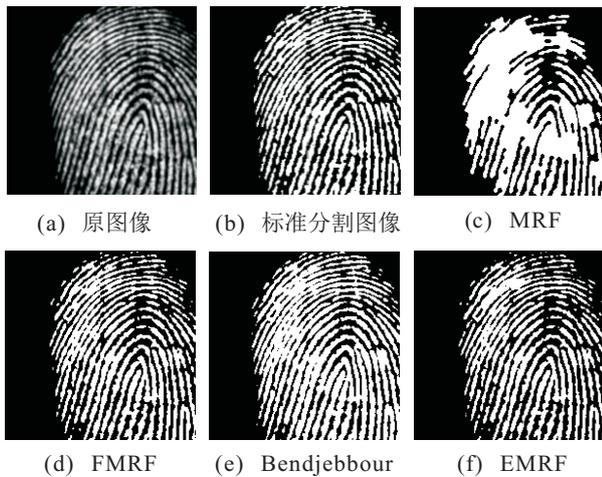


图4 指纹图像的分割结果

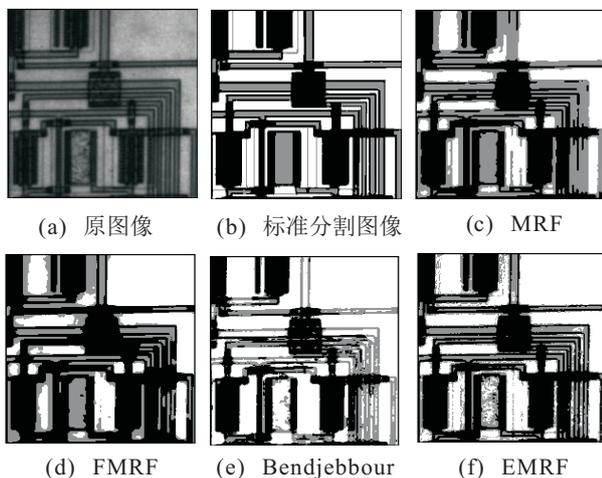


图5 Circuit图像的分割结果

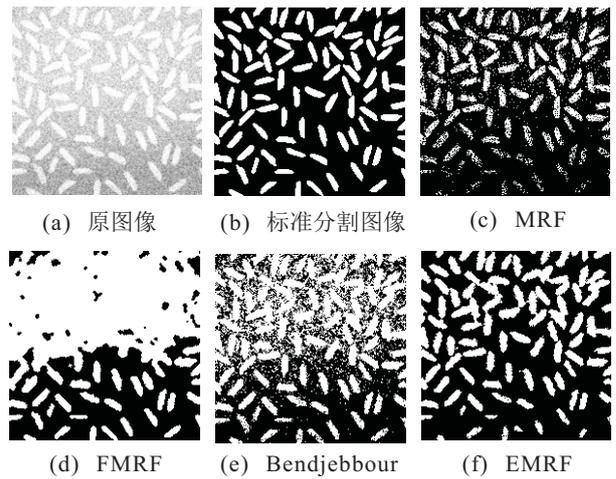


图6 添加高斯噪声的Rice图像的分割结果

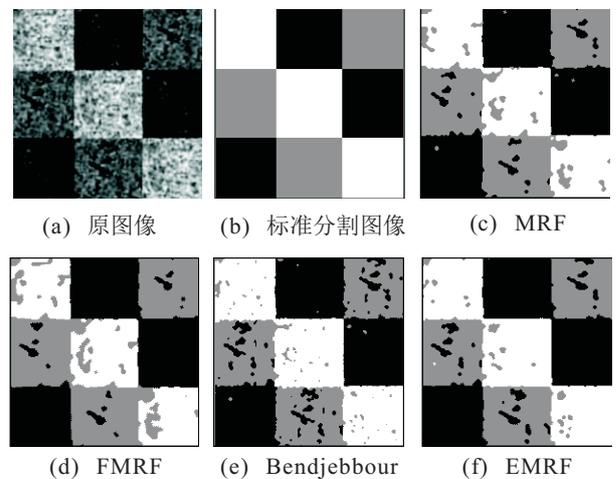


图7 模拟海冰特征人工图像的分割结果

表1 各算法在5幅实验图上的分割错误率 %

实验图	MRF	FMRF	Bendjebbour	EMRF
图3(a)	19.63	5.88	9.84	5.18
图4(a)	15.07	4.46	8.55	4.09
图5(a)	22.50	24.32	22.01	18.20
图6(a)	9.76	35.21	11.08	7.03
图7(a)	7.54	8.61	7.14	6.27

由图3 ~ 图7和表1可见,EMRF分割方法在表达图像细节和抗噪声能力方面均有良好表现.对比MRF、FMRF和Bendjebbour方法,EMRF方法在各实验图的分割结果中,不仅在视觉上更令人满意,其分割错误率也最低,这表明EMRF方法更适合解决图像分割中的不确定问题.

4 结论

本文以证据理论对图像分割问题中的含混性建模,结合MRF构造了证据MRF(EMRF)模型,并据此设计了新的图像分割方法.实验证明,对比本文中提到的其他方法,基于EMRF的分割结果不仅能更好地表达图像细节信息,而且能有效抑制噪声影响.

未来工作中,将关注EMRF方法所涉及的参数选取问题.研究中还将采用除Jousselme距离以外的其

他类型的证据距离进行实验比较. 同时, 将对 EMRF 模型进行更深入的理论分析, 并进一步改进本文所提出的图像分割方法.

参考文献(References)

- [1] Juang C F, Chang C M, Wu J R, et al. Computer vision-based human body segmentation and posture estimation[J]. *IEEE Trans on Systems, Man, and Cybernetics*, 2009, 39(1): 119-133.
- [2] Tian L F, Slaughter D C. Environmentally adaptive segmentation algorithm for outdoor image segmentation[J]. *Computers and Electronics in Agriculture*, 1998, 21(3): 153-168.
- [3] Zavaljevski A, Dhawan A P. Multi-level adaptive segmentation of multi-parameter MR brain images[J]. *Computerized Medical Imaging and Graphics*, 2002, 24(2): 87-98.
- [4] Baik S W, Ahn S M. Adaptive segmentation of remote-sensing image for aerial surveillance[J]. *Lecture Notes in Computer Science*, 2003, 2756: 549-554.
- [5] Sahoo P K, Soltani S, Wong A K C. A survey of thresholding techniques[J]. *Computer Vision, Graphics, and Image Processing*, 1988, 41(2): 233-260.
- [6] Basak J, Chanda B, Manjumder D. On edge and line linking with connectionist models[J]. *IEEE Trans Systems, Man, and Cybernet*, 1994, 24(3): 413-428.
- [7] Hojjatoleslami S A, Kittler J. Region growing: A new approach[J]. *IEEE Trans on Image Processing*, 1998, 7(7): 1079-1084.
- [8] Haris K, Efstratiadis S N, Maglaveras N, et al. Hybrid image segmentation using watersheds and fast region merging[J]. *IEEE Trans on Image Processing*, 1998, 7(12): 1684-1699.
- [9] Sarkar A, Biswas M K, Sharma M K S. A simple unsupervised MRF model based image segmentation approach[J]. *IEEE Trans on Image Processing*, 2000, 9(6): 801-812.
- [10] Kato Z, Pong T C, Qiang S G. Multicue MRF image segmentation: combining texture and color features[C]. *The 16th Int Conf on Pattern Recognition*. Turkey: IEEE Press, 2002: 10660.
- [11] Chittajallu D R, Shah S K, Kakadiaris I A. A shape-driven MRF model for the segmentation of organs in medical images[C]. *IEEE Conf on Computer Vision and Pattern Recognition*. San Francisco: IEEE Press, 2010: 3233-3240.
- [12] Salzenstein F, Pieczynski W. Parameter estimation in hidden fuzzy Markov random fields and image segmentation[J]. *Graphical Models and Image Processing*, 1997, 59(4): 205-220.
- [13] Shafer G. A Mathematical theory of evidence[J]. *Technometrics*, 1978, 20(1): 242.
- [14] Dempster A P. Upper and lower probabilities induced by a multiple valued mapping[J]. *The Annals of Mathematical Statistics*, 1967, 38(2): 325-339.
- [15] Bendjebbour A, Delignon Y. Multisensor image segmentation using Dempster-Shafer fusion in Markov feilds context[J]. *IEEE Trans on Geoscience and Remote Sensing*, 2001, 39(8): 1789-1798.
- [16] Rafael C. Gonzalez, Richard E Woods. *Digital image Processing*[M]. Beijing: Publishing House of Electronics Industry, 2010: 712-713.
- [17] Besag J. Spatial interaction the statistical analysis of lattice systems[J]. *J of the Royal Statistical Society*, 1974, 36(2): 192-236.
- [18] Geman S, Geman D. Stochastic relaxation, Gibbs distribution, and the Bayesian restoration of images[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1984, 6(6): 721-741.
- [19] Jousselme A L, Grenier D. A new distance between two bodies of evidence[J]. *Information Fusion*, 2001, 2(2): 91-101.
- [20] Masson M H, Denoeux T. ECM: An evidential version of the fuzzy c-means algorithm[J]. *Pattern Recognition*, 2008, 41(4): 1384-1397.
- [21] Zhang Zebing, Hu Weidong. Hyper parameter estimation in MRF based SAR chip image segmentation[C]. *IEEE CIE Int Conf on Radar*. Chengdu: IEEE Press, 2011: 760-763.

(责任编辑: 郑晓蕾)