

基于多节点拓扑重叠测度高阶 MRF 模型的图像分割

徐胜军¹ 周盈希¹ 孟月波¹ 刘光辉¹ 史亚¹

摘要 针对低阶马尔科夫随机场 (Markov random field, MRF) 模型难以有效表达自然图像中复杂的先验知识而造成误分割问题, 提出一种基于多节点拓扑重叠测度高阶 MRF 模型 (Higher-order MRF model with multi-node topological overlap measure, MTOM-HMRF) 的图像分割方法. 首先, 为描述图像局部区域内多像素蕴含的复杂空间拓扑结构信息, 利用多节点拓扑重叠测度建立图像局部区域的高阶先验模型; 其次, 利用较大的局部区域包含更多的标签节点信息能力, 基于 Pairwise MRF 模型建立基于局部区域的部分二阶 Potts 先验模型, 提高分割模型的抗噪能力; 再次, 为有效描述观察图像场与其标签场的似然特征分布, 研究利用局部区域内邻接像素的 Hamming 距离引入图像局部空间相关性, 建立局部空间一致性约束的高斯混合分布; 最后, 基于 MRF 框架建立用于图像分割的多节点拓扑重叠测度高阶 MRF 模型, 采用 Gibbs 采样算法对提出模型进行优化. 实验结果表明, 提出模型不仅能有效抵抗图像强噪声和复杂的纹理突变干扰, 鲁棒性更好, 而且具有更准确的图像分割结果.

关键词 图像分割, 高阶马尔科夫随机场, 拓扑重叠测度, 高斯混合模型, Gibbs 采样算法

引用格式 徐胜军, 周盈希, 孟月波, 刘光辉, 史亚. 基于多节点拓扑重叠测度高阶 MRF 模型的图像分割. 自动化学报, 2022, 48(5): 1353-1369

DOI 10.16383/j.aas.c190780



开放科学(资源服务)标识码(OSID):

Image Segmentation Based on Higher-order MRF Model With Multi-node Topological Overlap Measure

XU Sheng-Jun¹ ZHOU Ying-Xi¹ MENG Yue-Bo¹ LIU Guang-Hui¹ SHI Ya¹

Abstract Aim at the problem that lower-order Markov random field (MRF) model is inefficient to capture the rich prior knowledge of nature images which may bring out error image segmentation results, a new image segmentation method is proposed based on higher-order MRF model with multi-node topological overlap measure (MTOM-HMRF). Firstly, to capture complex spatial topological structure information embedded in the local region of images, the proposed method utilizes the topological overlap measure among multi-image-pixels to build higher-order prior model for the local region of images. Secondly, according that larger local region contains more information in label nodes, a partial 2-order Potts model is built based on pairwise MRF model, which increases the anti-noise capability of the proposed model. Thirdly, to efficiently describe the likelihood distribution between observed image field and its label field, a local spatial consistency constraints Gaussian mixture distribution is constructed based on the Hamming distribution between neighbor pixels which incorporated image local spatial correlation. Finally, a topological overlap measure higher-order MRF model is proposed for image segmentation based on the MRF framework, and Gibbs sampling algorithm is used to optimize the proposed model. Experimental results on artificial synthesis images and nature images show that the proposed model is not only efficient to overcome the impact of strong noise and complex texture abrupt on image segmentation results, thus possesses more robustness, but also can provide more accurate edge segmentation results.

Key words Image segmentation, higher-order Markov random field (HMRF), topological overlap measure, Gaussian mixture model, Gibbs sampling algorithm

Citation Xu Sheng-Jun, Zhou Ying-Xi, Meng Yue-Bo, Liu Guang-Hui, Shi Ya. Image segmentation based on higher-order MRF model with multi-node topological overlap measure. *Acta Automatica Sinica*, 2022, 48(5): 1353-1369

收稿日期 2019-11-12 录用日期 2020-04-27
Manuscript received November 12, 2019; accepted April 27, 2020
国家自然科学基金 (51678470, 61803293), 陕西省自然科学基金研究计划 (2020JM-472, 2020JM-473, 2019JQ-760, 2017JM6106, 2015JM6276), 陕西省教育厅专项科研项目 (18JK0477), 西安建筑科技大学基础研究基金 (JC1703, JC1706) 资助
Supported by National Natural Science Foundation of China (51678470, 61803293), the Natural Science Foundation of Shaanxi Province (2020JM-472, 2020JM-473, 2019JQ-760, 2017JM6106,

2015JM6276), the Special Research Project of Education Department of Shaanxi Province (18JK0477), the Basic Research Foundation of Xi'an University of Architecture and Technology (JC1703, JC1706)
本文责任编辑 桑农
Recommended by Associate Editor SANG Nong
1. 西安建筑科技大学信息与控制工程学院 西安 710055
1. School of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055

图像分割是计算机视觉领域研究的核心问题之一, 是对图像进行更高层分析、理解的基础. 近年来, 基于马尔科夫随机场 (Markov random field, MRF) 模型的图像分割方法受到广泛关注, 成为图像分割领域研究的热点. 在概率框架下, MRF 利用图像像素标签的 Gibbs 分布描述图像局部空间先验知识, 并基于贝叶斯定理将图像空间先验知识与似然特征结合起来, 在图像分割领域取得了成功应用^[1-8].

由于低阶 MRF 模型只能表达邻域平滑等简单的先验知识, 而这种简单先验知识常导致分割结果的过平滑, 从而阻碍了 MRF 在图像分割领域的进一步应用. 高阶 MRF 模型引入更多的邻域信息, 能够表达更复杂的先验知识和统计信息, 因而在计算机视觉领域得到广泛关注, 取得了很多有意义的研究成果^[1]. Kohli 等^[2-4] 提出一种 Robust \mathcal{P}^n Potts 模型, 将标签邻域一致性作为先验约束, 即约束局部区域内大部分标签倾向于取相同标签值, 显著提高了图像分割精度, 特别是在物体边界处取得了更准确的分割效果. 夏平等^[5] 针对医学图像中斑点噪声、目标边缘弱化对分割结果的干扰问题, 采用二阶邻域系统描述标签场的结构间联系, 利用复小波域中每一尺度内同标签区域的特征信息分布规律弥补了高阶 MRF 分割中参数估计复杂、小波域 MRF 缺乏平移不变性和特征提取方向性差的不足, 提出复小波域多分辨率 MRF 模型的超声医学图像分割算法. Li 等^[6] 提出一种基于超像素的高阶 CRF (Conditional random field) 语义分割模型, 利用超像素增强点对势能项引入图像的超像素高阶先验, 虽然基于超像素的高阶 CRF 模型大大提升了分割效率, 但是无监督分割算法产生的超像素常包含一些误分割边缘, 因而造成图像分割边界吻合度不理想. 这种约束区域一致性高阶 MRF 模型对于图像局部区域先验表达能力有限^[1], 特别是对于图像局部区域内的高阶拓扑结构等高维特征难以有效表达.

为提高 MRF 模型对图像局部区域的结构特征描述能力, 常利用邻接像素的距离度量方法描述图像局部空间相关性. 宋艳涛等^[7] 提出一种基于图像片权重方法的 MRF 模型, 利用邻接图像片之间的相似性描述局部邻域内对应像素点间的权值, 提高像素邻域内有用点和无用点的区分度, 并通过平滑 KL (Kullback-Leibler) 距离引入先验概率与后验概率熵的惩罚项, 该模型对图像边缘区域和纹理结构复杂区域均能获得较好的分割效果. Kim 等^[8] 建立一个基于超图的图像分割框架, 引入图像不同区域短距离和长距离的依赖性, 利用高阶相关性聚类方

法建立超像素间的高阶势能特征. 融合空间先验约束的高斯混合模型 (Gaussian mixture model, GMM) 在图像分割领域也得到广泛关注. Ji 等^[9] 提出一种空间约束的非对称高斯混合模型 (Asymmetric GMM), 利用 KL 距离计算邻域像素的空间先验信息, 并根据像素类内和类间的先验知识和后验概率建立像素与其标签间的非对称似然分布, 该方法有效抑制了噪声对分割结果的干扰, 得到了较好的分割结果. Zhang 等^[10] 基于局部空间信息和像素强度信息的相关性, 利用带权值的局部区域像素概率代替单一像素概率, 提出一种快速鲁棒的改进 GMM 分割模型. Ji 等^[11] 为提高基于 GMM 图像分割模型对噪声的鲁棒性, 利用局部窗内邻接像素的欧氏距离计算像素邻域空间权值因子, 提出一种新的带空间权值 GMM 模型. Niu 等^[12] 基于局部窗内局部空间逐像素距离引入局部相似度因子, 有效解决了传统基于区域的分割模型对高斯噪声和图像局部细节特征的不敏感性问题. Bi 等^[13] 提出一种显著度 GMM 图像分割模型, 该模型基于视觉注意力机制, 利用图像显著特征图提取基于图像内容的空间信息, 有效增强了重要像素在分割结果中的表达.

上述方法采用基于点对像素的相似性度量引入图像的局部空间先验信息, 这种先验信息约束距离越近的邻接像素越倾向于取相同标签. 由于复杂图像特征具有高维性, 因而常规的基于欧氏距离相似性度量不能有效描述局部像素的相似性. 为解决这一问题, 徐胜军等^[14] 提出一种基于局部区域一致性的流形约束 MRF 模型, 该模型基于流形局部信息度量更准确地捕获了图像局部区域的复杂几何结构先验. 冯宝等^[15] 提出一种结合 MRF 能量和模糊速度函数的活动轮廓模型方法, 利用 Garbo 纹理特征、DCE-MRI 时域特征、灰度特征构成特征向量与聚类中心向量的距离, 构建一种模糊速度函数, 并引入到活动轮廓模型中作为 MRF 能量模型的边缘检测项. Shao 等^[16] 假定空间邻域具有相似的表示因子, 因而利用图拉普拉斯正则项将空间信息引入稀疏表示模型, 提出一种空间和类结构正则化的稀疏表示图模型, 有效描述了图像本征数据结构特征. Dornaika 等^[17] 利用拉普拉斯平滑度提出一种新的约束稀疏图构造方法, 该方法假定拉普拉斯平滑度约束相似的数据样本产生相似的编码向量, 从而融合稀疏表示和拉普拉斯平滑度建立一种非对称权值的相似性矩阵, 进而建立一种更具表达能力的稀疏图.

图像像素邻域结构信息是图像的重要先验知识, 这种邻域结构信息的提取常采用基于邻接像素对的相似性度量方法. 但是由于图像“高维性”、

“强噪声”等特点, 基于点对像素的相似性度量方法不能揭示图像高维空间蕴含的本质几何结构; 同时, 这种“强噪声”在邻接像素之间带来较多假相关. 因而常规点对像素相似性度量方法难以捕获复杂图像高阶结构相关性特征, 这种高阶特征常蕴含在图像局部区域内多个邻接像素间. 由此可知, 研究邻接多像素相似性度量是非常有必要的. 但是常用的约束区域一致性高阶 MRF 模型对于局部区域内蕴含的拓扑结构特征的表达能力有限^[1]. 相关研究表明, 拓扑重叠测度 (Topological overlap measure, TOM)^[18-20] 不仅考虑了邻接点对变量的相关性, 而且引入了局部区域内节点对共享邻接变量的相关性. 与欧氏距离、Pearson 相关性^[21]、互信息^[22] 等传统基于点对像素相关性的距离度量方法相比, TOM 能够有效描述多变量之间的拓扑结构关系. 因而基于 TOM 建立的基因共表达网络能有效度量多个基因表达数据的相似性, 并降低“强噪声”所带来的假相关, 因此在生物信息领域中得到显著关注^[22-25].

受此启发, 为提高基于 MRF 模型对自然图像复杂特征描述的能力以及对噪声干扰的鲁棒性, 基于 MTOM (Multi-node topological overlap measure) 提出一种多变量相似性度量方法, 有效描述图像局部区域内邻接像素多变量拓扑结构关系, 并利用这种多变量拓扑结构关系建立图像的高阶拓扑结构先验模型. 最终基于 MRF 提出一种多节点拓扑重叠测度高阶 MRF 模型 (Higher-order MRF model with multi-node topological overlap measure, MTOM-HMRF) 图像分割方法, 有效提升了图像分割的效果.

1 相关基础知识

1.1 拓扑重叠测度

假定观察图像变量集合 $X = \{x_1, x_2, \dots, x_S\}$, 其中 $x_s, x_r \in X$ 是集合 X 的任意两个邻接变量, S 为集合 X 的变量总数. 假定邻接变量 x_s, x_r 之间共享相邻节点 x_u 的信息越多, 表明它们的相似性越强; 反之, 如果邻接变量 x_s, x_r 之间共享相邻节点 x_u 的信息越少, 表明它们的相似性越弱. 定义两个邻接变量 x_s, x_r 的点对拓扑重叠测度 t_{sr} 如式 (1) 所示^[18]:

$$t_{sr} = \begin{cases} \frac{\sum_{u \neq s, r} a_{su} a_{ru} + a_{sr}}{\min \left\{ \sum_{u \neq s} a_{su}, \sum_{u \neq r} a_{ru} \right\} + 1 - a_{sr}}, & \text{if } s \neq r \\ 1, & \text{if } s = r \end{cases} \quad (1)$$

式中, $a_{sr} = \text{dist}(x_s, x_r)$ 表示邻接变量 x_s, x_r 的相似性度量, 且 $0 \leq a_{sr} \leq 1$, 这个相似性度量常采用欧氏距离、Hamming 距离等相似性度量方法度量; $\sum_{u \neq s, r} a_{su} a_{ru}$ 为邻接变量 x_s, x_r 的共享变量度量; $1 - a_{sr}$ 的作用是避免当 $\sum_{u \neq s} a_{su}$ 或 $\sum_{u \neq r} a_{ru}$ 为 0 时, 分母项为 0.

由式 (1) 可知, 如果邻接变量 x_s, x_r 之间共享相邻节点 x_u 的信息越多, 那么点对拓扑重叠测度 t_{sr} 的值越大, 反之 t_{sr} 的值越小. 且因为 $0 \leq a_{sr} \leq 1$, 所以 $\sum_{u \neq s, r} a_{su} a_{ru} \leq \sum_{u \neq s} a_{su} - a_{sr}$, 也就是说 $\sum_{u \neq s, r} a_{su} a_{ru} \leq \min \left\{ \sum_{u \neq s} a_{su}, \sum_{u \neq r} a_{ru} \right\} - a_{sr}$. 因此由式 (1) 可知, 邻接变量 x_s, x_r 的点对拓扑重叠测度 t_{sr} 满足 $0 \leq t_{sr} \leq 1$.

根据式 (1) 邻接变量 x_s, x_r 的点对拓扑重叠测度 t_{sr} 的定义, 则观察变量集合 X 的 TOM 矩阵 $T(X)$ 为:

$$T(X) = [t_{sr}]_{s, r \leq S} \quad (2)$$

联合式 (1) 和式 (2) 可知, TOM 矩阵 $T(X)$ 是一个对称且非负的相似度矩阵. 这个矩阵把邻接变量的点对关系相似度矩阵转换成了多变量高阶 TOM, 并利用这种 TOM 建立邻接变量的高阶相似性约束, 从而引入多变量邻接节点的高阶拓扑空间相关性, 能更好地表达多变量局部空间特征, 并减少“强噪声”所带来的假相关^[18].

1.2 MRF 图像分割模型

MRF 是一种强力的图像特征表达模型, 在图像分割、图像恢复、图像匹配等低级图像处理领域具有广泛的应用. 设 $S = \{s | s \leq M \times N\}$ 表示一个定义在邻域系统 $\mathcal{N} = \{\mathcal{N}_s | s \in S\}$ 上的有限格点集合, 其中 \mathcal{N}_s 表示节点 s 的邻域节点集合, $M \times N$ 为集合大小. 令 $X = \{x_s | x_s \in \Omega, s \in S\}$ 表示一个观察图像, 其中 $\Omega = \{0, 1, \dots, 255\}$ 表示图像中观察像素 x_s 的强度值范围. 假定观察图像每一个像素 x_s 唯一对应一个标签节点 y_s , 则分割图像标签场 $Y = \{y_s | y_s \in \Lambda, s \in S\}$, 其中 $\Lambda = \{0, 1, \dots, L\}$, L 表示图像分割标签总数.

基于 MRF 的图像分割方法假定标签场 Y 满足 Markov 性质, 是一个马尔科夫随机场, 则标签场 Y 利用 Markov 性质建立图像分割的空间先验知识, 表示为 $P(Y)$. 给定观察图像场 X , 令标签场 Y 的条件似然分布表示为 $P(X|Y)$. 根据 Bayes 规则, 图像分割的后验概率分布模型 $P(Y|X)$ 如式 (3) 所示:

$$P(Y|X) = \frac{P(X|Y)P(Y)}{P(X)} \quad (3)$$

在概率 MRF 框架下, 图像分割问题的实质是给定已知观察图像场 X , 求取标签场 Y 的全局最优估计 Y^* . 这个全局最优标签场 Y^* 的估计问题常把 MRF 全局概率分布的最大化问题转化为 MRF 能量最小化问题^[26]:

$$Y^* = \arg \max_Y P(Y|X) \sim \arg \min_Y E_g(X, Y) = \arg \min_Y \{E_d(X, Y) + E_s(Y)\} \quad (4)$$

式中, $E_g(X, Y)$ 表示 MRF 分布的全局能量; $E_d(X, Y) = -\lg P(X|Y)$, 称为图像特征场模型的似然能量; $E_s(Y) = \sum_{s, r \in \mathcal{N}_s} \delta(y_s, y_r)$, 称为图像标签场 MRF 先验模型的平滑能量, 其中 \mathcal{N}_s 表示节点 s 的邻域节点集合; “ \sim ”表示近似于.

2 基于 MTOM-HMRF 的图像分割模型

常规 Pairwise MRF 能量模型中, 标签场先验平滑能量 $E_s(Y) = \sum_{s, r \in \mathcal{N}_s} \delta(y_s, y_r)$ 仅对邻域节点进行平滑性约束, 因而这种低阶点对结构限制了 Pairwise MRF 能量模型的表达能, 使其难以表达图像更加复杂的区域和全局先验知识. 为提高 MRF 模型对复杂图像特征的表达能及其在分割过程中对噪声、纹理等突变信号的抗干扰能力, 提出一种基于 MTOM-HMRF 的图像分割模型. 该模型利用多变量拓扑重叠测度方法建立邻接变量的高阶相似性约束, 从而引入了多变量邻接节点的高阶拓扑结构先验知识, 更好地表达了图像的复杂局部空间先验知识.

2.1 MTOM-HMRF 先验模型

基于 MRF 的图像分割模型中, 图像局部区域中蕴含的空间结构信息是图像分割的重要先验知识, 这种空间结构信息常采用基于邻接像素对的相似性度量方法描述, 但是简单的点对相似性度量难以捕获图像复杂的局部空间结构特征. 相关研究表明, TOM 能有效描述多变量之间的拓扑结构关系^[18-20]. 为提升 MRF 模型对图像复杂空间结构信息的表达能, 降低图像“强噪声”所带来的假相关性对分割结果的干扰, 提出一种融合 TOM 和 MRF 模型的 MTOM-HMRF 先验模型.

部分二阶 MRF 模型如图 1 所示, 令 y_s 表示 MRF 中任一隐标签节点; x_s 表示与隐标签节点 y_s 一一对应的图像观察节点; w_s 表示以隐标签节点 y_s 为中心节点的一个 MRF 的局部区域, 局部区域大小为 $|w_s| \times |w_s|$; 令 $y_r \in \mathcal{N}_s(y_s)$ 表示中心节点 y_s 的邻域节点, 其中 $\mathcal{N}_s(y_s)$ 表示中心节点 y_s 的邻域节

点集合. 在 MRF 模型中, 邻接节点对 x_s, x_r 的点对拓扑重叠测度 t_{sr} 反映了它们所共享邻接节点拓扑结构的相似性, 即这种相似性有效引入了图像局部区域内蕴含的空间拓扑结构特征, 能更有效地表达图像的局部区域特征, 对图像的噪声干扰所带来的假相关性具有鲁棒性.

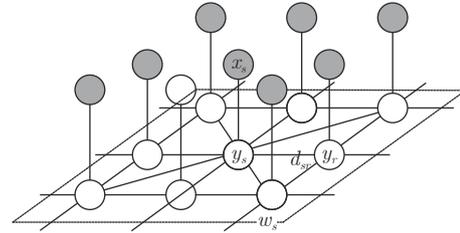


图 1 部分二阶 MRF 模型

Fig.1 Part 2-order MRF model

图像像素强度值分布是一个随机过程, 因此通常采用统计性的概率分布描述图像的先验信息. 在图像局部区域内, 中心像素与其邻接像素相似性有效描述了图像空间拓扑结构信息, 为图像分割提供了重要的上下文空间先验信息.

为度量邻接像素的拓扑重叠测度, 首先计算局部区域 w_s 的中心像素 x_s 与其所有邻域像素 x_r 的欧氏距离 $d(x_s, x_r)$, 并对像素间的相似度进行归一化, 使得 $0 \leq d_{sr} \leq 1$. 归一化函数如下^[27-28]:

$$d(x_s, x_r) = \exp \left\{ \frac{-\|x_s - x_r\|_2^2}{\left(\rho \max_{r \in \mathcal{N}_s} \|x_s - x_r\|_2 \right)^2} \right\} \quad (5)$$

式中, $\|x_s - x_r\|_2$ 表示邻接像素对的欧氏距离; $\rho \leq 0.2$ ^[27] 为归一化尺度参数, 衡量了邻接像素的相似度, ρ 值越小, 相同距离邻接像素的相似度越小.

由式 (5) 建立局部区域的欧氏距离度量向量:

$$D_{w_s}(X_{w_s}) = \{d(x_s, x_1), \dots, d(x_s, x_r), \dots, d(x_s, x_{|w_s| \times |w_s|})\} \quad (6)$$

式中, $d(x_s, x_r)$ 表示中心像素 x_s 与其邻域像素 x_r 的相似性, 且满足 $0 \leq d_{sr} \leq 1$; $|w_s| \times |w_s|$ 为图像局部区域的大小.

为了将邻接像素相似性转化为联接强度, 利用幂邻接函数把局部区域 w_s 的相似度量向量 $D_{w_s}(X_{w_s})$ 转换为一个邻接强度度量向量 $A_{w_s}(X_{w_s})$. 幂邻接函数定义如下:

$$a_{sr}(x_s, x_r) = |d(x_s, x_r)|^\gamma \quad (7)$$

式中, $a_{sr}(\cdot)$ 表示邻接像素对 x_s, x_r 的邻接矩阵权值;

$\gamma \geq 1$ 为一个幂指数, 其作用是加强强相关邻接像素的联接强度, 惩罚弱相关邻接像素的联接强度, 其值越大, 这种作用越强. 因此, 由式 (7) 建立的邻接矩阵增强了强相关邻接像素的相似性, 有效保持了邻接像素共表达信息的连续性. 建立的图像局部区域 w_s 的邻接强度度量向量 $\mathbf{A}_{w_s}(X_{w_s})$ 表示如下:

$$\mathbf{A}_{w_s}(X_{w_s}) = \{a(x_s, x_1), \dots, a(x_s, x_r), \dots, a(x_s, x_{|w_s| \times |w_s|})\} \quad (8)$$

然后根据式 (1) 计算中心像素及其邻接像素的 TOM. 令 $|w_s| = 3$, 拓扑结构示意图如图 2 所示. 图 2 (a) 中, 中心像素 x_s 与其上邻接像素 x_{up} 的共享邻域像素用灰色节点表示, 以此类推可知中心像素 x_s 与其余邻接像素的共享邻域像素分别如图 2 (b) ~ 图 2 (d).

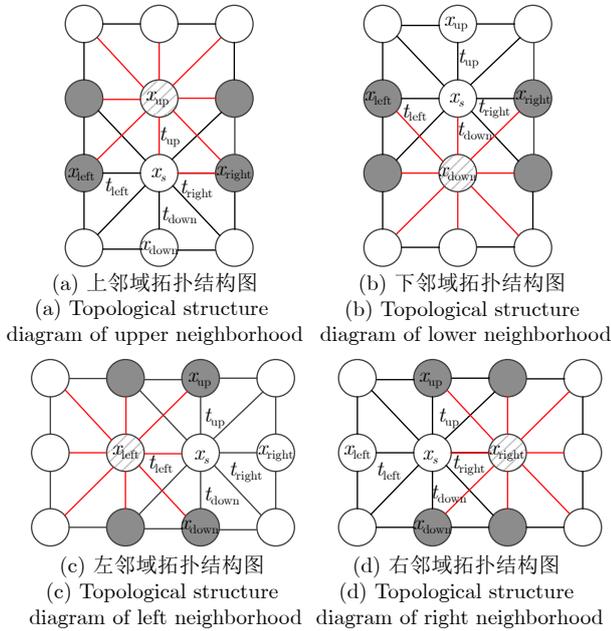


图 2 $|w_s| = 3$ 时中心像素 x_s 与其上、下、左、右邻接像素拓扑结构示意图

Fig. 2 When $|w_s| = 3$, the topological structure diagram of the center pixel and its upper, lower, left and right adjacent pixels

根据式 (1) 点对拓扑重叠测度计算式, 可知邻接像素对的点对拓扑重叠测度 $t_{sr}(x_s, x_r)$ 为:

$$t_{sr}(x_s, x_r) = \frac{\sum_{u \neq s, r} a_{su} a_{ur} + a_{sr}}{\min \left\{ \sum_{u \neq s} a_{su}, \sum_{u \neq r} a_{ru} \right\} + 1 - a_{sr}}, \quad s \neq r \quad (9)$$

式中, a_{sr} 表示邻接像素对 x_s, x_r 间的联接强度, 定义为:

$$a_{sr} = \left| \exp \left\{ -2 \times \frac{(\|x_s - x_r\|_2)^2}{\left(\rho \max_{r \in \mathcal{N}_s} \|x_s - x_r\|_2 \right)^2} \right\} \right|^\gamma \quad (10)$$

式中, $\|x_s - x_r\|_2$ 表示邻接像素对的欧氏距离; $\rho \leq 0.2$ 为归一化尺度参数; $\gamma \geq 1$ 为邻接像素对幂邻接函数的相似性惩罚因子.

由式 (9)、式 (10) 可知, 如果邻接像素对 x_s, x_r 分别与其共享邻接像素具有更多相似性, 那么邻接像素对 x_s, x_r 的点对拓扑重叠测度 $t_{sr}(x_s, x_r)$ 的值更大. 也就是说, 对于两个邻接像素对 x_s, x_r 来说, 如果像素 x_s 与其多个共享邻域节点具有较高相似性, 像素 x_r 也与这几个共享邻域像素具有较高相似性, 那么根据像素相似性传递性质可知, 这两个邻接像素对 x_s, x_r 也具有较高相似性, 即点对拓扑重叠测度 $t_{sr}(x_s, x_r)$ 具有更大的值, 反之亦然. 进一步可知, 如果像素 x_r 是一个噪声节点, 那么像素 x_r 与其共享邻域像素具有较低相似性, 而像素 x_s 与其共享邻域像素相似性较高, 则邻接像素对 x_s, x_r 的点对拓扑重叠测度 $t_{sr}(x_s, x_r)$ 具有较小的值. 由此可知, 这种基于多节点拓扑重叠测度相似性度量引入了局部区域像素的拓扑空间关系, 因而对于图像噪声、纹理突变的干扰具有鲁棒性.

最终, 如图 2 所示, 令局部区域 w_s 的高阶拓扑空间先验 $t_{w_s}(x_s, x_{N_s})$ 表示为:

$$t_{w_s}(x_s, x_{N_s}) = t_{up}(x_s, x_{up}) + t_{down}(x_s, x_{down}) + t_{left}(x_s, x_{left}) + t_{right}(x_s, x_{right}) \quad (11)$$

式中, $t_{up}(\cdot), t_{down}(\cdot), t_{left}(\cdot), t_{right}(\cdot)$ 分别表示中心像素 x_s 与其上、下、左、右邻域像素的 TOM. 即局部区域 w_s 的高阶拓扑空间先验 $t_{w_s}(x_s, x_{N_s})$ 定义为中心像素 x_s 与其邻域像素 $x_{up}, x_{down}, x_{left}, x_{right}$ 的 TOM 之和.

根据式 (9) ~ 式 (11), 提出基于 MTOM 的高阶 MRF 先验能量项定义如下:

$$E_h(x_{w_s} | \mathcal{Y}) = \sum_{s \in S, r \in N_s} \left[\frac{\sum_{u \neq s, r} a_{su} a_{ru} + a_{sr}}{\min \left\{ \sum_{u \neq s} a_{su}, \sum_{u \neq r} a_{ru} \right\} + 1 - a_{sr}} \right] \quad (12)$$

式中, $E_h(x_{w_s} | \mathcal{Y})$ 为局部区域 w_s 的高阶拓扑结构先

验能量; a_{sr} 表示中心像素 x_s 与其邻接像素 x_r 间的联接强度; $\Upsilon = \{\rho, \gamma\}$ 表示高阶先验模型的参数集合, 其中 ρ, γ 分别为归一化尺度参数和幂邻接函数的相似性惩罚因子.

由式 (12) 可知, 基于 MTOM 的高阶 MRF 先验知识利用邻接像素的 TOM 描述了局部区域内邻接像素所共享的多像素之间相似度, 构建了多像素高阶空间拓扑关系, 并利用这个空间拓扑关系度量邻接像素的高阶拓扑相似性, 从而建立了具有高阶空间相关性的 MRF 先验知识表达模型, 更有效描述图像局部区域内蕴含的复杂拓扑空间结构特征等高阶先验知识, 并降低“强噪声”所带来的假相关, 因此 MTOM-HMRF 先验模型对图像噪声、纹理突变干扰具有鲁棒性.

算法 1. 基于 MTOM-HMRF 先验模型的构造算法

输入. 观察图像 $X = \{x_s | x_s \in \Omega, s \in S\}$.

输出. MTOM-HMRF 高阶拓扑结构先验能量 $E_h(X|\Upsilon)$.

1) 参数初始化: 给定局部区域 w_s 、归一化尺度参数 ρ 、幂邻接参数 γ .

2) For $s = 1$ to S , 计算邻接像素的 MTOM.

a) 根据式 (5) 计算局部区域 w_s 的中心像素 x_s 与其邻域像素 x_r 的欧氏距离 $d(x_s, x_r)$, 并由式 (6) 建立局部区域 w_s 的欧氏距离度量向量 $\mathbf{D}_{w_s}(X_{w_s})$;

b) 根据幂邻接函数式 (7), 由式 (8) 建立局部区域 w_s 的邻接强度度量向量 $\mathbf{A}_{w_s}(X_{w_s})$;

c) 根据式 (9) MTOM 计算式, 计算邻接像素 x_s, x_r 的点对拓扑重叠测度 $t_{sr}(x_s, x_r)$;

d) 根据式 (12), 计算局部区域 w_s 的高阶拓扑结构先验能量 $E_h(x_{w_s}|\Upsilon)$.

3) 如果 $s = S$, 得到观察图像 X 所有区域的高阶拓扑结构先验能量 $E_h(X|\Upsilon)$, 算法结束; 否则返回步骤 2) 继续迭代.

2.2 具有局部区域一致性的 WGMM

特征场模型 $P(X|Y)$ 越逼近图像像素与其标签的真实分布, 越能反映图像似然特征. 但是基于常规 GMM 似然模型为了计算简便, 常假定邻接像素是独立同分布的, 这种假定忽略了图像局部区域空间相关性. 为有效描述像素与标签之间的似然特征, 提出基于局部区域一致性 WGMM (Weighted GMM) 似然特征模型. 该模型对任一像素点 x_s , 定义其邻域像素点为 x_r , 即 $x_r = \{x_r | r \in \mathcal{N}_s\}$. 为描述局部区域内像素间的空间交互关系, 利用中心像素 x_s 与其邻域像素 x_r 的距离度量得到中心像素与邻

域内其余像素的权重, 将构建的权重引入到 GMM 中, 得到局部区域一致性 WGMM 似然模型为:

$$P(X|Y, \theta) = \prod_{s=1}^N \left[P(x_s|y_s, \theta) \prod_{r \in \mathcal{N}_s} P(x_r|y_r, \theta)^{\frac{w(y_r)}{w_r}} \right] \quad (13)$$

式中, GMM 参数 $\theta = \{\mu_l, \sigma_l^2\}_{l \in \Lambda}$, 分别为第 l 个 GMM 分布的均值和方差, 其中 $\Lambda = \{0, 1, \dots, L\}$; L 表示图像分割标签总数; $w_r = \sum_{r \in \mathcal{N}_s} w(y_r)$ 为归一化函数, 对于局部区域 w_s 中所有像素, 当 $w(y_r) = 1$ 时, w_r 为区域内像素个数; $w(y_r)$ 是一个包含空间信息的权重函数, 其值的大小由中心像素 x_s 与其邻域像素 x_r 的相似性决定. 本文采用 Hamming 距离衡量邻接像素 x_s 与 x_r 之间的相似性, 定义权重函数 $w(y_r)$ 为:

$$w(y_r) = \sum_{s \in S} \sum_{r \in \mathcal{N}_s} \|x_s - x_r\| = \sum_{s \in S} \sum_{r \in \mathcal{N}_s} (x_s + x_r - 2x_s x_r) \quad (14)$$

式中, 邻接像素的相似性 $\|x_s - x_r\|$ 控制权重的大小, 即邻域像素对 x_s, x_r 之间距离越大, 相似度越低, 赋予像素权重越小.

建立的局部区域一致性 WGMM 似然模型利用像素间的距离描述像素空间关系, 通过权重约束邻域内像素标签一致性, 其邻接像素 Hamming 距离越小, 权重 $w(y_r)$ 越小, 因此可以使同态区域的相邻像素倾向于取相同类标签值, 而非同态区域的邻接像素取不同类标签值. 因此, WGMM 模型避免了对非同态区域的邻域像素局部特征的过平滑.

2.3 基于区域的部分二阶 Potts 先验模型

常规 Pairwise MRF 模型的简单点对结构大大限制了 MRF 先验模型的表达能力, 使其无法表达区域和全局先验知识, 因此提出一种基于区域的部分二阶 MRF 模型, 以利用更大的局部区域包含更多的局部先验知识的能力, 同时不会显著增加模型的计算复杂度. 在局部区域 w_s 内, 假定局部区域 w_s 的标签场 Y_{w_s} 是一个 MRF, 这个标签场的先验使用 Potts 模型描述. 根据 Hammersley-Clifford 定理可知, 建立的基于区域的部分二阶 Potts 先验模型描述为:

$$P(y_s|y_{w_s}, \beta) = \frac{\exp \left\{ -\beta \sum_{s, r \in \mathcal{N}_s} [1 - \delta(y_s, y_r)] \right\}}{Z(\beta)} \quad (15)$$

式中, $Z(\beta)$ 是一个归一化常量; β 为 Potts 模型先

验参数, 控制局部区域分割结果的平滑度; $\delta(y_s, y_r)$ 为 delta 函数:

$$\delta(y_s, y_r) = \begin{cases} 1, & y_s \neq y_r \\ 0, & y_s = y_r \end{cases} \quad (16)$$

在局部区域 w_s 内, 所提出的模型中心标签 y_s 与其邻接标签 y_r 不相等时, 这个不一致惩罚值为 $\beta \sum_{s, r \in \mathcal{N}_s} [1 - \delta(y_s, y_r)]$; 仅当中心标签 y_s 与其邻接标签 y_r 全部相等时, 惩罚值为 0.

因此, 基于区域的部分二阶 Potts 先验能量模型如式 (17) 定义:

$$E_s(y_s, y_{w_s}) = \lg P(y_s | y_{w_s}) = \begin{cases} \beta \sum_{s, r \in \mathcal{N}_s} [1 - \delta(y_s, y_r)], & y_s \neq y_r \\ 0, & y_s = y_r \end{cases} \quad (17)$$

由上式可知, 在局部区域 w_s 内, 当区域内较多像素点的类标签趋于一致时, 其惩罚值趋于 0; 对于具有不同类标签的局部区域, 其不一致惩罚值随着标签取值不一致的个数增长而线性增长. 这种区域类别一致性约束不仅避免了局部区域内异质像素的统一惩罚值所带来的过平滑现象, 有效提升了图像分割结果的边缘效果, 而且对图像噪声、纹理信号的干扰具有鲁棒性.

3 基于多节点拓扑重叠测度高阶 MRF 模型的图像分割算法

基于 MRF 框架, 融合基于 MTOM 的高阶先验知识、局部区域一致性的 WGMM 似然特征和部分二阶 Potts 先验知识, 建立 MTOM-HMRF 图像分割能量模型如下式所示:

$$E_g(Y|X, \Theta) = E_d(X|Y, \theta) + E_s(Y|\beta) + E_h(X|\Upsilon) \quad (18)$$

式中, $\Theta = (\theta, \beta, \Upsilon)$. $E_d(X|Y, \theta)$ 表示局部区域一致性 WGMM 似然能量, θ 为似然能量模型参数. 似然能量项 $E_d(X|Y, \theta)$ 利用 WGMM 似然特征分布, 有效保持了局部区域内像素与其标签的区域似然一致性. $E_s(Y|\beta)$ 表示部分二阶 Potts 先验能量, β 为 Potts 类型先验能量模型参数. 先验项 $E_s(Y|\beta)$ 根据局部区域内和中心标签值不一致数量成正比的线性惩罚建立局部区域先验的一致性平滑约束, 基于部分二阶 Potts 模型引入了更多的先验空间约束, 提高了分割过程的鲁棒性. $E_h(X|\Upsilon)$ 表示基于 MTOM 的高阶拓扑结构先验能量, Υ 为高阶拓扑

结构先验能量模型参数集合. 高阶先验项 $E_h(X|\Upsilon)$ 利用邻接像素所共享的多像素之间的 MTOM, 引入了图像局部区域拓扑结构相似性特征, 使得模型能够有效表达更高阶的空间信息, 进一步提高模型的鲁棒性与有效性, 提高图像分割精确度.

根据 MAP 准则, 提出 MTOM-HMRF 模型最优估计标签场 Y^* 为:

$$Y^* = \arg \min_Y E_g(Y|X, \Theta) = \arg \min_Y [E_d(X|Y, \theta) + E_s(Y|\beta) + E_h(X|\Upsilon)] \quad (19)$$

要求解最优估计标签值 Y^* , 首先需要估计提出模型的参数. Potts 模型先验参数 β 和高阶先验模型参数 $\Upsilon = \{\rho, \gamma\}$ 分别通过人工试错法估计; WGMM 似然模型的参数 $\{\mu_l, \sigma_l^2\}$ 通过期望最大化算法 (Expectation-maximization algorithm, EM) 求解, 具体过程参见文献 [26]. 提出的 MRF 能量模型采用 Gibbs 采样算法进行迭代优化, 求出最优值 Y^* .

算法 2. 基于 MTOM-HMRF 图像分割算法

输入. 图像 $X = \{x_s | x_s \in \Omega, s \in S\}$.

输出. 最优标签场 $Y^* = \{y_s | y_s \in \Lambda, s \in S\}$.

- 1) 参数初始化: 给定分类标签数 L ; WGMM 的均值和方差 $\{\mu_l, \sigma_l^2\}_{l \in \Lambda}$ 随机初始化; 先验参数 β 由实验给定; $\rho = 0.2; \gamma = 4$; Gibbs 采样算法初始温度 $T^{(0)} = 4.0$;
- 2) 利用算法 1 计算图像 X 的 MTOM 先验;
- 3) 由 EM 算法估计 WGMM 的均值和方差 $\{\mu_l, \sigma_l^2\}_{l \in \Lambda}$;
- 4) 根据式 (15) 建立 MTOM-HMRF 图像分割模型, 并按照 MAP 准则预分割图像 $Y' = \arg \max P(Y|X, \mu_l, \sigma_l^2)$;
- 5) For $s = 1$ to S , 对于每一个像素 x_s , 根据式 (15) 计算其所在局部区域 w_s 分配标签的能量 $E_{w_s}(y_s | x_{w_s}, \mu_l, \sigma_l^2, \rho, \beta, \gamma)$;
- 6) Gibbs 采样: 在局部区域 w_s 中, 中心像素 y_s 根据以下概率接受一个新的标号组态 η :

$$P(y_s = \eta) = \frac{\exp\{-E_{w_s}(y_s = \eta | x_{w_s}, \mu_l, \sigma_l^2, \rho, \beta, \gamma)\}}{\sum_{\zeta \in w_s} \exp\{-E_{w_s}(y_s = \zeta | x_{w_s}, \mu_l, \sigma_l^2, \rho, \beta, \gamma)\}}$$

- 7) 计算全局能量 $E_g^{(n)}(Y) = \sum_s E_{w_s}^{(n)}(y_s)$, 如果 $|E_g^{(n)}(Y) - E_g^{(n-1)}(Y)| \leq \varepsilon$ (ε 是一个小的常量), 则 $Y^* = Y^{(n)}$, 算法终止; 否则减小温度 $T = 0.95T^{(n)}$, 返回步骤 5) 继续迭代.

4 实验结果及分析

实验硬件环境为 Intel(R) Core(TM) i7-8700 CPU @3.20 GHz 处理器, 16 GB RAM, NVIDIA

GeForce GTX 1060 6 GB 显卡. 集成开发环境为 Visual Studio 2015 和 OpenCV3.4 计算机视觉开源库, 操作系统为 Windows10. 分别对人工加噪声图像和自然图像进行分割实验, 通过与基于区域的 Pairwise MRF 分割模型^[26]、基于 Robust \mathcal{P}^n 高阶分割模型^[4]的分割效果进行对比, 验证提出模型的有效性.

对于人工合成图像分割结果评价采用正确分类率 (Correct classification ratio, CCR) 参数作为量化评估指标, CCR 定义如下:

$$\text{CCR}(S_{\text{gt}}, S_{\text{seg}}) = \sum_{l=1}^L \frac{|S_{\text{gt}_l} \cap S_{\text{seg}_l}|}{|S_{\text{gt}_l}|} \quad (20)$$

式中, S_{seg} 表示算法分割结果, S_{gt} 表示标准分割结果, S_{seg_l} 表示第 l 类算法分割结果, S_{gt_l} 表示第 l 类算法标准分割结果, $|S_{\text{gt}}| = \bigcup_{l=1}^L S_{\text{gt}_l}$ 为总像素数. $\text{CCR} \in [0, 1]$, CCR 值越大, 表明分割结果越趋近于真实结果.

对于自然图像分割结果常用概率随机索引 (Probabilistic rand index, PRI) 指标和正确分类率 (CCR) 指标衡量. PRI 定义如下:

$$\text{PRI}(S_{\text{seg}}, S_{\text{gt}}) = \frac{2}{N(N-1)} \sum_{\substack{s, r \\ s < r}} [c_{sr}p_{sr} + (1 - c_{sr})(1 - p_{sr})] \quad (21)$$

式中, $c_{sr} = 1$ 表示像素 s 和 r 属于同一类, $c_{sr} = 0$ 表示像素 s 和 r 属于不同类别. $\text{PRI} \in [0, 1]$, PRI 值越大, S_{seg} 和 S_{gt} 对比结果一致性越好, 即分割结果越好.

提出模型的归一化尺度参数 $\rho \leq 0.2$ 衡量了不同尺度下邻接像素的相似度, 其值越小, 相同邻接像素相似度越小, 实验中令 $\rho = 0.2$. 幂邻接参数 $\gamma \geq 1$, 其作用是加强强相关邻接像素联接强度, 抑制弱相关邻接像素联接强度, 其值越大, 这种作用越强. 但是过大的 γ 值易导致邻接像素空间先验信息的丢失, 实验中设定 $\gamma = 4$; 邻域窗口大小设置为 3×3 像素块; 三个对比模型的 GMM 参数由 EM 算法估计; 不同图像的 Potts 先验参数 β 由大量实验人工选择对应分割结果最好的参数值. 参数 β 越大, 平滑项对图像局部区域分割结果的平滑作用越强, 反之越弱. 因此参数 β 选择原则是: 一般对于图像噪声较弱或图像纹理简单的图像, β 取较小值, 反之取较大值. 实验图像分类数目 L 根据图像由人工指定. 为了更直接对比分割模型的有效性, 所有模型优化算法采用 Gibbs 采样算法, Gibbs 采样算

法初始温度 $T^{(0)}$ 设定为 4.0, 退火率设为 0.95.

4.1 人工合成图像分割实验

人工合成图像 T_image 如图 3 所示, 大小为 300×300 像素, 灰度级为 256, 分类数为 4, 其各类均值分别为 0、85、170、255. 为验证提出模型对噪声干扰的鲁棒性, 分别对人工合成图像 T_image 加不同强度的高斯白噪声和椒盐噪声进行分割实验, 实验结果对比如图 4 所示. 实验中加方差 300、900 的高斯白噪声合成图像, 加 0.02、0.05、0.10 的椒盐噪声合成图像的 Potts 模型. 先验参数 β 分别设定为 2.1、10.0、4.6、4.9、5.1, Robust \mathcal{P}^n 高阶分割模型截断参数 Q 和惩罚参数 γ_{max} 分别设定为 3 和 2.5, 提出模型归一化尺度参数 ρ 和幂邻接参数 γ 分别设定为 0.2 和 4, 不同加噪图像 GMM 参数由 EM 算法估计.

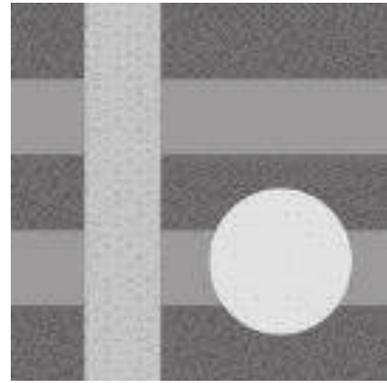
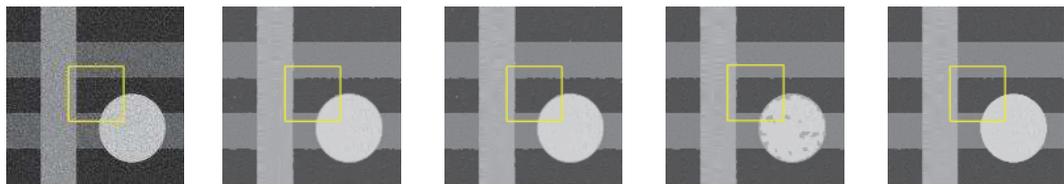


图 3 T_image 原图
Fig.3 T_image original image

为验证提出方法的有效性, 分别对人工合成图像分割结果进行定性和定量分析.

1) 定性分析. 由图 4 所示不同高斯白噪声合成图像的分割结果和局部细节, 可以看出对比模型中基于区域的 Pairwise MRF 模型分割结果最差. 主要是由于这种模型的简单点对结构难以描述复杂的图像空间相关性特征, 因而分割结果受高斯噪声干扰较大, 特别是在图像边缘有明显的毛刺和误分割时, 边缘分割结果较差. 基于 Robust \mathcal{P}^n MRF 模型引入了图像局部区域类别不一致性惩罚, 提高了分割结果对噪声干扰的鲁棒性, 如图 4 中分割结果所示, 在图像平坦区域大大减少了由于噪声干扰所造成的“斑点”误分割. 但是对于方差为 900 的高斯白噪声人工合成图的分割仍存在少量的“斑点”误分割, 特别是在分割结果中的“圆形”边缘区域, 仍存在明显的误分割. 这是由于 Robust \mathcal{P}^n MRF 模型假定局部区域中所有位置上的先验权重相同, 因



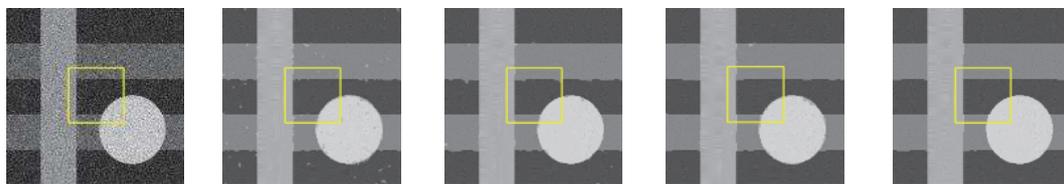
加方差 300 的高斯白噪声合成图像分割结果对比

Comparison of segmentation results of synthetic image with white Gaussian noise of 300 variance



加方差 300 的高斯白噪声合成图像分割结果局部放大图

A partially enlarged view of segmentation results of synthetic image with white Gaussian noise of 300 variance



加方差 900 的高斯白噪声合成图像分割结果对比

Comparison of segmentation results of synthetic image with white Gaussian noise of 900 variance



加方差 900 的高斯白噪声合成图像分割结果局部放大图

A partially enlarged view of segmentation results of synthetic image with white Gaussian noise of 900 variance

- (a) 加噪图 (b) Pairwise MRF 模型 (c) Robust P^n MRF 模型 (d) 不带 MTOM 项的提出模型 (e) 提出模型
 (a) Noise image (b) Pairwise MRF model (c) Robust P^n MRF model (d) The proposed model without MTOM term (e) The proposed model

图 4 合成图像加高斯白噪声分割结果对比

Fig.4 Comparison of segmentation results of synthetic image with white Gaussian noise

此造成较强噪声干扰时边缘分割结果往往不够精确. 不带 MTOM 项的提出模型仅仅考虑了局部区域低阶空间先验信息, 因此不能有效抑制强噪声信息干扰. 基于 MTOM-HMRF 模型的分割方法利用高阶拓扑结构引入了更丰富的图像空间高阶相关性特征, 这种高阶拓扑结构利用邻接像素的相似性描述了局部区域内的多像素复杂拓扑结构特征, 有效降低了图像强噪声的干扰, 对于方差为 900 的高斯白噪声人工合成图也得到了较理想的分割结果, 特别是在“圆形”边缘显著提高了分割精度.

由图 5 所示不同椒盐噪声合成图像分割结果分析进一步证明了提出模型的有效性. 对比模型对椒

盐噪声比较敏感, 尤其是随着椒盐噪声的增强, 对比模型对噪声颗粒产生了大量误分割. 提出模型对于加强度 0.02、0.05 的椒盐噪声人工合成图像的分割能够很好地去掉椒盐噪声干扰, 得到较为理想的分割结果. 对于强度为 0.10 的椒盐噪声人工合成图像, 存在极少量“斑点”误分割, 整体分割效果明显优于对比模型.

由以上两个加不同类型噪声的人工合成图像分割实验表明, 与基于区域的 Pairwise MRF 模型的分割方法、基于 Robust P^n MRF 模型的分割方法相比, 提出模型能够描述更远距离多像素拓扑结构特征, 表达更加复杂的图像高阶先验知识及统计信

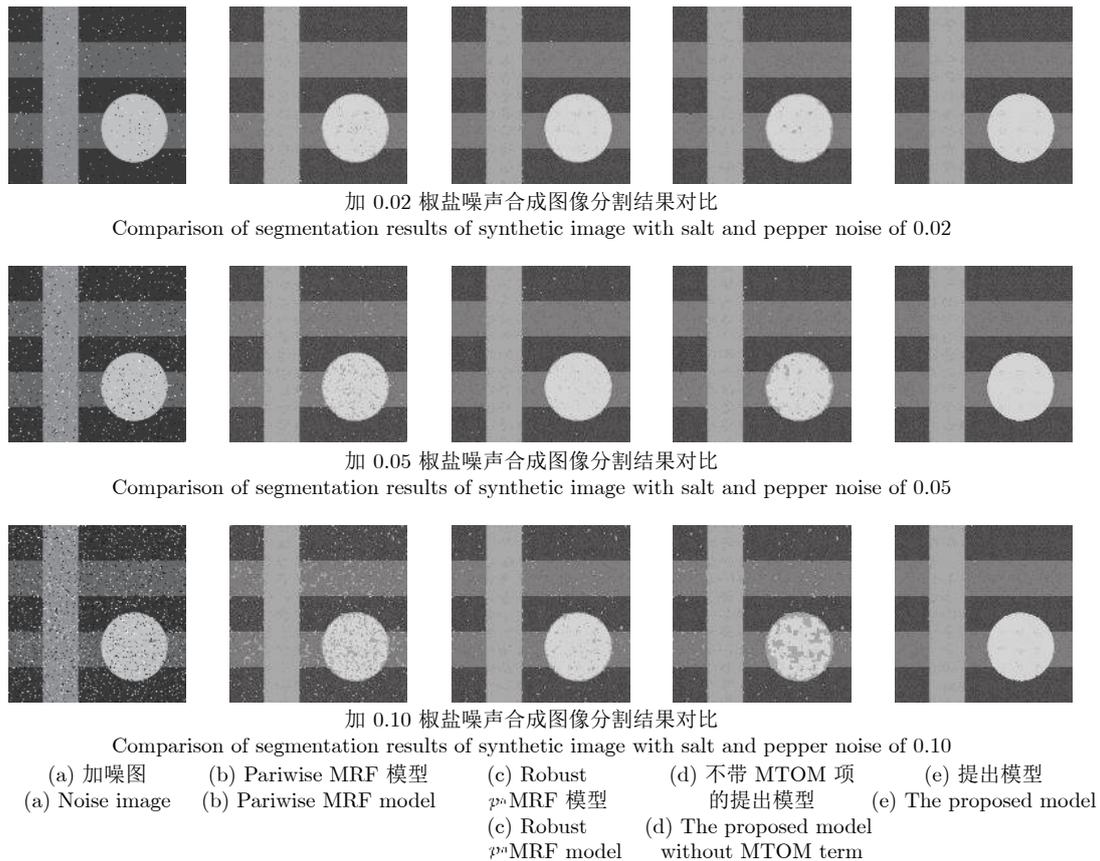


图 5 合成图像加椒盐噪声分割结果对比

Fig.5 Comparison of segmentation results of synthetic image with salt and pepper noise

息, 对不同类型噪声干扰鲁棒性更好, 在图像平坦区域获得了较平滑分割结果, 尤其是在图像分割的边缘区域得到了更好的效果。

2) 定量分析. 表 1 为基于上述 4 个模型对 T_image 人工合成图像加不同类型、不同强度噪声的人工合成图像分割结果的定量分析对比, 表中采用 50 次分割实验的平均 CCR 指标。

由表 1 可知, 基于区域的 Pairwise MRF 模型^[26]的 CCR 指标最低, 虽然这种算法利用局部区域内像素的点对交互引入了图像局部区域特征, 提升了图像分割效果, 但是局部区域能量项的引入增加了全局优化算法的迭代时间, 因此在对比较算法中虽然迭代次数少, 但是其分割时间相对较长. 基于 Robust \mathcal{P}^n MRF 模型在基于区域的 Pairwise MRF 模型^[26]基础上, 引入一种基于局部区域类别一致性 Robust \mathcal{P}^n 项, 有效提升了 CCR 指标, 但是高阶项的引入增加了算法的迭代次数和优化时间. MTOM-HMRF 模型针对区域 Pairwise MRF 模型^[26]引入 MTOM, 提升了图像高阶先验的表达能

力, 同时针对局部区域能量项的引入易造成边缘带现象, 去掉了局部区域能量项约束, 因此迭代次数虽然大大增加, 但是优化时间并没有显著增加. 在加高斯白噪声的分割结果中, 以噪声强度 900 为例, 在加入 Robust \mathcal{P}^n 高阶项后, 模型迭代次数成倍增加, 迭代时间降低, 正确分类率 CCR 提高了 4.43%. MTOM-HMRF 模型迭代次数相较于 Robust \mathcal{P}^n MRF 模型也显著增加, 但提出模型迭代时间更少, 正确分类率 CCR 在 Robust \mathcal{P}^n 模型的基础上仍提高了 6.45%. 同样, 在加椒盐噪声的分割结果中, 随着噪声强度增大, 对比模型正确分类率 CCR 显著降低, 而 MTOM-HMRF 模型表现稳健, 迭代时间略有增长. 因此提出模型对噪声有较好的抗干扰能力, 这是因为 MTOM-HMRF 模型有效描述了图像的高阶拓扑空间关系, 因而得到了更好的分割结果。

综上所述, 在不同类型、不同噪声强度人工合成图像分割实验中, 通过不同模型实验结果的定性分析和定量分析对比表明, 提出模型不仅对图像噪

表 1 人工合成加噪图像在不同模型下的分割结果对比
Table 1 Synthetic image segmentation results of different models

Image	Model	Number of iterations	Running time (s)	CCR (均值 \pm 标准差)
高斯白噪声方差 300	Pairwise MRF	46	12.496	0.9119 \pm 0.0020
	Robust \mathcal{P}^n MRF	94	13.014	0.9483 \pm 0.0019
	不带 MTOM 项的提出模型	162	17.374	0.9793 \pm 0.0012
	提出模型	133	10.486	0.9977 \pm 0.0002
高斯白噪声方差 900	Pairwise MRF	45	12.315	0.8854 \pm 0.0039
	Robust \mathcal{P}^n MRF	83	11.588	0.9297 \pm 0.0034
	不带 MTOM 项的提出模型	149	11.853	0.9902 \pm 0.0005
	提出模型	120	9.521	0.9942 \pm 0.0006
椒盐噪声 0.02	Pairwise MRF	44	11.917	0.8859 \pm 0.0034
	Robust \mathcal{P}^n MRF	80	11.873	0.9386 \pm 0.0019
	不带 MTOM 项的提出模型	144	10.017	0.9883 \pm 0.0004
	提出模型	163	12.947	0.9978 \pm 0.0001
椒盐噪声 0.05	Pairwise MRF	43	11.523	0.7463 \pm 0.0025
	Robust \mathcal{P}^n MRF	77	11.955	0.9017 \pm 0.0036
	不带 MTOM 项的提出模型	94	8.925	0.9784 \pm 0.0008
	提出模型	160	12.605	0.9976 \pm 0.0001
椒盐噪声 0.10	Pairwise MRF	41	10.997	0.5465 \pm 0.0027
	Robust \mathcal{P}^n MRF	78	11.290	0.7915 \pm 0.0047
	不带 MTOM 项的提出模型	76	7.556	0.9440 \pm 0.0012
	提出模型	155	12.248	0.9962 \pm 0.0003

声干扰有较强的鲁棒性, 而且在图像边缘区域获得了更好的分割精度, 因而提出模型具有更高的有效性和鲁棒性.

4.2 自然图像分割实验

为进一步验证提出模型的有效性和鲁棒性, 对自然图像进行分割对比实验. 实验用自然图像选自 Berkley 数据集 BSDS500^[29], 部分代表性的实验图像 ID 分别如图 6 所示. 待分割图像大小为 481×321 像素或 321×481 像素, 灰度值为 256. 分割类别人工设定: 3 096、135 069、196 073、8 068、189 080、198 087、15 088 分类数为 2, 62 096、167 062、238 011、253 036、24 063、311 068 分类数为 3, 241 004、55 067 分类数为 4. 图 6 中从上至下不同 MRF 模型的先验平滑参数 β 分别采用人工试错法选择最优值为 1.5、1.5、3.2、15.1、4.8、1.2、2.5、2.1、7.5、2、9、5、4.5、10、14. Robust \mathcal{P}^n MRF 模型局部区域设定为 3×3 像素块, 截断参数 Q 和惩罚参数 γ_{\max} 分别设定为 3 和 2.5. 提出模型局部区域设定为 3×3 像素块, 归一化尺度参数 ρ 和幂邻接参数 γ 分别设定为 0.2 和 4. GMM 参数由 EM 算法估计.

分割实验对比结果如图 6 所示, 图 6 (b) 列为基于区域的 Pairwise MRF 模型^[26] 分割方法的分割

结果, 图 6 (c) 列为基于 Robust \mathcal{P}^n MRF 模型分割方法的分割结果, 图 6 (d) 列为基于提出模型分割方法的分割结果, 图 6 (e) 列为 Ground Truth 图.

首先对自然图像分割结果进行定性分析. 从分割结果对比图中可以发现, 基于区域的 Pairwise MRF 模型分割结果较差, 这是由于 Pairwise MRF 模型的简单点对结构难以描述复杂的图像空间相关性特征, 因此对图像噪声和纹理特征干扰鲁棒性较弱, 如图 “196 073” 中丰富的 “沙粒” 特征, 图 “167 062”、“238 011” 中 “树叶” 和 “树枝” 纹理特征等对分割结果造成较大干扰, 出现较多 “斑点” 误分割区域. 与 Pairwise MRF 模型相比, 基于 Robust \mathcal{P}^n MRF 模型的分割结果得到一定提升, 如图 “196 073” 的分割结果中, “沙粒” 纹理干扰所造成的 “斑点” 误分割区域得到一定抑制. 但是由于 Robust \mathcal{P}^n MRF 模型假定局部区域中所有位置上的先验权重相同, 因此造成图像边缘、细节结构部分的分割结果不够精确, 如图 “62 096” 中 “风帆” 的 “横式手把柄” 没有得到较好的提取, 图 “167 062” 中 “树林” 与 “坡地” 之间的边界线出现了 “边缘带” 的现象等. 提出模型分割方法利用高阶拓扑结构引入更丰富的高阶空间相关性特征, 对于图像边缘、细节特征具有较好的分割结果, 如图 “167 062” 中 “树林” 与 “坡地” 之间的边界线, 图 “62 096” 中 “风帆”

的“横式手柄”,图“3 096”的“飞机”,图“135 069”的“飞鸟”等得到了较准确分割;同时对于图像纹理突变干扰具有较强鲁棒性,如图“196 073”中的“沙粒”,图“62 096”、“8 068”、“15 088”中的

“水波”,图“167 062”中的“雪地”,图“253 036”的“草地”,图“311 068”的“草丛”等区域得到更平滑的分割结果.因此,提出模型对复杂自然图像的强噪声和纹理突变干扰具有较强鲁棒性,显著提高了

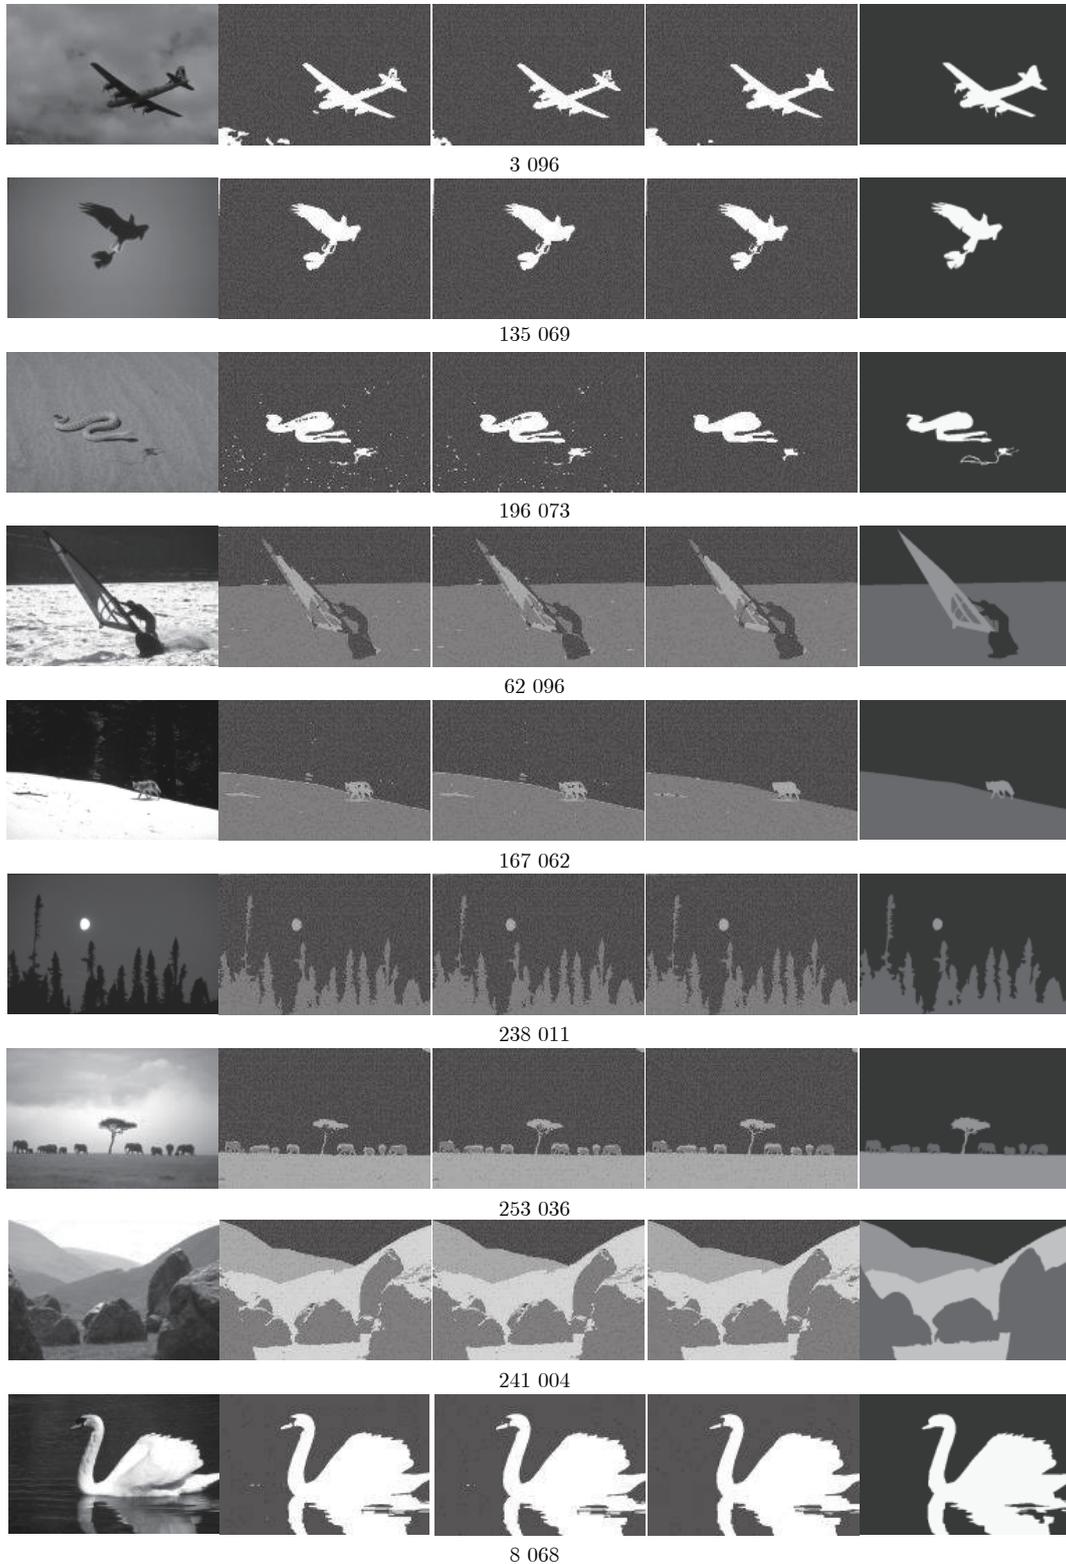




图 6 自然图像分割结果对比

Fig.6 Comparison of segmentation results of natural images

图像分割精度, 特别是在图像分割边缘处具有更高的分割精度.

然后进行定量分析, 对于自然图像分割结果评价常采用概率随机索引 PRI 和正确分类率 CCR, PRI 和 CCR 值越大, 分割精确度越高. 表 2 给出了对比图像在不同分割模型下所得到分割结果的 PRI 和 CCR 值. 由表 2 可知, 与对比分割模型相

比, 提出模型的 PRI 和 CCR 值最高, 即提出模型的分割精度优于所有对比模型. 表 2 也给出了三种模型在 BSDS500 数据集的分割结果评价, 与基于区域的 Pairwise MRF 模型^[26]、Robust P^n MRF 分割模型^[4] 相比, 提出模型分割结果的平均 PRI 指标分别提高了 9.30%、8.32%, 平均 CCR 指标分别提高了 9.74%、8.68%. 图 7、图 8 给出了三种模型在

表 2 自然图像在不同方法下的评价指标比较
Table 2 Comparison of evaluation indexes of natural image on different models

Image	Evaluation index	Pairwise MRF (均值 ± 标准差)	Robust \mathcal{P}^n MRF (均值 ± 标准差)	MTOM-HMRF (均值 ± 标准差)
3 096	PRI	0.9159 ± 0.0008	0.9398 ± 0.0024	0.9456 ± 0.0004
	CCR	0.9283 ± 0.0005	0.9431 ± 0.0003	0.9820 ± 0.0007
135 069	PRI	0.9635 ± 0.0003	0.9640 ± 0.0002	0.9652 ± 0.0004
	CCR	0.9646 ± 0.0002	0.9649 ± 0.0001	0.9943 ± 0.0000
196 073	PRI	0.8598 ± 0.0019	0.8818 ± 0.0026	0.9522 ± 0.0005
	CCR	0.9064 ± 0.0014	0.9186 ± 0.0016	0.9905 ± 0.0005
62 096	PRI	0.9331 ± 0.0006	0.9333 ± 0.0004	0.9451 ± 0.0006
	CCR	0.8970 ± 0.0006	0.8978 ± 0.0006	0.9611 ± 0.0003
167 062	PRI	0.9529 ± 0.0009	0.9542 ± 0.0007	0.9705 ± 0.0001
	CCR	0.9448 ± 0.0009	0.9464 ± 0.0007	0.9938 ± 0.0005
238 011	PRI	0.8631 ± 0.0001	0.8709 ± 0.0000	0.8711 ± 0.0001
	CCR	0.8428 ± 0.0042	0.8429 ± 0.0000	0.9697 ± 0.0000
253 036	PRI	0.9571 ± 0.0004	0.9574 ± 0.0002	0.9600 ± 0.0005
	CCR	0.9257 ± 0.0004	0.9286 ± 0.0008	0.9703 ± 0.0002
241 004	PRI	0.8758 ± 0.0002	0.8767 ± 0.0001	0.8801 ± 0.0005
	CCR	0.8182 ± 0.0003	0.8212 ± 0.0003	0.9236 ± 0.0002
8 068	PRI	0.9093 ± 0.0006	0.9100 ± 0.0004	0.9182 ± 0.0007
	CCR	0.9153 ± 0.0006	0.9154 ± 0.0005	0.9790 ± 0.0002
24 063	PRI	0.9043 ± 0.0003	0.9040 ± 0.0002	0.9076 ± 0.0035
	CCR	0.8910 ± 0.0039	0.8906 ± 0.0003	0.9572 ± 0.0003
55 067	PRI	0.9205 ± 0.0002	0.9545 ± 0.0001	0.9552 ± 0.0002
	CCR	0.8657 ± 0.0004	0.9072 ± 0.0002	0.9748 ± 0.0001
189 080	PRI	0.9009 ± 0.0002	0.9003 ± 0.0003	0.9066 ± 0.0014
	CCR	0.9181 ± 0.0003	0.9174 ± 0.0002	0.9727 ± 0.0003
198 087	PRI	0.8200 ± 0.0004	0.8188 ± 0.0005	0.8249 ± 0.0009
	CCR	0.8515 ± 0.0004	0.8493 ± 0.0003	0.9280 ± 0.0004
311 068	PRI	0.8688 ± 0.0017	0.6542 ± 0.0014	0.9265 ± 0.0016
	CCR	0.8819 ± 0.0012	0.7264 ± 0.0013	0.9743 ± 0.0004
15 088	PRI	0.8944 ± 0.0007	0.8948 ± 0.0007	0.9170 ± 0.0015
	CCR	0.9095 ± 0.0006	0.9096 ± 0.0006	0.9676 ± 0.0005
BSDS500数据集	PRI	0.6864	0.6962	0.7794
	CCR	0.6478	0.6584	0.7452

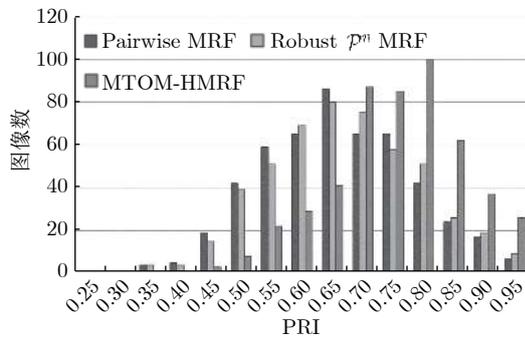


图 7 BSDS500 数据集 PRI 分布对比
Fig.7 Comparison of PRI distribution of BSDS500 data sets

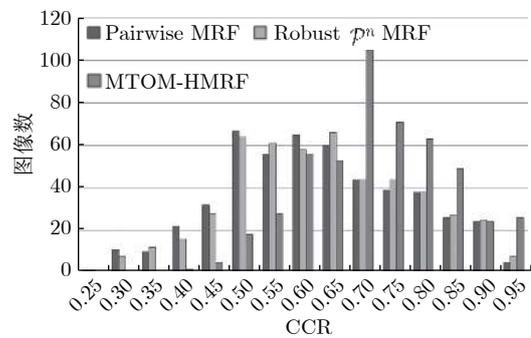


图 8 BSDS500 数据集 CCR 分布对比
Fig.8 Comparison of CCR distribution of BSDS500 data sets

表 3 自然图像在不同方法下的效率比较
Table 3 Comparison of the efficiency of natural image on different models

Image	Pairwise MRF		Robust \mathcal{P}^n MRF		MTOM-HMRF	
	Number of iterations	Running time (s)	Number of iterations	Running time (s)	Number of iterations	Running time (s)
3 096	44	13.356	84	26.084	112	9.578
135 069	33	10.192	60	18.440	140	12.045
196 073	47	14.184	87	26.472	134	11.559
62 096	44	17.130	83	33.516	139	15.443
167 062	40	15.558	88	33.239	109	12.082
238 011	9	3.466	74	22.964	101	11.919
253 036	42	16.144	74	29.421	171	19.248
241 004	46	21.275	80	32.993	197	25.981
8 068	43	13.405	89	27.509	154	19.192
24 063	73	29.401	74	29.421	197	32.271
55 067	38	19.117	34	17.517	146	31.874
189 080	38	12.476	72	22.266	189	23.924
198 087	41	12.927	79	25.239	177	23.081
311 068	44	18.138	88	36.111	153	26.101
15 088	42	12.881	87	27.319	116	15.346

BSDS500 数据集分割指标 PRI、CCR 的分布情况, 从图中可以看出, 提出模型的整体性能优于对比模型.

进一步对基于不同模型的分割效率进行对比, 由表 3 可以看出, 与基于区域的 Pairwise MRF 模型^[26]、Robust \mathcal{P}^n MRF 分割模型^[4] 相比, 为避免较大的局部区域能量最小化造成部分边缘出现边缘带现象, 提出模型的似然能量项采用了较小的 4 邻域结构, 因此提出模型虽然具有较高迭代次数, 但是运行时间和对比模型相比并没有显著增加. 综上所述, 提出模型能更好保持图像细节信息, 且具有更高的分割精度, 对复杂自然图像强噪声和纹理突变干扰具有更强的鲁棒性.

5 结论

本文提出一种基于多节点拓扑重叠测度高阶 MRF 模型的图像分割方法. 提出模型利用多节点拓扑重叠测度建立了图像的高阶 MRF 先验模型, 有效描述了图像局部区域内多节点间的拓扑结构信息, 提高了 MRF 先验模型对复杂自然图像的先验知识表达能力. 同时, 建立了一种基于局部区域的部分二阶 Potts 先验模型, 利用较大的局部区域引入更多的标签节点信息, 建立了基于局部区域不一致性惩罚的局部标签一致性约束. 然后, 利用邻接像素的 Hamming 距离引入图像局部空间相关性, 提出具有局部区域一致性的 WGMM, 有效描述了观察图像场与标签场之间复杂的似然特征分布. 最

后, 在 MRF 框架下, 提出了基于多节点拓扑重叠测度高阶 MRF 模型 (MTOM-HMRF) 的图像分割方法, 并利用 Gibbs 采样算法实现了模型优化. 大量实验结果表明, 提出模型不仅能有效抑制图像强噪声和纹理突变干扰, 鲁棒性更好, 而且具有更准确的图像分割边缘.

References

- 1 Yu Miao, Hu Zhan-Yi. Higher-order Markov random fields and their applications in scene understanding. *Acta Automatica Sinica*, 2015, **41**(7): 1213–1234
(余淼, 胡占义. 高阶马尔科夫随机场及其在场景理解中的应用. *自动化学报*, 2015, **41**(7): 1213–1234)
- 2 Kohli P, Kumar M P, Torr P H S. \mathcal{P}^3 & Beyond: Move making algorithms for solving higher order functions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, **31**(9): 1645–1656
- 3 Kohli P, Kumar M P, Torr P H S. \mathcal{P}^3 & Beyond: Solving energies with higher order cliques. In: Proceedings of the 2007 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2007). Minneapolis, MN, USA: IEEE, 2007. 1–8
- 4 Kohli P, Ladickuy L, Torr P H S. Robust higher order potentials for enforcing label consistency. In: Proceedings of the 2008 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2008). Anchorage, AK, USA: IEEE, 2008. 1–8
- 5 Xia Ping, Shi Yu, Lei Bang-Jun, Gong Guo-Qiang, Hu Rong, Shi Dong-Xia. Ultrasound medical image segmentation based on hybrid probabilistic graphical model in complex-wavelet domain. *Acta Automatica Sinica*, 2021, **47**(1): 185–196
(夏平, 施宇, 雷帮军, 龚国强, 胡蓉, 师冬霞. 小波域混合概率图模

- 型的超声医学图像分割. 自动化学报, 2021, **47**(1): 185–196)
- 6 Li S, Ishfaq A, Alexander J A. Superpixel-enhanced pairwise conditional random field for semantic segmentation. In: Proceedings of the 25th IEEE International Conference on Image Processing (ICIP). Athens, Greece: IEEE, 2018. 271–275
 - 7 Song Yan-Tao, Ji Ze-Xuan, Sun Quan-Sen. Brain MR image segmentation algorithm based on Markov random field with image patch. *Acta Automatica Sinica*, 2014, **40**(8): 1754–1763 (宋艳涛, 纪则轩, 孙权森. 基于图像片马尔科夫随机场的脑MR图像分割算法. 自动化学报, 2014, **40**(8): 1754–1763)
 - 8 Kim S, Chang D Y, Nowozin S, Kohli P. Image segmentation using higher-order correlation clustering. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2014, **36**(9): 1761–1774
 - 9 Ji Z X, Huang Y B, Sun Q S, Guo C. A spatially constrained generative asymmetric Gaussian mixture model for image segmentation. *Journal of Visual Communication and Image Representation*, 2016, **40**(PB): 611–626
 - 10 Zhang H, Wen T, Zheng Y H, Xu D H. Two fast and robust modified Gaussian mixture models incorporating local spatial information for image segmentation. *Journal of Signal Processing Systems*, 2015, **81**(1): 45–58
 - 11 Ji Z X, Huang Y B, Xia Y, Zheng Y H. A robust modified Gaussian mixture model with rough set for image segmentation. *Neurocomputing*, 2017, **266**: 550–565
 - 12 Niu S J, Chen Q, Sisternes L D, Ji Z X, Zhou Z M, Rubin D L. Robust noise region-based active contour model via local similarity factor for image segmentation. *Pattern Recognition*, 2017, **61**: 104–119
 - 13 Bi H, Tang H, Yang G. Accurate image segmentation using Gaussian mixture model with saliency map. *Pattern Analysis and Applications*, 2018, **21**: 869–878
 - 14 Xu Sheng-Jun, Meng Yue-Bo, Liu Guang-Hui, Yu Jun-Qi, Xiong Fu-Li, Hu Gao-Zhen. Local region consistency manifold constrained MRF model for image segmentation. *Control and Decision*, 2019, **34**(5): 997–1003 (徐胜军, 孟月波, 刘光辉, 于军琪, 熊福力, 胡高珍. 用于图像分割的局部区域一致性流形约束MRF模型. 控制与决策, 2019, **34**(5): 997–1003)
 - 15 Feng Bao, Chen Ye-Hang, Liu Zhuang-Sheng, Li Zhi, Song Rong, Long Wan-Sheng. Segmentation of breast cancer on DCE-MRI images with MRF energy and fuzzy speed function. *Acta Automatica Sinica*, 2020, **46**(6): 1188–1199 (冯宝, 陈业航, 刘壮盛, 李智, 宋嵘, 龙晚生. 结合MRF能量和模糊速度的乳腺癌图像分割方法. 自动化学报, 2020, **46**(6): 1188–1199)
 - 16 Shao Y, Sang N, Gao C, Li M. Spatial and class structure regularized sparse representation graph for semi-supervised hyperspectral image classification. *Pattern Recognition*, 2018, **81**: 81–94
 - 17 Dornaika F, Weng L. Sparse graphs with smoothness constraints: Application to dimensionality reduction and semi-supervised classification. *Pattern Recognition*, 2019, **95**: 285–295
 - 18 Ravasz E, Somera A L, Mongru D A, Oltvai Z N, Barabasi A L. Hierarchical organization of modularity in metabolic networks. *Science*, 2002, **297**(5586): 1551–1555
 - 19 Yip A M, Horvath S. Gene network interconnectedness and the generalized topological overlap measure. *BMC Bioinformatics*, 2007, **8**(1): 22
 - 20 Li A. Generalizations of the Topological Overlap Measure for Neighborhood Analysis and Module Detection in Gene and Protein Networks [Ph. D. dissertation], University of California, USA, 2008
 - 21 Steuer R, Kurths J, Daub C O, Weise J, Selbig J. Themutual information: Detecting and evaluating dependencies between variables. *Bioinformatics*, 2002, **18**(Suppl 2): S231–S240
 - 22 Shi X, Wang X, Shajahan A. BMRF-MI: Integrative identification of protein interaction network by modeling the gene dependency. *BMC Genomics*, 2015, **16**(7 Supplement): S10
 - 23 Lin S, Peter L, Steve H. Comparison of co-expression measures: Mutual information, correlation, and model based indices. *BMC Bioinformatics*, 2012, **13**: 328
 - 24 Langfelder P, Horvath S. WGCNA: An R package for weighted correlation network analysis. *BMC Bioinformatics*, 2008, **9**: 559
 - 25 André V, Eivind A. Assessment of weighted topological overlap (wTO) to improve fidelity of gene co-expression networks. *BMC Bioinformatics*, 2019, **20**: 58
 - 26 Xu Sheng-Jun, Han Jiu-Qiang, Zhao Liang, Liu Xin. Algorithm of minimizing local region energy for image segmentation. *Journal of Xi'an Jiao Tong University*, 2011, **45**(8): 7–12 (徐胜军, 韩九强, 赵亮, 刘欣. 用于图像分割的局部区域能量最小化算法. 西安交通大学学报, 2011, **45**(8): 7–12)
 - 27 Shi J, Malik J. Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, **22**(8): 888–905
 - 28 Streib K, Davis J W. Using Ripley's K-function to improve graph-based clustering techniques. In: Proceedings of the 2008 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2011). Providence, RI, USA: IEEE, 2011. 2305–2312
 - 29 Arbeláez P, Maire M, Fowlkes C. Contour detection and hierarchical image segmentation. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2011, **33**(5): 898–916



徐胜军 西安建筑科技大学信息与控制工程学院副教授。2013年获得西安交通大学工学博士学位。主要研究方向为图像处理, 人工智能与自动化。
E-mail: duplin@sina.com
(XU Sheng-Jun Associate professor at the School of Information and

Control Engineering, Xi'an University of Architecture and Technology. He received his Ph. D. degree of engineering from Xi'an Jiaotong University in 2013. His research interest covers image processing, artificial intelligence and automation.)



周盈希 西安建筑科技大学信息与控制工程学院硕士研究生. 主要研究方向为图像分割, 深度学习. 本文通信作者. E-mail: 13572978250@163.com

(ZHOU Ying-Xi Master student at the School of Information and Control Engineering, Xi'an University of Architecture and Technology. Her research interest covers image segmentation, deep learning. Corresponding author of this paper.)



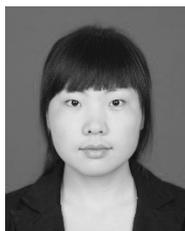
孟月波 西安建筑科技大学信息与控制工程学院副教授. 2014 年获得西安交通大学工学博士学位. 主要研究方向为机器学习, 建筑智能化技术. E-mail: mengyuebo@163.com

(MENG Yue-Bo Associate professor at the School of Information and Control Engineering, Xi'an University of Architecture and Technology. She received her Ph. D. degree of engineering from Xi'an Jiaotong University in 2014. Her research interest covers machine learning, intelligent building technology.)



刘光辉 西安建筑科技大学信息与控制工程学院副教授. 2016 年获得西安建筑科技大学工学博士学位. 主要研究方向为机器学习, 建筑智能化技术. E-mail: guanghuil@163.com

(LIU Guang-Hui Associate professor at the School of Information and Control Engineering, Xi'an University of Architecture and Technology. He received his Ph. D. degree of engineering from Xi'an University of Architecture and Technology in 2016. His research interest covers machine learning, intelligent building technology.)



史亚 西安建筑科技大学信息与控制工程学院讲师. 分别于 2008 年, 2011 年, 2015 年获得西安电子科技大学学士学位、硕士学位和博士学位. 主要研究方向为机器学习. E-mail: shiyaworld@163.com

(SHI Ya Lecturer at the School of Information and Control Engineering, Xi'an University of Architecture and Technology. She received her bachelor, master, and Ph. D. degrees from Xidian University in 2008, 2011, 2015. Her main research interest is machine learning.)