

基于多尺度图谱和局部谱的目标提取算法*

王永国, 彭国华, 王小龙, 唐 梦

(西北工业大学 理学院, 西安 710129)

摘 要: 针对多尺度图谱算法不能有效提取含有较多纹理或包含差异较大区域的目标物体, 提出了一种结合图像平滑、多尺度图谱和局部谱的目标提取方法。首先对图像进行 l_0 梯度最小化平滑处理, 锐化边缘的同时消除图像的部分纹理信息; 其次通过多尺度图谱方法对图像进行分割, 该算法结合了归一化割算法的高精确度和多尺度算法的高效率性; 最后结合局部谱理论, 将人工选取的种子区域作为约束条件, 进行有偏割向量估计, 通过最大类间方差法将该向量分割成目标和背景。实验表明, 该方法弥补了多尺度图谱算法的不足, 并能产生很好的目标提取效果。

关键词: l_0 梯度最小化; 图像平滑; 归一化割; 多尺度图谱; 局部谱; 最大类间方差法; 目标提取

中图分类号: TP391.41

文献标志码: A

文章编号: 1001-3695(2013)05-1577-05

doi:10.3969/j.issn.1001-3695.2013.05.078

Object extraction algorithm based on multi-scale spectral and local spectral

WANG Yong-guo, PENG Guo-hua, WANG Xiao-long, TANG Meng

(School of Science, Northwestern Polytechnical University, Xi'an 710129, China)

Abstract: Aiming at the drawback of multi-scale spectral which could not extract object region that contained many difference areas or challenging textures. This paper proposed a novel scheme of object extraction. This new scheme was based on image smoothing, multi-scale spectral and local spectral. Firstly, it smoothed the image, sharpening major edges while eliminating part of textures by gradient minimization. Secondly, it used multi-scale spectral image segmentation algorithm to partition image, which combined high accuracy of normalized-cut algorithm and high efficiency of multi-scale algorithm. Finally, combining with local spectral theory, it selected seed region as an additional constraint, then characterized the optimal solution to new problem and showed that it could be interpreted as a locally-biased vector. This locally-biased vector was divided into object and background by maximum variance between clusters. Experimental results show that the proposed approach makes up for the shortage of multi-scale spectral and obtains more satisfactory results.

Key words: l_0 gradient minimization; image smoothing; normalized-cut; multi-scale spectral; local spectral; maximum variance between clusters; object extraction.

0 引言

目标提取是对特定区域的图像分割。图像分割是利用灰度、颜色、纹理、形状等信息将图像划分成具有不同特性的区域, 是图像处理领域中的关键问题。图像分割的主要方法^[1]有活动轮廓法、图像分裂与合并法、基于图论的方法, 以及能量最小化方法等。其中图割方法是图像分割领域研究比较热的方法, 它具有很强的理论依据和较好的分割结果。

对于纹理复杂或有噪声的图像, 在图像分割前需要进行预处理。图像分割的预处理主要是将图像的不显著边缘(即部分纹理)去掉, 同时去掉部分噪声, 保留显著边缘。常用的预处理方法有: 双边滤波器法^[2](BLF), 它是早期的图像平滑算法, 根据位置和像素的相似度生成不同的权重表, 在计算中心像素时考虑这两个权重表, 从而实现双边低通滤波; 梯度最小化图像平滑法, 即定义一种梯度的 l_p ($0 \leq p \leq 1$) 范数^[3-5]作为能量函数的正则项, 最小化能量函数, 实现图像的平滑处理, 不同范数的特点在第1章介绍; 另外还有利用扩散方程理论进行

图像平滑, 如 PM 方程、ROF 模型等。实验表明, 没经过预处理的复杂图像会产生严重的过分割或分割错误现象, 预处理后则会产生更好的分割效果。

多尺度图谱算法是多尺度框架和图割的结合算法。图割方法有很多种, 其中 Shi 等人^[6]提出的归一化割方法(NCut)较其他图割方法更有优势, 分割时不会产生偏向较小或较大区域的情况。由于图割算法构造的权值矩阵阶数较大, 计算效率较低, 因此引入多尺度弥补该方法的不足。多尺度图谱在构造边权值矩阵时, 计算不同尺度上近邻域像素之间的相似性; 而在图割算法中, 需要计算单尺度上大邻域像素之间的相似性。前者构造的权值矩阵阶数变小, 计算效率提高, 并且大尺度像素间的权值反映了图像的整体框架。图像的多尺度包括小波多尺度、金字塔多尺度、代数网格多尺度等。Sharon 等人^[7]将代数网格理论与图割方法结合应用于图像分割, 用图像光谱信息进行图上边权重的度量, 实现了快速分割。Galun 等人^[8]对文献^[7]中边的权重计算进行拓展, 考虑了更多的纹理特征, 有纹理的平均长、平均宽、纹理方向、滤波响应等信息, 通过指数

收稿日期: 2012-09-07; 修回日期: 2012-10-28 基金项目: 国家自然科学基金资助项目(61070233)

作者简介: 王永国(1988-), 男, 陕西西安人, 硕士, 主要研究方向为图像处理、计算机视觉(wangyg1807@mail.nwpu.edu.cn); 彭国华(1962-), 男, 湖北黄冈人, 教授, 博导, 主要研究方向为计算机图形学、计算机辅助几何处理、图像处理、计算机视觉; 王小龙(1988-), 男, 陕西安康人, 博士研究生, 主要研究方向为图像处理、计算机视觉; 唐梦(1987-), 女, 陕西西安人, 硕士研究生, 主要研究方向为图像处理、计算机视觉。

加权值对各特征进行整合,对纹理图像有较好的适应性。Alpert 等人^[9]也用到了该多尺度方法,但对特征整合方法进行了改进,将指数加权方法改为概率统计模型。上述方法是基于数据驱动的尺度变化,各个尺度只能串行运算。Cour 等人^[10]采用了一种金字塔多尺度方法,其特点是各个尺度预先定好,通过约束矩阵保持各个尺度之间的一致性,可以在多个尺度下进行并行分割计算,提高了算法的时间效率。因此本文采用金字塔多尺度方法进行图像分割。

多尺度图谱分割是全局谱最优,对图像的整体分割效果比较好,但对包含差异较大区域的目标物体不能产生较好的分割效果。文献[11,12]引入局部谱概念,对全局谱方法进行改进,采用人工选取的种子节点集作为附加约束条件,使分割区域的向量和种子节点相关性更大,分割结果将会逼近种子节点所在的区域(即目标物体),文中详细地给出该局部谱理论基础。文献[13]将局部谱与轮廓检测相结合应用于图像分割,文献[14]将局部谱和 Bezier 曲线相结合进行医学图像的边缘定位,都产生了较好效果。文献[15]提出一种综合轮廓检测、图像多尺度和分水岭算法的方法,并结合人工交互作用,最终产生了较好的分割效果,因此,多尺度图谱和交互作用在图像分割中有着广阔的前景。本文将局部谱与多尺度图谱算法有机结合,在多尺度图谱算法基础上,根据人工选取的种子区域,对分割图像进行有偏割向量估计,有偏割向量为目标分割的指示向量,通过指示向量提取出目标对象。该算法既结合了多尺度图谱算法的优势,又结合了局部谱的优势。

1 l_0 梯度最小化的图像平滑

Li 等人^[5]提出一种 l_0 梯度最小化的图像平滑算法,该算法能够有效地保持显著边缘,同时去除部分噪声和不重要的细节部分。平滑后的图像有利于边界特征提取,对图像分割起到了很好的预处理效果。

图像梯度的 l_0 范数定义为 $C(S)$,如式(1)所示:

$$C(S) = \#\{p \mid |\partial_x S_p| + |\partial_y S_p| \neq 0\} \quad (1)$$

其中: S_p 表示图像 S 在像素点 p 的灰度值, $\nabla S_p = (\partial_x S_p, \partial_y S_p)^T$ 是像素点 p 的 x 方向和 y 方向的梯度, $C(S)$ 统计梯度幅值 $|\partial_x S_p| + |\partial_y S_p|$ 不为零的像素点 p 的个数, $\#$ 表示个数。

二维图像平滑的目标函数为

$$\min_{S, \nu} \left\{ \sum_p (S_p - I_p)^2 + \lambda C(S) \right\} \quad (2)$$

其中: I 和 S 分别表示输入图像和输出图像; I_p 和 S_p 分别表示对应像素点 p 的灰度值; λ 为平滑因子,用来调节图像的平滑程度和输出图与输入图的相似程度。目标函数的第一项是保真项,其作用是使原始图像和平滑后的图像尽可能地相似。第二项是正则项,当 $C(S)$ 值比较大时,梯度幅值不为零的个数较多,保留的边缘数较多;当 $C(S)$ 值较小时,梯度幅值不为零的个数较少,保留的边缘数相对较少。由于第一项的限制,第二项保留的边缘主要为显著边缘,部分不重要的边缘(即过细的纹理信息)被平滑。

式(2)第一项是有关图像全局离散量的统计,第二项是有关像素级梯度模值的计算量,因此该目标函数不易求解。为方便求解式(2)的目标函数,引入辅助变量 h_p 和 ν_p ,它们分别对应梯度 $\partial_x S_p$ 和 $\partial_y S_p$,则式(2)可按式(3)近似求解。

$$\min_{S, h, \nu} \left\{ \sum_p (S_p - I_p)^2 + \lambda C(h, \nu) + \right.$$

$$\left. \beta \sum_p ((\partial_x S_p - h_p)^2 + (\partial_y S_p - \nu_p)^2) \right\} \quad (3)$$

其中: $C(h, \nu) = \#\{p \mid |h_p| + |\nu_p| \neq 0\}$; β 为自适应参数,它控制变量 (h, ν) 和对应梯度 $(\partial_x S_p, \partial_y S_p)$ 之间的相似性。通过相互迭代 (h, ν) 和 S 求解式(3)。

为计算 (h, ν) ,去除式(3)中与 (h, ν) 无关的第一项,得到

$$\min_{h, \nu} \left\{ \sum_p ((\partial_x S_p - h_p)^2 + (\partial_y S_p - \nu_p)^2) + \frac{\lambda}{\beta} C(h, \nu) \right\} \quad (4)$$

为计算 S ,去除式(3)中与 S 无关的第二项,得到:

$$\min_p \left\{ (S_p - I_p)^2 + \beta \sum_p ((\partial_x S_p - h_p)^2 + (\partial_y S_p - \nu_p)^2) \right\} \quad (5)$$

算法 1 L_0 梯度最小化。

a) 输入:图像 I ,平滑因子 λ ,参数 β_0 和 $\beta_{\max}$,比率参数 κ 。

b) 初始化。 $S \leftarrow I, \beta \leftarrow \beta_0, i \leftarrow 0$ 。

c) 迭代。由 $S^{(i)}$,根据式(5)求解 $h_p^{(i)}$ 和 $\nu_p^{(i)}$;

由 $h_p^{(i)}$ 和 $\nu_p^{(i)}$,根据式(4)求解 $S^{(i+1)}$;

$\beta \leftarrow \kappa \beta, i \leftarrow i + 1$;

当 $\beta \geq \beta_{\max}$ 时,停止迭代。

d) 输出:结果图像 S 。

实验表明,当 β 和 $\beta_{\max}$ 固定取 2λ 和 $1E5$, κ 取 2 时,算法能够取得效率和效果的最佳平衡^[5]。

该算法引进了梯度的 l_0 范数,相比 TV 算子^[3]中梯度的 l_1 范数和文献[4]中梯度的 l_p ($0.5 \leq p < 1$) 范数,该算法对图像的边缘锐化效果更好。这主要是由于其他梯度算法考虑梯度大小,大边缘处梯度大,对能量函数起到大的惩罚,求解时必然产生边缘模糊;而 l_0 范数只考虑非零的梯度模值个数,不考虑梯度大小,因此大边缘处不会对能量函数产生大的惩罚,在图像平滑的同时保留了显著边缘。因此本文采用 l_0 梯度最小化的图像平滑进行预处理。

2 多尺度图谱模型

多尺度图谱是图割和多尺度结合的方法。对给定的图像 I ,构造一个无向权重图 $G = (V, E, W)$,其中像素作为图的节点 V ,像素间距离小于等于 G_r 的像素相连构成图的边。权重矩阵中的 $W(i, j)$ 是度量像素 i 和 j 属于同类区域的概率大小。因此图像分割问题等价于图的划分问题。

2.1 相似性度量和归一化割

图边权重度量的准确性决定了图像的分割质量。好的权重能够客观地描述像素之间的相似度关系,本文采用光谱信息和边缘作为像素间的相似性度量特征。光谱信息包括像素的位置和像素的灰度值,像素间光谱信息越接近,像素间边的权重越小,文献[6,7,10]均用到该特征。当背景与目标物体的光谱信息比较相似时,只利用光谱信息不能得到很好的分割效果,因此本文另外考虑了边缘特征。该特征也是一个相对比较重要的相似性度量特征,若像素间存在的边缘越强,像素间边的权重越大,文献[10,15]均用到该特征作为权重计算的一部分。

给定一个图像 I 和其中两个邻近的像素 i 和 j ,光谱信息在权值中的度量用 $W_l(i, j)$ 表示:

$$W_l(i, j) = e^{-\|L_i - L_j\|^{2/\delta_L} - \|I_i - I_j\|^{2/\delta_I}} \quad (6)$$

其中: L_i 和 I_i 分别表示像素的位置和灰度大小。边缘信息在权值中的度量用 $W_c(i, j)$ 表示:

$$W_c(i, j) = e^{-\max_{x \in \text{line}(i, j)} \|\text{edge}(x)\|^{2/\delta_C}} \quad (7)$$

其中: $\text{line}(i, j)$ 是连接 i 和 j 的直线段, $\text{edge}(x)$ 是在 x 处的边缘强度。结合两个特征构造边的权值如下:

$$W(i, j) = \sqrt{W_l(i, j) \times W_c(i, j)} + \alpha W_c(i, j) \quad (8)$$

其中 α 为调节因子, 它调节边缘特征与光谱信息在图的权重构造中的比例。

用图构造、归一化割^[6]将图像分割转换为 K 类分割问题:

$$\bar{X} = \arg_{X=[X_1, \dots, X_K]} \max \mathcal{E}(X) = \frac{1}{K} \sum_{l=1}^K \frac{X_l^T W X_l}{X_l^T D X_l} \quad (9)$$

其中: X_l 是像素的区域指示函数, 即 $X_l(i) = 1$ 当且仅当像素 i 属于区域 l ; D 为对角矩阵, $D(i, i) = \sum_j W(i, j)$ 。该优化问题的解为式(10)的前 K 个广义最大特征值所对应的特征向量 V 张成的子空间:

$$WV = \lambda DV \quad (10)$$

求解该优化问题, 根据 X_l 可以得到每个像素所属的区域。

2.2 多尺度图谱模型

同一幅图像在不同的尺度上可以提取不同的特征, 大尺度上提取的特征反映图像整体框架特征, 小尺度上提取的特征反映局部特征, 可结合图像的不同尺度特点进行权重构造和特征提取。金字塔图谱法相对图割法, 图的权重构造矩阵阶数减少, 且多尺度计算时可以并行计算。在进行多尺度图谱分析时, 通过尺度制约性约束, 分割的代价函数被迫从一个尺度传播到另一个尺度; 通过尺度一致性约束, 不同尺度的对象最终达到统一。

多尺度分割矩阵 X_{MS} 和多尺度权重矩阵 W_{MS} 定义为

$$X_{MS} = [X_{MS}^{(0)}, \dots, X_{MS}^{(N-1)}]^T \quad (11)$$

$$W_{MS} = \text{diag}[W_{MS}^{(0)}, \dots, W_{MS}^{(N-1)}] \quad (12)$$

其中: $X_{MS}^{(n)}$ 是在尺度 n ($0 \leq n \leq N-1$) 上像素的指示性矩阵, 即 $X_{MS}^{(n)}(i, l) = 1$ 当且仅当尺度 n 上的节点 i 属于分割部分 l 。 $W_{MS}^{(n)}$ 是尺度 n 上的权重矩阵。 $X_{MS}^{(n)}$ 的维数为 $T_n \times K$, 而 X_{MS} 的维数为 $T^* \times K$, $T^* = \sum_{n=0}^{N-1} T_n$, 其中 T_n 表示尺度 n 上的图像像素个数。 X_{MS} 又可以表示为

$$X_{MS} = [y_1, \dots, y_K, \dots, y_K] \quad (13)$$

其中: y_k ($0 \leq k \leq K$) 维数为 $T^* \times 1$, $y_k \in \{0, 1\}^{T^* \times 1}$, 且 $X_{MS} \mathbf{1}_K = \mathbf{1}_{T^*}$, 即每一个行向量和为 1。

为了提高计算效率, 在本文的计算中, 没有根据 X_{MS}^* 进行逐尺度计算 $W_{MS}^{(n)}$, 而是在原始图像上计算 $W_{MS}^{(0)}$, 然后对 $W_{MS}^{(0)}$ 直接逐次降采样并计算 $W_{MS}^{(n)}$ 。逐尺度计算方法是基于数据驱动影响的尺度变换, 如文献[7~9]。逐次降采样方法则是直接将尺度固定好, 再通过约束条件将各个尺度的特征综合起来, 如文献[10]。本文采用后者方法, 这种直接降采样的方式并没降低分割的性能, 尺度制约性约束和尺度一致性约束可以由尺度制约矩阵 C 、尺度插值矩阵 $C_{n,n+1}$ 和多尺度分割方程式(16)来表示。

$$C = \begin{pmatrix} C_{0,1} & -I_1 & 0 & 0 & 0 \\ 0 & C_{1,2} & -I_2 & 0 & 0 \\ 0 & 0 & C_{2,3} & -I_3 & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & C_{N-2,N-1} & -I_{N-1} \end{pmatrix} \quad (14)$$

$$C_{n,n+1}(i, j) = \begin{cases} \frac{1}{|N_i|} & j \in N_i \\ 0 & \text{其他} \end{cases} \quad (15)$$

$$CX_{MS} = 0 \quad (16)$$

矩阵 $C_{s,s+1}$ 的大小为 $T_s \times T_{s+1}$, N_i 是尺度间降采样的邻域, 于是多尺度图像分割可表示为下面的有约束的优化问题, 约束条件为式(15)

$$\bar{X}_{MS} = \arg_{X_{MS}=[y_1, \dots, y_K]} \max \frac{1}{K} \sum_{l=1}^K \frac{y_l^T W_{MS} y_l}{y_l^T D_{MS} y_l} \quad (17)$$

其中: $D_{MS}(i, i) = \sum_j W_{MS}(i, j)$, 约束条件为式(15)。由于该问题求解是 NP 问题, 因此利用谱方法进行近似有效的求解, 即式(10)求解。

文献[16]对式(10)的求解进行了深入考虑, 根据广义 Rayleigh-Ritz 定理将上述问题转换为求解下面问题。

计算 QPQ 的最大 K 个特征值 $S = \text{diag}([s_1, s_2, \dots, s_K])$ 和最对应的特征向量 $\bar{V} = [\bar{v}_1, \bar{v}_2, \dots, \bar{v}_K]$ 。

$$QPQ \bar{V} = \bar{V} S \quad (18)$$

$$P = D^{-\frac{1}{2}} W D^{-\frac{1}{2}} \quad (19)$$

$$Q = I - D^{-\frac{1}{2}} C^T (C D^{-1} C^T)^{-1} C D^{-\frac{1}{2}} \quad (20)$$

$D^{-\frac{1}{2}} \bar{V}$ 的二值离散化是本文所要求解的 $\bar{X}_{MS}$ 。 $\bar{X}_{MS}$ 的每个列向量表示一个图像的分割区域, 总共分割为 K 个区域。

算法 2 金字塔多尺度图谱算法。

a) 给定一个 $p \times q$ 的图像 I , 对于尺度 $n = 1, \dots, N$, 其中 N 为最大尺度。

(a) 从小尺度图像中像素 $i \in I_n$, 下采样得到大尺度图像中的像素 $j \in I_{n+1}$, 采样比率为 ρ , 采样到的像素个数为 $\frac{P_n}{\rho} \times \frac{q_n}{\rho}$, 其中 $p_n \times q_n$ 为 I_n 的像素个数;

(b) 根据式(15)计算约束矩阵 $C_{n,n+1}(i, j)$;

(c) 在图像尺度 n 上, 根据半径 r 内像素间的光谱信息和边缘计算 $W_{MS}^{(n)}$, 计算公式为式(8)。

b) 根据式(12)(14)从 $W_{MS}^{(n)}$ 和 $C_{n,n+1}$ 计算 W 和 C 。

c) 由式(18)计算 QPQ 的最大 K 个特征值和对应特征向量。

d) 根据特征值和特征向量对图像进行划分。

3 局部谱

全局谱算法在分割时考虑全局最优, 对特定的目标并非最优, 本文引入局部谱^[11~13]解决该问题。局部谱理论引入向量的相关性, 在目标物体中选取种子节点集作为先验的局部信息, 节点集用向量表示, 将全局谱算法所得割向量与种子节点向量相关性进行计算, 相关性小将产生大的惩罚, 相关性大将产生小的惩罚, 分割结果就会偏向于种子节点所指示的目标物体。

3.1 相关概念

令 $G = (V, E, W)$ 表示无方向权重图, 图的顶点数 $n = |V|$, 边数 $m = |E|$, 边 ij 的权重构造为 $w(i, j)$ 。权重矩阵 $W_G = [w(i, j)]_{n \times n}$, 定点 i 的权重为 $D_G(i, i) = d_i = \sum_{j \in V} w(i, j)$ 。在图上对于顶点集 $S \subseteq V$, 则 S 的容量为 $\text{vol}(S) = \sum_{i \in S} d_i$, 同理整个图的容量 $\text{vol}(G) = \sum_{i \in V} d_i = \sum_i d_i$ 。 G 的拉普拉斯矩阵为 $L_G = D_G - W_G$ 。 $K_G = D_G^{-\frac{1}{2}} L_G D_G^{-\frac{1}{2}}$ 为规范的拉普拉斯矩阵。 S 的补集为 $\bar{S} = V/S$, S 和 $\bar{S}$ 的割为两者之间所有边的权重之和, 即 $\text{cut}(S, \bar{S}) = \sum_{i \in S, j \in \bar{S}} w(i, j)$ 。对应于 $(S, \bar{S})$ 的归一化割的定义为

$$\varphi(S) = \text{Ncut}(S) = \frac{\text{cut}(S, \bar{S})}{\text{vol}(S)} + \frac{\text{cut}(\bar{S}, S)}{\text{vol}(\bar{S})} \quad (21)$$

其中, $\text{vol}(S) + \text{vol}(\bar{S}) = \text{vol}(G)$ 。一个好的二划分相当于求解

最小的 $\varphi(S)$, 等价于求解拉普拉斯矩阵第二个最小特征向量。

若 G 是连通的, 由式 (22) 计算 L_G 关于 D_G 的广义的特征值和特征向量, 其中特征值为 $0 = \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$, 对应的特征向量为 $v_1, v_2, \dots, v_n$, v_1 是单位 1 向量。

$$L_G v_i = \lambda_i D_G v_i \quad (22)$$

两向量 s 和 t 在图中的相关性定义为 $K(s, t) = (s D_G t)^2$ 。根据文献 [11] 可知最优的有偏二划分为 $\min \psi(S)$ 。

$$\psi(S) = \frac{\varphi(S)}{(1-\beta) + \beta K(S, T)} \quad (23)$$

其中: T 为种子集向量; S 是分割特征向量; β 为平衡全局最优和局部最优的参数, 当 β 为 0 时, 方程退化为归一化割。固定 β , 当分割区域和种子向量相关性较大时, 目标函数产生小的惩罚; 当两者相关性较小时, 目标函数产生大的惩罚。因此目标函数最优时, 分割结果偏向于种子节点集。

式 (24) (25) 分别表示全局谱与局部谱最优的求解方程, 式 (24) 中条件 1 保证解的归一化性, 即归一化割的本质; 条件 2 保证解与向量 1 的正交性, 即解向量与向量 1 的相关性为 0。局部谱增加的条件 3 表示所求解向量和种子集向量的相关性要达到 κ , 因此图像的分割结果会偏向于种子集向量。

$$\min X^T L_G X \begin{cases} X^T D_G X = 1 \\ (X^T D_G 1)^2 = 0 \\ X \in \mathbb{R} \end{cases} \quad (24)$$

$$\min X^T L_G X \begin{cases} X^T D_G X = 1 \\ (X^T D_G 1)^2 = 0 \\ (X^T D_G s)^2 \geq \kappa \\ X \in \mathbb{R}, \kappa \in (0, 1) \end{cases} \quad (25)$$

根据文献 [12] 定理 1 可知, 设 $s \in R^V$ 是种子节点, 并且满足 $s^T D_G 1 = 0, s^T D_G s = 1, v_2$ 为 L_G 关于 D_G 的第二广义特征值对应的特征向量; $\kappa \in (0, 1)$ 表示相关参数, x^* 为局部谱 (式 (25)) 的最优解。存在 $\gamma \in (-\infty, \lambda_2(G))$ 和 $c \in [0, \infty]$, 使得 $x^* = c(L_G - \gamma D_G)^+ D_G s$ 。其中: A^+ 为 A 的 moore-penrose 逆; γ 表示解向量和种子向量的相关性, 当 κ 趋向 1 时, γ 趋向 $-\infty$, 解 x^* 和 s 比较接近, 当 κ 趋向 0 时, γ 趋向 $\lambda_2(G)$, 解 x^* 和 v_2 比较接近; c 为归一化参数, 将解向量的模归一化到 1。由上述定义可得 $L_G^+ = \sum_{i=2}^n \frac{1}{\lambda_i} v_i v_i^T$, 则 $(L_G - \gamma D_G)^+ = \sum_{i=2}^n \frac{1}{\lambda_i - \gamma} v_i v_i^T$, 因此 $x^* = c \sum_{i=2}^n \frac{1}{\lambda_i - \gamma} v_i v_i^T D_G s$, 该有偏割向量 x^* 为目标的指示向量。

3.2 局部谱算法

算法 3 有偏图割 (G, w, s_T, γ)。

构造图 $G = (V, E)$, 其中边的权重函数为 w , 种子 s_T 以及相关参数 $\gamma \in (-\infty, \lambda_2(G))$ 。

a) $W_G(i, j) = [w(i, j)]_{n \times n}, D_G(i, i) = \sum_j w(i, j)$ 。

b) $L_G = D_G - W_G$, 根据式 (22) 求解 L_G 的最小 K 个特征值 $\lambda_1, \lambda_2, \dots, \lambda_K$ 和对应的特征向量 $v_1, v_2, \dots, v_K$ 。

c) 根据图像的初分割结果选取种子节点向量 s_T , 其中 T 为种子节点数。

d) 求有偏割特征向量 $x^* = c \sum_{i=2}^K \frac{1}{\lambda_i - \gamma} v_i v_i^T D_G s_T$ 。

4 本文算法思想

在图割理论中, 特征值对应的特征向量指示着图像的区域

特性。若构造权值矩阵用同一种方法, 则算法 3 根据式 (22) 求得的最小 K 个特征值等价于归一化割根据式 (10) 求得的最大 K 个特征值。若式 (10) 的特征值为 $\bar{\lambda}_i$, 则式 (18) 的特征值 $\lambda_i = 1 - \bar{\lambda}_i$, 对应的特征向量不变, 因此局部谱算法可以与归一化割进行结合。由于多尺度图谱是在归一化割基础发展而来, 根据 Rayleigh-Ritz 定理将式 (10) 的特征值求解转换为式 (18) 的特征值求解。因此局部谱算法与多尺度图谱算法可以有有机结合。

根据前面论述, 提出图像平滑、多尺度图谱和局部谱相结合的图像目标提取算法, 即算法 4。

算法 4 结合多尺度图谱和局部谱的算法。

a) 根据算法 1 进行图像平滑预处理。

b) 根据算法 2 进行图像多尺度分割, 计算 W 和 C , 计算 QPQ 的最大 K 个特征值 $\mu_1, \mu_2, \dots, \mu_K$ 和特征向量 $\omega_1, \omega_2, \dots, \omega_K$ 。

c) 根据图像的目标物体选取种子区域向量 s_T , 其中 T 为种子区域。

d) 求有偏割特征向量 $x^* = c \sum_{i=2}^K \frac{1}{1 - \mu_i - \gamma} \omega_i \omega_i^T D_G s_T$ 。

e) 有偏割特征向量 x^* 为目标物体指示向量, 再通过最大类间方差法 (Otsu) 将 x^* 分割成目标和背景。

本文算法将局部谱的种子节点集选取改为种子区域选取, 种子区域为目标对象粗轮廓所包含的区域。若目标被粗分割的区域过多, 部分区域没有选取种子节点, 则产生的有偏割向量与该区域不相关, 导致目标提取错误。种子区域的选取不仅解决了该问题, 而且在人工选取时比较灵活 (接近目标轮廓即可)。在计算有偏割向量时, 若粗轮廓选在实际边界外面, 则外面区域的割向量和种子区域相关性较小, 产生大的惩罚, 内部区域的割向量和种子区域相关性较大, 最终轮廓会向内逼近, 靠近真正的边界轮廓; 反之亦然。

5 实验结果和分析

5.1 图像平滑对比

图 1 比较了 BLF 算法 [2]、TV 算法 [3]、WLS 算法 [4] 以及 l_0 梯度算法的图像平滑效果。本文用到的图像均来自 Berkeley 分割数据集, 图像大小均为 481×321 。两组实验的 BLF 算法、WLS 算法、 l_0 梯度算法的参数分别为 $(\delta_r = 0.15, \delta_d = 10), (\alpha = 1.6, \lambda = 0.25), \lambda = 0.004; (\delta_r = 0.35, \delta_d = 12), (\alpha = 18, \lambda = 0.35), \lambda = 0.02$ 。根据两组实验结果可以看出, BLF 算法和 TV 算法平滑时均在一定程度上保留了边缘, 但也使得边缘产生部分模糊。由图 1(a) ~ (e) 结果可知, WLS 算法和 l_0 梯度算法均能够有效地平滑图像, 且能够产生很好的边缘保持能力; 由图 1(f) ~ (j) 结果表明, 相比 WLS 算法, l_0 梯度算法能够很好地平滑图像细节, 同时边缘不产生模糊, 并且该算法只有一个参数, 更易于控制。

5.2 图像预处理作用

图 2 比较了是否预处理图像多尺度图谱分割效果。两组图像的分割部分数和平滑因子分别为 $n = 5, \lambda = 0.01; n = 10, \lambda = 0.03$ 。在参数选取一致的情况下, 相比未预处理的图像分割结果, l_0 梯度最小化平滑后的图像分割结果和人工分割结果更加接近, 表现在图 2(d) 中鸵鸟的头部分割比图 2(b) 更加准

确;图2(j)中鸟的边缘定位比图2(h)更加准确,因为预处理后的图像去除了部分细节信息,更利于多尺度图谱割。




图1 图像平滑对比实验




图2 图像预处理作用实验

5.3 多尺度图谱和局部谱相结合的算法实验

图3为本文算法结果,其中实验图中种子区域为选取点依次相连所组成轮廓的内部。实验产生的分割结果均很好地逼近了人工分割结果,显示了本文算法能有效地提取目标。即使在多尺度图谱算法中将目标物体分割成不同的区域,也能通过有偏割向量将目标物体提取出来。实验中各组图像的多尺度图谱分割部分数和平滑因子分别为 $n=13, \lambda=0.005, n=10, \lambda=0.005, n=20, \lambda=0.02, n=16, \lambda=0.01, n=15, \lambda=0.01, n=13, \lambda=0.005$ 。图3(d2)中狗的尾巴在粗分割时没有分割好,但经过有偏分割计算后,在(d5)中得到改善;图3(e2)(e5)中花的左侧也有此现象,该现象表明局部谱的分割不仅仅是将粗分割结果进行合并,而是根据种子区域向量对粗分割的特征向量进行有目的的整合。图3(c5)中人的头发和腿部、(f5)中小熊的脚部分割效果均不是很好,这主要是由于目标中的该区域与周围背景的光谱信息或纹理信息十分接近,在粗分割时产生错误,再经过向量相关性作用,影响到最终分割效果。

当目标对象与背景纹理较多,且两者在某一边界光谱信息较接近时,粗分割效果不佳,影响到有偏割结果。结合更多特征的多尺度图谱是下一步解决该问题的研究方向。

5.4 种子节点和种子区域分割对比

图4比较了种子节点和种子区域的局部谱图像分割。分割部分数和平滑因子分别为 $n=16, \lambda=0.01$ 。从图4(c)(d)中看出,当狗脖子处没有选取种子节点时,有偏割向量不包含这部分;当狗尾部只有一个种子节点时,有偏割向量只将部分分割出来。但选取种子区域分割时不会出现此问题,如图4(f)所示。在局部谱算法中,相比种子节点的选取,种子区域的选取比较灵活,且分割效果较好。

6 结束语

本文的主要创新点在于有效地将 l_0 梯度最小化平滑、多

尺度图谱和局部谱相结合进行目标提取,并将局部谱中的种子节点集用种子区域进行改进。多尺度图谱具有高效率、高精准确性的特点。多尺度图谱在构造边的权值时会受到图像的噪声和纹理影响,使得分割不够精确,本文采取了图像平滑预处理,平滑部分细节的同时很好地保持了边缘,使得图像分割更加精确。若目标包含差异比较大的不同区域时,多尺度图谱不能有效地提取目标,而局部谱方法的引入弥补了全局谱的不足。实验表明,相比多尺度图谱,本文算法具有更好的目标提取效果。




图3 本文算法与多尺度图谱算法在目标提取中的对比实验




图4 种子节点和种子区域分割对比实验

参考文献:

- [1] RICHARD S. Computer vision: algorithms and applications [M]. [S. l.]: Springer, 2010: 267-305.
- [2] TOMASI C, MANDUCHI R. Bilateral filtering for gray and color images [C]//Proc of the 6th IEEE International Conference on Computer Vision. Washington DC: IEEE Computer Society, 1998: 839-846.
- [3] RUDIN L I, OSHER S, FATEMI E. Nonlinear total variation based noise removal algorithms [J]. Physica D, 1992, 60(3): 259-268.
- [4] FARBMAN Z, FATTAL R, LISCHINSKI D, et al. Edge-preserving decompositions for multi-scale tone and detail manipulation [J]. ACM Trans on Graph, 2008, 27(3): Article No. 67. (下转第1585页)

像去模糊质量的影响。将得到的相位估计值与孔径函数 A 相结合得到相应 PSF 的 i , 然后由 i 采用去卷积的方法便可得到去模糊的图像。在仿真中, 验证图像受到原 PSF 以及加性高斯噪声的污染。图 5 所示为 satellite 的原图及受污染的图像。

在得到 PSF 的估计值后, 采用去卷积的方法便可得到去模糊以后的图像。为了便于比较, 去卷积采用由 DS 采样得到的相位值获得 PSF。这种方法能够得到精度最高的去模糊图像, 因为既没有涉及到降采样, 也不需要采用 CS 的方法进行相位估计。将去卷积后的图像与原图像相比, 比较的标准为 SSIM(结构相似度)。从图 6 中可以看出, 采用 DCS 方法能够得到相似度更高的去模糊图像。




图5 satellite图像

图6 采用不同方法的重建图像

5 结束语

本文采用 DCS 的方法实现了光学图像的去模糊问题求解。在受到大气扰动影响时, GPF 的相位是一个随机函数, 需要通过 AO 测量。为了降低后续的信号处理难度, 本文采用基于压缩感知的方法。与传统的压缩感知相比, 本文采用了相位的偏微分作为相位稀疏的约束条件。通过仿真可以看出, 采用 DCS 的方法能够得到比传统 CCS 方法更高的相位估计值。本文的主要目的是通过减少透镜的数目简化 SHI 的结构; 通过采用压缩感知的方法, 在降低采样率的情况下, 不会对相位估计的精度以及去模糊图像的质量造成影响。

参考文献:

- [1] YANG Jian-chao, WRIGHT J, HUANG T S, *et al.* Image super-resolution via sparse representation[J]. *IEEE Trans on Image Process*, 2010, 19(11): 2861-2873.
- [2] PAUL R T. Review of robust video watermarking techniques[J]. *IJCA Special Issue on Computational Science*, 2011(3): 90-95.
- [3] ELAD M, AHARON M. Image denoising via sparse and redundant representations over learned dictionaries[J]. *IEEE Trans on Image Process*, 2006, 15(12): 3736-3745.
- [4] KUNDUR D, HATZINAKOS D. Blind image deconvolution[J]. *IEEE Signal Processing Magazine*, 1996, 13(3): 43-64.
- [5] CHAMBOLLE A. An algorithm for total variation minimization and applications[J]. *Journal of Mathematical Imaging and Vision*, 2004, 20(1-2): 89-97.
- [6] MICHAILOVICH O, TANNENBAUM A. Blind deconvolution of medical ultrasound images: parametric inverse filtering approach[J]. *IEEE Trans on Image Process*, 2007, 16(12): 3005-3019.
- [7] JANSSON P A. Deconvolution of images and spectra[J]. *Optical Engineering*, 1997, 36(11): 3224-3225.
- [8] DAYTON D, PIERSON B, SPIELBUSCH B, *et al.* Atmospheric structure function measurements with a Shack-Hartmann wave-front sensor[J]. *Optics Letters*, 1992, 17(24): 1737-1739.
- [9] HOSSEINI M, MICHAILOVICH O. Derivative compressive sampling with application to phase unwrapping[C]//Proc of the 17th European Signal Processing Conference. 2009.
- [10] TSAIG Y, DONOHO D L. Compressed sensing[J]. *IEEE Trans on Information Theory*, 2006, 52(4): 1289-1306.
- [11] CANDÈS E J, ROMBERG J, TAO T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information[J]. *IEEE Trans on Information Theory*, 2006, 52(2): 489-509.
- [12] YIN W, OSHER S, GOLDFARB D, *et al.* Bregman iterative algorithms for l_1 -minimization with applications to compressed sensing[J]. *SIAM Journal on Imaging Sciences*, 2008, 1(1): 143-168.
- [13] BECK A, TEOULLE M. A fast iterative shrinkage-thresholding algorithm for linear inverse problems[J]. *SIAM Journal on Imaging Sciences*, 2009, 2(1): 183-202.
- [14] DAUBECHIES I, DEFRISE M, MOL C D. An iterative thresholding algorithm for linear inverse problems with a sparsity constraint[J]. *Communications on Pure and Applied Mathematics*, 2004, 57(11): 1413-1457.
- [15] SCHMIDT J D. Numerical simulation of optical wave propagation with examples in MATLAB[M]. Washington DC: SPIE, 2010.
- [16] MAHONEY M W, OZECCHIA L, VISHNOI N K. A spectral algorithm for improving graph partitions[EB/OL]. (2009-12-03). <http://arxiv.org/abs/0912.0681>.
- [17] MAHONEY M W, OZECCHIA L, VISHNOI N K. A local spectral method for graphs: with applications to improving graph partitions and exploring data graphs locally[EB/OL]. (2011-10-21). <http://arxiv.org/abs/0912.0681v3>.
- [18] MAJI S, VISHNOI N, MALIK J. Biased normalized cuts[C]//Proc of IEEE Conference on Computer Vision and Pattern Recognition. 2011: 2057-2064.
- [19] ABDELLATIF H, TAHAL T E, ZAHARAN O F, *et al.* K2. automatic pectoral muscle boundary detection in mammograms using eigenvectors segmentation[C]//Proc of the 29th National Radio Science Conference. 2012.
- [20] ARBELAEZ P, MAIRE M, FOWLKES C, *et al.* Contour detection and hierarchical image segmentation[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2011, 33(5): 898-916.
- [21] YU S X, SHI J. Segmentation given partial grouping constraints[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2004, 26(2): 173-183.
- [22] LI Xu, LU Ce-wu, YI Xu, *et al.* Image smoothing via L_0 gradient minimization[J]. *ACM Trans on Graph*, 2011, 30(6): Article No. 174.
- [23] SHI J, MALIK J. Normalized cuts and image segmentation[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 888-905.
- [24] SHARON E, BRANDT A, BASCRI R. Fast multiscale image segmentation[C]//Proc of IEEE Conference on Computer Vision and Pattern Recognition. 2000: 70-77.
- [25] GALUN M, SHARON E, BASCRI R, *et al.* Texture segmentation by multi-scale aggregation of filter responses and shape elements[C]//Proc of the 9th IEEE International Conference on Computer Vision. Washington DC: IEEE Computer Society, 2003: 716-723.
- [26] ALPERT S, GALUN M, BASRI R, *et al.* Image segmentation by probabilistic bottom-up aggregation and cue integration[J]. *IEEE Trans Pattern Analysis and Machine Intelligence*, 2012, 34(2): 315-327.
- [27] COUR T, BENEZIT F, SHI J. Spectral segmentation with multi-scale graph decomposition[C]//Proc of IEEE Conference on Computer Vision and Pattern Recognition. 2005: 1124-1131.

(上接第 1581 页)