

用于图像分割的局部区域一致性流形约束MRF模型

徐胜军, 孟月波, 刘光辉[†], 于军琪, 熊福力, 胡高珍

(西安建筑科技大学 信息与控制工程学院, 西安 710055)

摘要: 针对区域马尔可夫随机场(MRF)模型难以有效描述图像复杂先验知识的问题,提出一种基于局部区域一致性流形约束MRF(LRCMC-MRF)模型. 首先,所提模型利用高维数据的低维流形分布表征图像局部区域的复杂几何结构先验,建立图像局部区域的流形先验约束;其次,基于Pairwise MRF模型,建立一种包含更多图像局部信息的局部空间自适应MRF模型;最后,基于贝叶斯理论,将复杂局部区域几何结构先验和局部空间自适应统计特征融合,利用Gibbs采样算法对所提出模型进行优化. 实验结果表明,与基于常规区域的MRF模型相比,所提出的分割算法具有较好的分割效果.

关键词: 流形学习; 马尔可夫随机场; 局部区域一致性; Gibbs采样算法; 图像分割

中图分类号: TP2391

文献标志码: A

Local region consistency manifold constrained MRF model for image segmentation

XU Sheng-jun, MENG Yue-bo, LIU Guang-hui[†], YU Jun-qi, XIONG Fu-li, HU Gao-zhen

(School of Information & Control Engineering, Xi'an University of Architecture & Technology, Xi'an 710055, China)

Abstract: Region-based Markov random fields (MRF) is usually difficult to effectively describe the prior knowledge of complex natural images. To solve this problem, a local region consistency manifold constrained MRF (RCMC-MRF) model is proposed. Firstly, the proposed model uses low-dimensional manifold distribution of high-dimensional data to characterize complex geometry structure prior in local region of images, and builds a localized manifold prior constraints term for the image segmentation model. Then, the proposed model utilizes more local region information of images to construct a local spatial adaptive MRF based on the pairwise MRF. Finally, the complex geometry structure prior and local spatial adaptive statistical feature in the local region are incorporated according to the Bayesian theory. The Gibbs sample algorithm is used for optimization. Compared with the conventional region-based MRF model, experimental result shows that the proposed model can provide a better segmentation result.

Keywords: manifold learning; Markov random fields; local region consistency; Gibbs sample algorithm; image segmentation

0 引言

近年来,基于马尔可夫随机场(Markov random fields, MRF)的图像处理技术受到了广泛的关注,成为图像分割领域的研究热点. MRF对自然图像建模增强了结构信息的关联性,这使得自然图像分割的速度和精度都有很大的提高. 但是,对于具有丰富统计特征的自然图像而言,基于常规点对交互结构的MRF(Pairwise MRF)模型不能充分描述自然图像复

杂的统计信息和先验知识. 因此,在图像分割问题中,这种基于Pairwise MRF模型的图像分割算法在图像的区域或者边缘经常出现误分割.

复杂的自然图像通常具有高维的非高斯统计特性,要准确构建图像的先验知识需要在扩展邻域上建模图像结构的依赖关系. 高阶MRF(Higher order MRF)能够表达更加复杂的先验知识及统计信息,但是由于高阶MRF模型的复杂度和模型参数学习的困

收稿日期: 2017-10-31; 修回日期: 2018-03-31.

基金项目: 国家重点研发计划项目(2017YFC0704100); 国家自然科学基金项目(61473216); 陕西省自然科学基金项目(2015JM6276, 2015JM6337); 陕西省教育厅专项项目(14JK1429, 18JK0477); 西安建筑科技大学基础基金项目(JC1415).

责任编辑: 张国山.

作者简介: 徐胜军(1976—),男,副教授,博士,从事图像处理、模式识别等研究; 刘光辉(1976—),男,副教授,博士,从事图像处理及其应用等研究.

[†]通讯作者. E-mail: duplin@sina.com.

难性,阻碍了其在图像处理领域进一步的应用. Kohli等^[1]提出了 \mathcal{P}^N Potts模型,将Potts模型的邻域一致性约束扩展到区域,建立了约束区域标签一致性的高阶能量模型.约束区域一致性的高阶能量模型尽管优化效率很高,但对于区域先验的表达能力有限^[2],特别是对于图像局部区域内的一些高维特征,这种约束区域一致性模型难以有效表达局部区域内的精细几何结构. Diplaros等^[3]利用邻域像素先验概率的Kullback-Leibler (K-L)散度描述邻域像素的空间相似性,提出了一种基于空间约束信息的MRF分割模型.宋艳涛等^[4]提出了一种基于图像片权重方法的MRF模型,根据高斯加权欧氏距离对邻域内不同图像片进行相似性度量,赋予邻域图像片不同的权重,在克服噪声干扰的同时,保持了图像细节信息.徐胜军等^[5]基于Pairwise MRF模型建立了一种空间自适应局部区域MRF分割模型,利用带权值自适应高斯模型简单地描述了图像内不同区域丰富的局部特征,并对局部区域先验知识进行自适应估计.

虽然基于局部区域MRF的方法采用距离度量方式(如欧氏距离、K-L距离等)引入图像局部区域的空间信息,并作为局部区域一致性约束,但是在欧氏空间里,表示空间中距离较近的样本点并不一定是在事物本身所处空间中距离最近,因而基于距离度量局部区域MRF模型不能有效描述复杂高维数据局部一致性特征.流形学习假设高维数据分布在一个光滑的非线性流形上,利用这个流形上各点间邻域关系或者全局测地距离获得保持分布在流形上的高维数据的低维表示.谱图理论和流形学习理论的研究证明,高维数据局部几何结构能够有效通过最近邻图进行建模^[6].基于此,He等^[7]提出了LapGMM (Laplacian regularized Gaussian mixture model)模型,利用最近邻图建模高维数据流形结构,并作为GMM模型正则项,引入了高维数据局部几何空间特征;Liu等^[8]基于K-L散度量测最近邻节点概率分布的距离,建立了一种LCGMM (Locally consistent gaussian mixture model)模型.但是,LapGMM模型和LCGMM模型仅考虑高维数据局部几何结构特征,而忽略了高维数据全局流形特征.Fisher等^[9]利用流形学习方法建模图像块局部纹理流形结构,并基于MRF将图像块的局部一致性传递到图像的全局,在图像降噪和图像补全问题的应用研究表明,所提模型在表达图像局部纹理模式方面是优于专家场(FoE)模型的.

为了描述复杂高维数据的空间几何特征,有效建立图像局部区域的一致性约束,本文基于流形学习,利用高维数据的分布来发现隐含在图像局部区域的流形结构,从而更有效地描述图像局部区域内的精

细几何结构特征.同时,基于MRF,利用更大的图像局部区域包含更多局部空间信息的特征,建立图像局部区域的局部统计特征模型.最终,将流形学习描述的局部区域几何结构特征和图像局部统计特征结合起来,建立一种新的基于局部区域一致性流形约束的MRF模型.利用Gibbs采样算法对所提出模型进行优化,并基于最大后验准则(MAP)估计图像的分割结果.

1 基于流形学习的局部一致性约束

1.1 流形学习

给定观察样本集 $X = \{x_1, x_2, \dots, x_N\}$ 为独立同分布的随机样本,其中 $x_s \in \mathbb{R}^D$.设 $Y \in \mathbb{R}^d$ 是一个低维流形, $f: Y \rightarrow \mathbb{R}^D$ 是一个光滑嵌入在 D 维欧氏空间中的 d 维流形,其中 $D > d$.数据集 $\{y_s\}$ 是随机生成的,且经过 f 映射为观察样本空间的数据 $\{x_s = f(y_s)\}$.流形是指局部同胚于一个欧氏空间的几何体,而流形学习是在给定有限的观察样本集 X ,且关于 Y 和 d 的先验知识未知条件下,重构高维空间的低维光滑嵌入 $f(\cdot)$,并找到与观察样本集 X 一一对应的低维嵌入 $Y = \{y_1, y_2, \dots, y_N\}$,其中 $y_s \in \mathbb{R}^d$.

基于谱图理论和流形学习的研究表明,数据流形的局部几何结构可以通过一个最近邻图有效描述^[6].在样本集 X 中,构建一个加权无向图 $G = (V, E, W)$.其中: V 是顶点集合, E 是边的集合, W 是图 G 的权值矩阵.假设顶点集合中第 s 个顶点表示为 x_s , $N_k(x_s)$ 为样本点 x_s 的 k 近邻集,如果 $x_s \in N_k(x_r)$ 或 $x_r \in N_k(x_s)$,则样本点 x_s 与 x_r 是相邻的,其权值衡量两个样本点之间的相似度,表示为 w_{sr} .距离较近的样本点其权值较大,反之较小,因而合适的权值能有效保持高维空间在低维映射的局部空间关系.根据谱图理论^[8,10],热核函数常被认为是建立空间约束权值的一个好的选择,其权值 w_{sr} 定义如下:

$$w_{sr} = \exp\left(-\frac{\|x_s - x_r\|^2}{t}\right), \quad (1)$$

其中 t 为热核参数.这个参数基于不同最近邻节点距离的远近控制着节点的相对重要性.根据式(1),图 G 的相似度邻接矩阵 W 如下所示:

$$W_{sr} = \begin{cases} w_{sr}, & x_s \in N_k(x_r) \text{ or } x_r \in N_k(x_s); \\ 0, & \text{else.} \end{cases} \quad (2)$$

1.2 概率框架下的流形一致性约束

在概率框架下,与观察样本集 $X = \{x_1, x_2, \dots, x_N\}$ 一一对应的隐变量标签集合为 $Y = \{y_1, y_2, \dots, y_N\}$.其中: $y_s \in \{1, 2, \dots, K\}$, K 为类别总数.令 $P(X, Y)$ 表示观察样本集和隐变量的联合概率分布,根据贝叶斯定理,有

$$P(X, Y) = P(X|Y) \cdot P(Y). \quad (3)$$

其中: $P(X|Y)$ 表示给定标签集 Y 时观察样本集 X 的条件概率分布; $P(Y)$ 表示标签集 Y 的先验分布.

欧氏距离度量仅能反映样本空间局部分布特征,不能反映复杂数据集的全局一致性特征^[11]. Laplacian 特征映射基于谱图理论,通过图的嵌入寻找流形的低维表示,将样本数据在高维空间复杂分布投影到低维空间,在局部建立降维映射关系,并利用流形在局部与欧氏空间的同胚,在低维空间建立表示流形的几何结构关系. 令光滑嵌入 $f_k(x)$ 为一个条件概率分布 $p(y = k|x)$, 即

$$f_k(x) = p(y = k|x), \forall k \in \{1, 2, \dots, K\}. \quad (4)$$

条件概率分布 $p(y = k|x)$ 局部信息度量 S_k 定义如下:

$$S_k = \frac{1}{2} \sum_{s=1}^N \sum_{r=1}^N D(p(k|x_s), p(k|x_r))^2 W_{sr}. \quad (5)$$

其中: $D(p(k|x_s), p(k|x_r))^2$ 表示两个相邻节点 x_s 和 x_r 的条件概率分布 $p(y_s|x_s)$ 和 $p(y_r|x_r)$ 的距离. 根据流形假设,如果相邻节点 x_s, x_r 的条件概率分布 $p(y_s|x_s)$ 和 $p(y_r|x_r)$ 显著不相同,则 W_{sr} 具有较大的惩罚权值;反之, W_{sr} 的惩罚权值较小.

基于 K-L 散度方法常用来度量两个样本点的条件概率分布 $p(y_s|x_s)$ 和 $p(y_r|x_r)$ 的距离,有

$$D(p(k|x_s), p(k|x_r)) = \sum_{y \in y_{\delta_s}} p(y_s|x_s) \log \frac{p(y_s|x_s)}{p(y_r|x_r)}. \quad (6)$$

由于上述 K-L 散度的不对称性,本文采用 D_{sr} 来测量样本点的条件概率分布的距离,有

$$D_{sr}(p(y_s|x_s) || p(y_r|x_r)) = \frac{1}{2} (D(p(y_s|x_s), p(y_r|x_r)) + D(p(y_r|x_r), p(y_s|x_s))). \quad (7)$$

利用最近邻图 G 的相似度邻接矩阵式(2)、条件概率分布的局部信息度量式(5)以及样本点的条件概率分布的距离式(7),建立图像局部区域一致性流形约束项,描述图像局部区域的内在几何结构

$$S_k = \sum_{s=1}^N \sum_{r=1}^N D_{sr}(p(y_s|x_s) || p(y_r|x_r)) W_{sr}, \quad (8)$$

其中局部信息度量 S_k 衡量了条件概率分布 $p(k|x)$ 的局部最小邻域图的平滑程度. 因此,对于局部信息度量 S_k 的最小化表明,如果相邻节点 x_s 与 x_r 距离较近,则其条件概率分布 $p(y_s|x_s)$ 和 $p(y_r|x_r)$ 也是较接近的. 在内蕴几何结构中,沿着测地线的条件概率分布是平滑的. 因而,局部信息度量 S_k 的最小化有效度量了条件概率分布 $p(y = k|x)$ 的平滑性, S_k 越小,沿着测地线的条件概率分布 $p(y = k|x)$ 越平滑. 因此,基

于局部信息度量 S_k 的测度更准确地反映了数据在空间分布的先验信息.

2 局部空间自适应MRF分割模型

令观察样本集 $X = \{x_1, x_2, \dots, x_N\}$ 表示一个包含 N 个像素的二维图像,图像中任一像素用强度值 x_s 表示,且 $s \in N, \forall x_s \in \{0, 1, 2, \dots, 255\}$. 假定图像 X 可被分割为 K 类,且图像中任一像素 x_s 唯一对应一个标签 $y_s, \forall y_s \in \Omega, \Omega \in \{0, 1, 2, \dots, 255\}$. 所有像素的标签组成一个标签场 $Y = \{y_1, y_2, \dots, y_N\}$.

基于 MRF 的图像分割问题中,设 Y 为以 δ 为邻域系统的马尔可夫随机场,根据其马尔可夫性, MRF 的全局分布由其节点的局部分布通过节点之间的交互关系得到. 节点 s 的局部空间特征由该节点的邻域节点决定,其邻域节点集合表示为 δ_s . 研究表明,在 Pairwise MRF 模型中,引入更多的区域信息可以表达更复杂的图像区域特征,提升 Pairwise MRF 模型的表达能力,同时不显著增加 MRF 模型的学习和优化困难. 因此,作为一种有效的近似方法,基于区域的 MRF 模型得到了广泛的关注^[5-8],这种方法在许多图像处理问题中得到了鲁棒的处理结果.

由于 MRF 全局分布划分函数求解困难,常将 MRF 全局分布的最大后验概率求解问题转化为能量最小化问题. 建立的基于局部空间自适应 MRF 能量分割模型如下所示:

$$E_{\text{Global}}(Y|X, \Theta, \beta) \propto \sum_{s=1}^N \left\{ \left[-w_s(y_s, y_s) \log p(x_s|y_s, \Theta) - \sum_{r \in \delta_s} w_r(y_s, y_r) \log p(x_r|y_r, \Theta) \right] - \sum_{r \in \delta_s} \log p_{\delta_s}(y_s|y_{\delta_s}, \beta) \right\}. \quad (9)$$

其中:第1项为 E_{Data} 项,表示局部区域内 MRF 模型的似然能量项. $p(x_s|y_s, \Theta)$ 表示给定条件 (y_s, Θ) 时节点 x_s 的条件分布, Θ 表示条件分布的参数. $w_r(y_s, y_r)$ 表示中心节点 s 与其邻域节点 r 的权值函数,用一个标准正态分布函数描述为

$$w_r(y_s, y_r) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2|S(y_r)|^2}\right). \quad (10)$$

这里 $S(y_r) = \{y_r|y_s = y_r, \forall r \in \delta_s\}$ 表示在邻域集 δ_s 中,与中心节点 s 的标签值相等的邻域节点标签的集合, $|S(y_r)|$ 表示集合 $S(y_r)$ 的势. 在局部区域内,与中心节点 s 的标签值相同的邻域节点越多,该权值越大. 第2项为 E_{Smooth} 项,表示 MRF 模型的先验平滑能量项, β 表示 MRF 的先验参数, δ_s 表示节点 s 的邻域节点集合.

标签 y 的取值过程可以看作是一个函数 f 在离散定义域 Ω 上的求值过程: $f : Y \rightarrow \Omega$. 这个映射

函数通常用高斯混合模型 (Gaussian mixture model, GMM) 来描述. 在局部区域内, 假定各像素点是独立同分布的, 则标签 y_s 的条件分布如下所示:

$$p(x_s|y_s, \Theta) = \prod_{k \in K} \frac{1}{\sqrt{2\pi\sigma_k^2}} \exp\left\{-\frac{(x_s - \mu_k)^2}{2\sigma_k^2}\right\}, \quad (11)$$

其中 μ_k 和 σ_k^2 分别为 GMM 第 k 类均值和方差.

假定标签场 Y 满足马尔可夫性, 即标签场中任一标签的取值仅与该标签的邻域状态有关, 对标签场中非邻域标签的影响可以通过节点的局部交互关系传递到标签场的全局, 从而得到标签场的全局表达, 这样将 MRF 分布的全局标签优化问题转换成一个局部标签的优化问题. 根据 Hammersley-Clifford 等效定理^[12], 局部区域标签场 y_{δ_s} 由 Gibbs 分布描述如下:

$$p_{\delta_s}(y_s|y_{\delta_s}, \beta) = \frac{\exp\{-\beta\mathcal{H}_{y_{\delta_s}}^{\text{prior}}\}}{\sum_{y_{\delta_s}} \exp\{-\beta\mathcal{H}_{y_{\delta_s}}^{\text{prior}}\}}. \quad (12)$$

其中: $\beta > 0$ 为 Gibbs 分布参数; $\sum_{y_{\delta_s}} \exp\{-\beta\mathcal{H}_{y_{\delta_s}}^{\text{prior}}\}$ 为 Gibbs 分布的划分函数, 在 y_{δ_s} 分布组态确定时, 这个划分函数是一个常量; $\mathcal{H}_{y_{\delta_s}}^{\text{prior}}$ 为局部区域标签场 y_{δ_s} 的 Gibbs 自由能量函数, 令

$$\mathcal{H}_{y_{\delta_s}}^{\text{prior}} = \sum_{r \in y_{\delta_s}} \delta(y_s, y_r), \quad (13)$$

$\delta(y_s, y_r)$ 为一个 kroneker 函数, 描述了中心节点 s 的标签 y_s 与其所有邻接节点标签 y_r 之间的交互关系, 且具有对称性, 即 $\delta(y_s, y_r) = \delta(y_r, y_s)$.

将式 (11)~(13) 代入 MRF 能量分割模型 (9), 则基于局部区域 MRF 图像分割的能量最小化问题如下所示:

$$\begin{aligned} \hat{Y} = \arg \min_{Y \subset \Omega} E_{\text{Global}}(Y|X, \Theta, \beta) \propto \\ \arg \min_{Y \subset \Omega} \left\{ \sum_{s=1}^N w_s(y_s, y_s) \frac{(x_s - \mu_k)^2}{2\sigma_k^2} + \right. \\ \left. \sum_{r \in \delta_s} w_r(y_s, y_r) \frac{(x_r - \mu_k)^2}{2\sigma_k^2} + \beta \sum_{r \in y_{\delta_s}} \delta(y_s, y_r) \right\}. \end{aligned} \quad (14)$$

其中: $w_r(y_s, y_r)$ 衡量了中心节点 s 与其所有邻域节点的相似程度, 在一定程度上保证了与中心节点 s 越相似的邻域节点倾向于取相同的标签值; $\sum_{r \in \delta_s} \delta(y_s, y_r)$ 为局部区域内标签场 y_{δ_s} 的先验分布, 在局部区域内, 与中心节点 s 的标签值相同的邻域节点具有较小的惩罚, 反之惩罚较大. 因此, 该先验分布为一个局部一致性的约束, 即约束中心节点 s 的邻域节点标签值相同. 根据分析可以发现, 该模型引入了图像局部区域的空间结构信息.

3 局部区域一致性流形约束 MRF 模型

3.1 模型建立

局部空间自适应 MRF 模型引入了更多的图像区域信息, 建立了局部区域类别一致性的约束, 使得局部区域内所有像素倾向于取相同的标签值. 对于图像分割问题而言, 这种区域类别一致性约束对于图像的噪声或者纹理突变信号的干扰具有一定的鲁棒性, 因此基于这种模型的分割方法可以得到较为平滑的分割结果, 但是局部区域先验 $\beta \sum_{r \in y_{\delta_s}} \delta(y_s, y_r)$ 是对局部区域 y_{δ_s} 不满足类别一致性时的惩罚, 即只要中心节点 s 的任一邻域节点的标签值不等于中心节点的标签值, 则局部区域先验的惩罚为 $\beta\mathcal{H}_{y_{\delta_s}}^{\text{prior}}$. 这样会导致一些过分割问题, 特别是在分割的对象边缘, 由于这种区域先验模型倾向于使得区域内部像素取同一个标签值, 容易导致边缘的误分割.

由 2.2 节分析可知, 基于局部信息度量 S_k 的测度更准确反映了数据在高维空间几何分布的先验信息. 在内蕴几何结构中, 局部信息度量 S_k 是沿着流形最短距离计算得到的. 局部信息度量 S_k 越小, 即样本点条件概率分布的距离越小, 表明沿着测地线的条件概率分布 $p(k|x)$ 越平滑. 因此, 局部信息度量 S_k 的最小化能够有效描述图像局部像素间的低维近邻关系.

基于式 (14) 建立的局部区域 MRF 全局能量分割模型, 引入图像局部区域一致性流形约束项, 得到局部区域一致性流形约束 MRF (LRCMC-MRF) 图像分割模型如下所示:

$$\begin{aligned} \hat{Y} = \arg \min_{Y \subset \Omega} E_{\text{Global}}(Y|X, \Theta, \beta) + \lambda \sum_{k=1}^K S_k \propto \\ \arg \min_{Y \subset \Omega} \left\{ \left[\sum_{s=1}^N w_s(y_s, y_s) \frac{(x_s - \mu_k)^2}{2\sigma_k^2} + \right. \right. \\ \left. \sum_{r \in \delta_s} w_r(y_s, y_r) \frac{(x_r - \mu_k)^2}{2\sigma_k^2} \right] + \\ \left. \beta \sum_{r \in y_{\delta_s}} \delta(y_s, y_r) + \lambda \sum_{k=1}^K S_k \right\}. \end{aligned} \quad (15)$$

从式 (15) 可以看出, 所提出的 LRCMC-MRF 图像分割模型包含 3 项: 第 1 项为 E_{Data} 项, 表示能量模型的似然项, 在局部空间自适应 GMM 中, 权值 $w_r(y_s, y_r)$ 引入相似像素之间的空间信息; 第 2 项为 E_{Smooth} 项, 表示局部区域的先验项, 利用较大的区域先验知识, 有效避免了噪音或者纹理突变干扰, 保持了图像的一些明显的局部结构, 参数 β 控制着局部区域的平滑度; 第 3 项为流形约束项 E_{Manifold} , 表示局部区域概率分布的空间几何结构先验, 利用更复杂的高维流形结构信息, 避免了局部区域先验的过平滑惩罚, λ 是一个约束项参数, 控制着概率分布内蕴几何函数的复杂

度.由此可以看出,该模型充分利用了图像的灰度信息和复杂的空间结构信息,不仅对图像噪声和纹理突变有很好的鲁棒性,而且能保持图像细节特征.

3.2 参数估计

提出的LRCMC-MRF模型包含3类参数:局部空间自适应GMM参数 $\Theta = \{\alpha_k, \mu_k, \sigma_k^2\}$ 、局部区域先验模型参数 β 以及流形一致性区域约束项参数 λ .参数 β 和 λ 的最优值采用试验法给定,即通过大量分割实验选择分割结果最好的参数值确定为最优值.给定图像观察场 X ,局部空间自适应GMM参数 Θ 的最大似然估计公式如下:

$$\hat{\Theta} = \arg \max_X P_{\text{Global}}(Y|X, \Theta, \beta) + \lambda \sum_{k=1}^K S_k. \quad (16)$$

上述参数估计问题是一个带有隐变量的参数估计问题,对于这类含有“不完整数据”的参数估计问题,期望最大化算法(EM算法)是一个有效估计算法.要估计GMM模型参数 Θ ,EM算法通常分为E-Step和M-Step两步完成.

E-Step:根据第 $t-1$ 次估计的局部空间自适应GMM参数 $\Theta^{(t-1)}$,估计样本 x_s 对第 k 个局部区域GMM的贡献,则估计隐变量 $y_s = k$ 时后验概率为

$$P(y_s = k | x_s, x_{\delta_s}, \Theta_k^{(t-1)}) = \frac{\alpha_k^{(t-1)} P_{\text{Local}}(x_s, x_{\delta_s} | \Theta_k^{(t-1)})}{\sum_{s=1}^N \alpha_k^{(t-1)} P_{\text{Local}}(x_s, x_{\delta_s} | \Theta_k^{(t-1)})}, \quad (17)$$

其中 $\Theta_k^{(t-1)} = \{\alpha_k^{(t-1)}, \mu_k^{(t-1)}, \sigma_k^{2(t-1)}\}$ 为第 k 个高斯分布的参数.

M-Step:根据式(17)估计的局部空间自适应GMM的后验概率 $P(y_s = k | x_s, x_{\delta_s}, \Theta_k^{(t-1)})$,对GMM的参数估计如下:

$$\hat{\alpha}_k = \frac{1}{N} \sum_{s=1}^N P(y_s = k | x_s, x_{\delta_s}, \Theta_k^{(t-1)}), \quad (18)$$

$$\hat{\mu}_k = \frac{\sum_{s=1}^N \left(x_s + \sum_{r \in \delta_s} p(k | x_s) \right) + \frac{\lambda}{2} \sum_{s,r=1}^N \{ (p(k | x_s) - p(k | x_r))(x_r - x_s) W_{sr} \}}{\sum_s (1 + |\delta_s|) p(k | x_s)}, \quad (19)$$

$$\hat{\sigma}_k^2 = \frac{\sum_{s=1}^N p(k | x_s) \left((x_s - \mu_k)^2 + \sum_{r \in \delta_s} (x_r - \mu_k)^2 \right) + \frac{\lambda}{2} \sum_{s,r=1}^N \{ (p(k | x_s) - p(k | x_r))(x_r - \mu_k)^2 - (p(k | x_s) - p(k | x_r)) W_{sr} \}}{4 \sum_s (1 + |\delta_s|) p(k | x_s)}, \quad (20)$$

其中 $|\delta_s|$ 为中心节点 s 的邻域节点数.

4 实验结果和分析

为验证所提出的局部区域一致性流形约束MRF(LRCMC-MRF)分割模型的有效性,分别对人工加噪声图像(如图1(a)所示)和自然图像(如图2(a)、图3(a)所示)进行分割实验,对比分割模型分别采用基于常规点对MRF分割模型(Pairwise MRF)和基于局部空间自适应MRF(Local spatial adaptive MRF, LSAMRF)模型.基于Pairwise MRF分割方法采用GMM模型建立标签场 Y 和观察图像场 X 之间的先验分布,GMM参数由EM算法估计.标签场 Y 先验模型采用Potts模型,其先验参数 β 由实验给定.LSAMRF模型局部区域的大小选择 3×3 像素块,每个子图的局部特征由空间自适应GMM模型来描述,其参数 $(\alpha_k, \mu_k, \sigma_k^2)$ 由EM算法估计.每个子图对应一个局部标签场,其先验模型由Potts模型描述,局部区域Potts先验参数 β_s 由改进的ASA算法估计,模型细节参见文献[5].提出的LRCMC-MRF模型中,局部空间自适应GMM参数 $(\alpha_k, \mu_k, \sigma_k^2)$ 由EM算法迭代公式(18)~(20)估计得到.局部区域先验Gibbs分布参数 β 由实验人工选择对应分割结果最好的参数值,一般对于噪声较大或者纹理复杂的图像, β 取值较大,有助于平滑分割结果,反之取值较小.在建立的流形一致性约束项中, k 近邻参数的大小定义了图像流形结构的局部性,其中 k 取值为 $\{4, 8, 12\}$.正则项参数 λ 控制了条件概率分布的平滑性,取值为 $[0.001 \ 1]$,通过搜索不同参数值对实验结果的影响,确定最优参数取值.通过实验发现,当 k 取值为 $\{4, 8, 12\}$ 和 λ 在 $[0.001 \ 1]$ 区间变化时,提出模型的分割结果保持了较好的性能.但是对于 k 近邻参数而言,选择较大的邻域不能确保局部邻域的线性空间假设,并且显著增加了MRF模型的计算复杂度,基于MRF模型的Gibbs采样算法每次采样的计算复杂度为 $O(|\delta_s|K)$,其复杂度与局部区域的像素个数 $|\delta_s|$ 以及分割类别数 K 成正比.因此,考虑到计算效率和精确性的平衡, k 近邻参数设定为8.热核参数 t 设定为 $[5 \ 100]$,具体值根据实验效果确定.

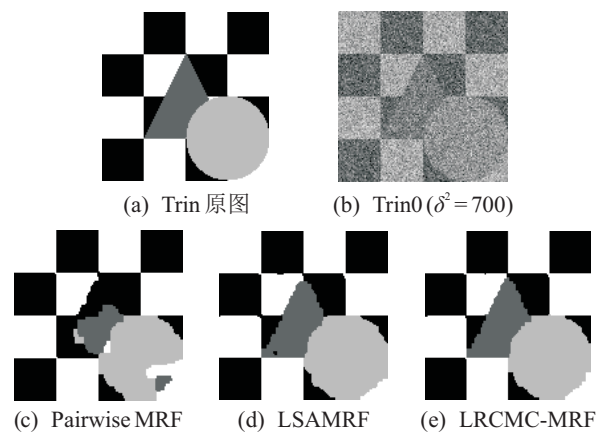


图1 人工加噪声图像“Trin0”分割结果对比

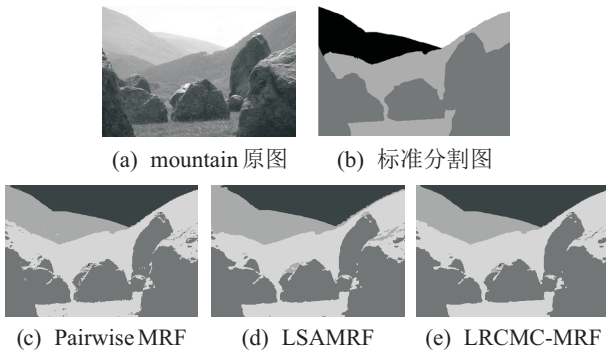


图2 “mountain”图像分割结果对比

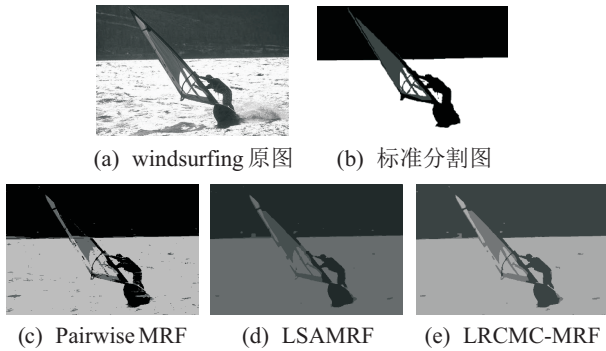


图3 “windsurfing”图像分割结果对比

4.1 人工加噪声图像分割实验及分析

给定人工图像“Trin”(大小为 128×128 ,灰度级为256),如图1(a)所示.设定“Trin”图像分类数为4类,其均值分别为0、85、170、255.人工为原始图像“Trin”添加方差为700的高斯白噪声,加噪声图像如图1(b)所示.实验中,分别采用基于Pairwise MRF分割模型、基于LSAMRF分割模型^[8]以及提出的LRCMC-MRF分割模型进行分割实验,3个MRF模型的先验参数 β 均设定为1.2. LRCMC-MRF模型参数 λ 设定为0.001,分割算法采用Gibbs采样算法,分割结果如图1所示.从图1可以发现,由于Pairwise MRF模型的先验知识仅考虑了节点之间的点对交互,不能充分描述图像的空间相关性特征,因此较强的噪声对分割结果干扰较大,造成基于Pairwise MRF分割模型的分割效果最差.基于LSAMRF分割模型引入了 3×3 的子图空间信息,较好地描述了图像局部空间相关性特征,能够抑制较强的噪声对图像分割结果的干扰,因此其分割结果较平滑,但由于图像边缘特征的高维复杂性,这种均匀的区域特征模型不能准确对边缘特征进行建模,容易造成边缘的误分割,出现“边缘带”现象.提出的LRCMC-MRF模型基于流形学习将复杂的高维图像边缘特征表达为一个欧氏空间的低维特征,有效描述了图像的局部几何结构特征,得到了更准确的分割结果.

表1中不同模型的误分率结果对比充分说明了以上结论,表中参数误分率 $r_{MC}(\%)$ 定义如下:

$$r_{MC} = \frac{1}{N} \sum_{s=1}^N (1 - \delta(\hat{y}_s, y_s^{\text{true}})). \quad (21)$$

其中: \hat{y}_s 为第 s 个像素估计的标签值, y_s^{true} 为第 s 个像素的真实标签值, N 为像素总数, $\delta(\hat{y}_s, y_s^{\text{true}})$ 为一个kroneker函数.

表1 人工加噪声图像分类结果和迭代时间对比

模型	误分类率/%	迭代时间/s
Pairwise MRF	9.2597	3.922
LSAMRF	1.6235	4.110
LRCMC-MRF	1.2878	10.311

4.2 自然图像分割实验及分析

为了进一步验证提出的LRCMC-MRF模型的有效性和鲁棒性,对自然图像进行分割实验,待分割自然图像分别如图2(a)和图3(a)所示.其中:图2(a)“mountain”原图大小为 481×321 ,分割类别设定为5类;图3(a)“windsurfing”原图大小为 481×321 ,分割类别设定为3类.分割实验中,分别采用基于Pairwise MRF分割模型、基于LSAMRF模型^[8]以及所提出的LRCMC-MRF模型等进行分割实验,分割结果对比分别如图2和图3所示,其中人工分割的标准分割图分别如图2(b)和图3(b)所示.图2和图3模型的先验参数 β 分别设定为2.3和2.0, LRCMC-MRF模型约束项参数 λ 分别设定为0.001和0.047.

从不同分割模型对比结果可以看出:基于Pairwise MRF分割模型的分割结果最差,这是由于Pairwise MRF模型的点对交互结构过于简单,使得其难以有效表达复杂图像的先验知识,导致图像噪声或者纹理突变等因素对图像分割结果造成很大干扰.图2(c)“mountain”图像的分割结果中,“草地”、“岩石”等区域有明显的分割噪声.图3(c)“windsurfing”图像的分割结果中,“海水”区域的分割有较多的分割斑点噪声,特别是“风帆”的上半部分出现了明显的误分割.基于LSAMRF分割模型引入了图像的区域特征,包含了更多的图像区域信息,对噪声或者纹理信号的突变具有较好的鲁棒性,其分割结果分别如图2(d)、图3(d)所示.从分割结果可以看出,“mountain”图像的“草地”和“岩石”区域、“windsurfing”图像的“海水”区域,以及“windsurfing”图像中“风帆”的上半部分已经能得到较正确的分割,但是由于区域MRF模型的求解过程中局部区域的能量最小化容易导致“sibling competition”现象,导致在一些图像的分割边缘出现了“边缘带”的现象,如图2(d)“mountain”图像的分割结果所示,在“天空”和“山”之间出现了一条边缘带.提出的LRCMC-MRF模型首先利用局部空间自适应GMM考虑了相似像素之间的空间

信息,有效避免了噪音或者纹理突变的干扰,然后建立了图像的局部流形约束项,有效描述了局部区域复杂的空间几何结构先验,避免了常规局部区域先验的过平滑惩罚,保持了自然图像的一些明显的局部结构.由图像分割结果可以发现,提出的LRCMC-MRF模型不仅具有较好的分割结果,而且有效解决了如图2(d)“mountain”图像分割结果的边缘带.在图3“windsurfing”图像分割结果中,不仅在“海洋”区域分割具有较好的鲁棒性,而且保持了图像的一些细节特征,如“windsurfing”图中的“横式手把柄”得到了有效的提取等.由此可以看出,提出的LRCMC-MRF模型充分利用了图像的灰度信息和复杂的空间结构信息,不仅对图像的噪音和纹理突变有很好的鲁棒性,而且保持了图像细节特征.

进一步对基于不同模型的分割效率进行对比,结果如表2所示.与实验图像的专家手工分割的标准分割图相比,提出的LRCMC-MRF模型在误分类率上是优于对比模型的.在分割时间上,提出模型比LSAMRF模型的运行时间稍短,相对于Pairwise MRF模型运行时间较长,但分割精度明显优于Pairwise MRF模型.结合图像分割结果和分割准确度对比可知,尽管提出模型的分割时间较长,但相比其他模型,提出模型能够更好地保持图像中的细节纹理特征,较好的图像分割结果体现了模型的优越性.

表2 自然图像误分类结果和迭代时间对比

图像	模型	误分类率/%	迭代时间/s
mountain	Pairwise MRF	19.63	17.112
	LSAMRF	15.60	232.661
	LRCMC-MRF	9.35	196.812
windsurfing	Pairwise MRF	13.65	21.563
	LSAMRF	5.38	150.281
	LRCMC-MRF	4.33	154.062

5 结论

本文提出了一种用于图像分割的局部区域先验一致性流形约束MRF(LRCMC-MRF)模型.所提出的LRCMC-MRF模型基于流形学习,利用数据的低维流形分布特性有效地描述了图像局部区域空间几何结构先验,建立了表征局部区域空间几何结构特征的流形约束项;进一步地,基于空间自适应GMM模型建立了一种局部区域自适应MRF模型,有效包含了更多图像空间特征信息;最后,将局部几何结构特征、局部区域似然特征和先验知识结合起来,提出了一种新的基于局部区域一致性流形约束的MRF模型的图像分割算法.实验结果表明,所提出的LRCMC-MRF模型具有较强的抗噪性和鲁棒性,同时能较好地保持图像的几何结构特征,有效克服了Pairwise

MRF模型对噪声或者纹理突变敏感的缺陷以及常规区域MRF分割模型的边缘带现象,获得了较为理想的分割结果.

参考文献(References)

- [1] Kohli P, Kumar M P, Torr P H S. \mathcal{P}^3 & beyond: Move making algorithms for solving higher order functions[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2009, 31(9): 1645-1656.
- [2] 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[J]. 自动化学报, 2015, 41(7): 1213-1234. (Yu M, Hu Z Y. Higher-order Markov random fields and their applications in scene understanding[J]. Acta Automatica Sinica, 2015, 41(7): 1213-1234.)
- [3] Diplaros A, Vlassis N, Gevers T. A spatially constrained generative model and an EM algorithm for image segmentation[J]. IEEE Trans on Neural Networks, 2007, 18(3): 798-808.
- [4] 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[J]. 自动化学报, 2014(8): 1754-1763. (Song Y T, Ji Z X, Sun Q S. Brain MR image segmentation algorithm based on Markov random field with image patch[J]. Acta Automatica Sinica, 2014(8): 1754-1763.)
- [5] 徐胜军, 韩九强, 刘光辉, 等. 基于局部空间自适应MRF模型的图像分割[J]. 控制与决策, 2013, 28(6): 889-893. (Xu S J, Han J Q, Liu G H, et al. Image segmentation based on local spatial adaptive markov random field model[J]. Control and Decision, 2013, 28(6): 889-893.)
- [6] Yan S C, Xu D, Zhang B Y, et al. Graph embedding and extensions: A general framework for dimensionality reduction[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2007, 29(1): 40-51.
- [7] He X F, Cai D, Shao Y L, et al. Laplacian regularized gaussian mixture model for data clustering[J]. IEEE Trans on Knowledge & Data Engineering, 2011, 23(9): 1406-1418.
- [8] Liu J, Cai D, He X. Gaussian mixture model with local consistency[C]. The 24th AAAI Conf on Artificial Intelligence. Atlanta: AAAI Press, 2010: 512-517.
- [9] Fisher J, Lin D. Manifold guided composite of Markov random fields for image modeling[C]. 2012 IEEE Computer Vision and Pattern Recognition. Providence: IEEE Press, 2012: 2176-2183.
- [10] Chung F R K. Spectral graph theory, CBMS regional conference series in mathematics[M]. Providence RI: AMS, 1997: 1-21.
- [11] 张震, 汪斌强, 李向涛, 等. 基于近邻传播学习的半监督流量分类方法[J]. 自动化学报, 2013, 39(7): 1100-1109. (Zhang Z, Wang B Q, Li X T, et al. Semi-supervised traffic identification based on affinity propagation[J]. Acta Automatica Sinica, 2013, 39(7): 1100-1109.)
- [12] Li S Z. Markov random field modeling in computer vision[M]. New York: Springer-Verlag, 2001: 13-16.