

基于局部随机游走的超像素分割方法^①

马志国^{②*} 苗军^{*} 卿来云^{**} 陈熙霖^{③*}

(^{*}中国科学院智能信息处理重点实验室 中国科学院计算所 北京 100190)

(^{**}中国科学院大学计算机与控制学院 北京 100049)

摘要 针对基于图论的超像素分割方法缺乏超像素紧凑性控制和运算复杂度过高的问题,提出了一种基于局部懒惰随机游走(LLRW)的超像素分割方法,并将超像素分割形式化为像素邻接图的局部划分问题,提出了一种直观的分割质量度量。该方法首先将均匀平铺的六边形重心作为超像素种子点初始位置;然后利用局部随机游走算法计算种子点与周围像素的相关程度,将其最相关种子点的标号赋予该像素;最后计算新的超像素重心,并将其作为下一轮迭代的种子点位置,通过若干次迭代逐步优化超像素分割结果。此算法具有线性的时间复杂度和线性的空间复杂度,同时超像素分割质量具有理论保证。通过标准数据集上的实验证明,该方法不仅能够较好地保持图像边界,还可以保证超像素的紧凑性,从而达到理想的超像素分割效果。

关键词 超像素分割, 归一化割, 局部图划分, 传导率, 局部懒惰随机游走(LLRW)

0 引言

超像素是指具有相似纹理、颜色、亮度等特征的相邻像素构成的图像块。超像素作为图像的一种紧凑表示,可以摒弃冗余的图像信息,从而可提升图像处理效率,降低后续图像处理流程的计算和空间复杂度。超像素分割将图像基元的表示从上百万个像素转变为几百个超像素,进而为图像局部特征提取提供空间范围信息,有利于建模图像基元间远距离的空间拓扑关系。超像素分割算法逐渐成为计算机视觉的常用预处理步骤,被广泛应用于图像分割^[1]、深度估计^[2]、物体跟踪^[3]等视觉任务。本文在研究已有超像素分割方法的基础上,提出了一种基于局部懒惰随机游走(local lazy random walk, LLRW)的超像素分割方法(以下简称 LLRW 方法)。实验表明,该方法对不同复杂度的自然图像均能取得良好的超像素分割效果。

1 相关研究

超像素分割算法大致可分为基于梯度下降的方

法和基于图论的方法两类。基于梯度下降的超像素分割方法包括分水岭(watersheds, WS)方法^[4]、均值漂移(mean-shift, MS)方法^[5]、快速漂移(quick shift, QS)方法^[6]、TurboPixel 方法^[7]及简单线性迭代聚类(simple linear iterative clustering, SLIC)方法^[8]等。基于图论的超像素分割方法包括最小生成树方法^[9]、归一化割(normalized cut, Ncut)方法^[10]、超像素网格(superpixel lattice, SL)方法^[11]和熵率超像素(entropy rate superpixel, ERS)的方法^[12,13]等。

基于梯度下降的方法大都采用特征聚类的基本思想,实现方法和算法存在一定的差异,具有不同的优缺点。分水岭(WS)方法^[4]基于图像拓扑理论的数学形态学操作,该方法的运算速度很快,缺点是无法方便地控制超像素的数量与形状。均值漂移(MS)方法^[5]是一种迭代的密度最大化搜索过程,可以产生平滑的超像素,缺点是速度较慢,无法控制输出超像素的数目、形状和紧凑性。TurboPixel 方法^[7]是一种基于水平集的几何流方法,从初始的规则种子点逐渐演化为形状规则的超像素,缺点是超像素

① 973 计划(2009CB320900)和国家自然科学基金(61175115, 61272320, 61070116)资助项目。

② 男,1981 年生,博士;研究方向:计算机视觉与模式识别;E-mail: zhiguo.ma@vipl.ict.ac.cn

③ 通讯作者, E-mail: xlchen@ict.ac.cn

(收稿日期:2014-07-21)

的边界对齐与图像真实边界对齐较差。简单线性迭代聚类(SLIC)算法^[8]融合像素的颜色和距离相似性,通过局部 K-means 聚类算法生成超像素分割,该方法简单直观,可以在较短的时间内生成指定数量的超像素。SLIC 方法的缺点是局部 K-means 算法容易陷入局部最小值,同时对种子点初始化敏感,需要通过预处理操作将种子点放置在平坦区域;同时,输出的超像素不能保证单连通性,需要启发式的后处理步骤保证连通性。

基于图论的超像素方法使用图表示像素之间的关系,并利用图算法生成超像素分割结果。最小生成树算法^[9]对图像进行过分割,可以较好地对齐图像轮廓,速度较快;缺点是超像素大小和形状变化剧烈,同时无法控制超像素数目。归一化 Ncut 算法^[10]提取轮廓和纹理等特征,通过全局最小化代价函数生成规则的超像素,但是计算量较高,且图像边界对齐效果一般,不适合在较大的图像上生成大量的超像素。超像素网格(SL)方法^[11]可以保持图像的空间拓扑结构,但算法的性能依赖预先提取的图像轮廓,轮廓提取需要耗费较长的时间,不同的轮廓提取方法对最终的超像素分割结果影响很大。熵率超像素(ERS)方法^[12,13]将随机游走的熵率与其平衡项定义为目标函数,通过目标函数的最大化实现图像的过分割,算法生成的超像素的速度较快,可以控制超像素的数目,但算法输出的超像素大小和形状不规则。

在实际应用中,不同的应用要求超像素分割具有不同的特性,难以给出满足所有应用的超像素质量特性。然而,研究者普遍认可的超像素特性包括边界对齐、均匀大小和形状、计算速度快、空间关系规则、简单连通性等特性,例如:

- 超像素边界应当对齐图像边界^[8],同时具有均匀的尺寸和覆盖范围^[7]。超像素分割应该将图像分割成大小均匀和形状紧凑的多个部分。

• 超像素的计算速度应该很快,同时内存占用少且易于使用^[8]。超像素经常被用作预处理步骤以降低后续处理的计算复杂度,运行时间过长会影响后续任务的效率。

• 超像素应具有规则的拓扑连接关系^[11]。现有的视觉算法大都针对规则排列的像素设计,超像素保持规则网格的空间关系,可以提高算法的处理效率,方便学习相邻超像素间的高阶关系。

• 超像素应由像素的单连通集构成,连通性缺失会影响后续算法的处理。在没有局部边界时,超像素应当保持紧凑性。超像素间不重叠,每个像素应当分配给唯一的超像素^[7]。

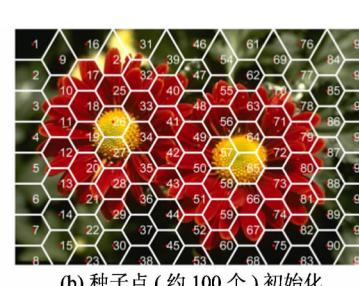
现有的超像素方法侧重底层能量函数的设计和具体的算法流程,忽视了超像素分割质量的直观定义,使得算法优化的目标函数与超像素质量缺乏直接联系。本文使用像素局部邻接图表示相邻像素之间的相似关系,超像素分割被形式化为像素邻接图的局部切分问题,图切对应的传导率是一种直观的超像素质量度量,同时考虑超像素内部及不同超像素间的相似性,设计了一种具有线性时间复杂度和线性空间复杂度的算法,通过快速的迭代生成大小均匀、形状紧凑的超像素分割结果。

基于局部懒惰随机游走的图像超像素分割方法,即 LLRW 方法,包括如下步骤:

- (1) 初始化超像素种子点:在原始图像(图 1(a))上均匀平铺大小相同的正六边形,六边形的重心(图 1(b))被初始化为超像素种子点。
- (2) 局部扩散过程与超像素生成:从种子点开始,利用局部随机游走计算种子点与像素间的相关性,像素被分配给最相关的种子点。
- (3) 种子点位置更新:重新计算超像素重心作为新的种子点位置,迭代第(2)步与第(3)步,输出最终的超像素分割结果(图 1(c))。



(a) 原始图像



(b) 种子点(约 100 个)初始化



(c) 最终的超像素分割结果

原始图像上六边形平铺作为种子点,多次局部扩散生成最终的分割结果

图 1 超像素分割流程

经过上述3个步骤若干次迭代,可以得到紧凑的超像素分割结果。本文提出的LLRW算法可以

输出对应不同超像素数量的分割结果,如图2所示。



被白线切开的部分,从上往下分别对应的超像素数目为 2400, 600, 150

图2 LLRW 超像素分割算法输出

本文提出的基于局部随机游走的超像素分割算法在问题形式化、超像素质量度量、算法复杂度和理论保证及方法的特性上都具有一定的创新性:

- 创新地将超像素分割形式化为像素邻接图的局部图划分问题。相对传统的全局图划分(如归一化割算法),局部图划分的形式化更加简单直观,无需概率边界检测步骤,能明显降低计算的复杂度^[14]。
- 提出了一种直观的超像素质量度量,集合传导率可在最小化超像素间相似性的同时,最大化超像素内部的相似性。如文献[15]所述,传导率与定义在图像底层特征上的能量函数相比,可以更直观地衡量超像素分割的质量。
- 提出的局部图划分算法,基于新颖的局部懒惰随机游走过程,可以确保种子点只与周围局部范围的像素进行相似性计算,从而极大降低了图划分算法的复杂度。基于全局谱分割的图划分的方法具有超线性的时间复杂度,而本文提出的LLRW算法具有较低的线性时间复杂度和线性空间复杂度,同时超像素分割质量具有理论保证^[14,16]。
- LLRW 算法可以输出大小均匀、形状紧凑的超像素分割,同时超像素之间可以保持规则的全局空间拓扑连接关系。此外,对图像噪音和复杂纹理鲁棒,可以保持超像素的简单连通性。

2 超像素分割的局部图划分形式化

图可以很方便地表示多个对象之间的空间和相似性关系。图由结点与边组成,图 $G = (V, E)$ 是一

个二元组, $v \in V$ 称为结点集合, $e \in E \subseteq V \times V$ 称为边的集合,其中 e_{ij} 表示连接结点 v_i 和 v_j 的边, $n = |V|$ 与 $m = |E|$ 分别表示结点与边的数量。一般情况下,加权图中的每条边 e_{ij} 都被分配一个非负实数,称为权重,记为 w_{ij} 或 $w(i, j)$ 。

基于图论的超像素分割,目标是将像素邻接图的结点集合 V 划分为 K 个互斥的子集 V_1, V_2, \dots, V_K , 即 $V_1 \cup V_2 \cup \dots \cup V_K = V$ 且 $V_i \cap V_j = \emptyset, \forall i \neq j$, 其中每一个子集 V_k 对应一个超像素块 S_k 。子集 V_k 与其他子集之间的相似性可以表示为该子集与图中其他部分连接边的权重和,在图论中被称为割(cut):

$$\text{cut}(V_k) = \sum_{i \in V_k, j \notin V_k} w(i, j) \quad (1)$$

子集内的相似性用所有结点度的和表示,图论中称为容量(volume),子集 V_k 的容量 $\text{vol}(V_k)$ 为

$$\text{vol}(V_k) = \sum_{i \in V_k} d_i \quad (2)$$

其中,结点 v_i 的度记为 $d_i = \sum_j w_{ij}$, 是所有连接到该结点的边的权重和。

子集 V_k 的传导率(conductance)是子集的割与容量的函数,记为 $\Phi(V_k)$, 表示子集间相似性(cut)与子集中相似性(vol)的比值:

$$\Phi(V_k) = \frac{\text{cut}(V_k)}{\min\{\text{vol}(V_k), \text{vol}(\bar{V}_k)\}} = \frac{\sum_{u \in V_k, v \notin V_k} w_{uv}}{\sum_{i \in V_k} d_i} \quad (3)$$

其中, $\text{vol}(\bar{V}_k)$ 为 V_k 补集容量,一般情况下 V_k 补集的容量远大于 V_k 的容量,即 $\text{vol}(\bar{V}_k) \gg \text{vol}(V_k)$,

因此 $\min\{vol(V_k), vol(\bar{V}_k)\} = vol(V_k) = \sum_{i \in V_k} d_i$

传导率的定义与归一化割^[10]相似, 归一化割 Ncut 定义为

$$Ncut(V_k) = \frac{cut(V_k)}{vol(V_k) \times vol(\bar{V}_k)} \quad (4)$$

归一化割 Ncut 需要同时考虑集合 V_k 及其补集 \bar{V}_k 的容量, 在二者的容量相似时达到最小值, 因此需要全局的计算方法, 计算复杂度较高。而本文的传导率只需要考虑较小子集的容量, 因此计算复杂度较低。后续的实验将展示本文提出的 LLRW 局部算法与 Ncut 全局算法在计算时间上的差异。

传导率是一种直观的超像素分割的质量度量, 传导率最小化要求在最小化超像素间相似性的同时, 最大化超像素内的相似性。因此, 超像素分割的目标可以表示为最小化所有超像素传导率的和, 即最小化 $\sum_{k=1}^K \Phi(V_k)$ 。与归一化割^[10]类似, 传导率最小化也是一个 NP 完全问题, 无法在多项式时间内精确求解。本文将传导率最小化求解嵌入到种子点概率的局部扩散过程中, 通过局部随机游走算法高效准确地求解近似解, 从而迅速得到高质量的超像素分割结果。

3 LLRW 方法流程

3.1 超像素种子点初始化

超像素分割算法的目标是输出大小一致、空间均匀分布的图像过分割结果。若用户指定的超像素数量为 K , 超像素种子点初始化为 K 个均匀平铺的相同大小的正方形^[7,8]或正六边形^[17]的中心。

正方形的边长约等于 $S = \sqrt{\frac{N}{K}}$, 其中 N 为图像像素的数目。类似地, 六边形的边长约等于 $S = \sqrt{\frac{N}{1.5 \times \sqrt{3} \times K}} \approx \sqrt{\frac{N}{2.6 \times K}}$ 。给定图像的长度 W 和宽度 H , 可以确定种子点的位置, 如图 1(b) 所示。本文将正六边形重心作为种子点的初始位置, 由于相同周长的正六边形比正方形面积小, 正六边形的形状更加紧凑。TurboPixel 方法^[7]和 SLIC 方法^[8]对种子点附近的图像边缘敏感, 需要将种子点扰动到图像平坦区域, 而本文的 LLRW 算法对种子点初始位置鲁棒, 无需扰动种子点初始位置。

3.2 局部扩散过程与超像素生成

图像的每个像素作为加权图 $G = (V, E)$ 中的

一个结点, 与周围最近的 8 个像素对应的结点相连。边的权重 w_{ij} 是相邻像素的相似性, 表示相邻像素归属同一个超像素的概率:

$$w_{ij} = e^{-\frac{\|F_{(i)} - F_{(j)}\|_2^2}{2\sigma^2}} \quad (5)$$

其中特征向量 $F_{(i)}$ 和 $F_{(j)}$ 表示像素 v_i 和 v_j 的 LAB 空间的颜色值; 标准差 σ 由颜色距离的中值确定, 即 $\sigma = \text{median}_{e_i, e_j \in E} (\|F_{(i)} - F_{(j)}\|_2)$ 。权重矩阵 W 记录所有边的权重信息 w_{ij} :

$$W(i, j) = \begin{cases} w_{ij}, & e_{ij} \in E \\ 0, & e_{ij} \notin E \end{cases} \quad (6)$$

懒惰随机游走在每一步状态转移中, 都有 50% 的概率停留在当前结点。懒惰随机游走的转移矩阵 T 记录随机游走在下一步到达相邻结点的概率, 可以通过权重矩阵 W 和度矩阵 D 计算得到:

$$T = \frac{(I + D^{-1}W)}{2} \quad (7)$$

其中, I 为单位矩阵。度矩阵 D 是由全部结点的度 d_k 组成的对角矩阵:

$$D = \begin{pmatrix} d_1 & & & \\ & d_2 & & \\ & & \ddots & \\ & & & d_K \end{pmatrix} \quad (8)$$

本文采用局部懒惰随机游走(LLRW)算法, 计算像素与种子点的相关程度, 迭代公式为

$$P_t = P_{t-1} T \quad (9)$$

矩阵 P_t 的大小为 $K \times N$, 记录 t 步懒惰随机游走后 K 个种子点与 N 个像素间的相关性。初始化时, 矩阵 $P_0(k, c(k)) = 1$ 仅在第 k 个种子点线性坐标 $c(k)$ 处为 1, 其他位置均为 0。

典型的随机游走步数为 $t = S$, 即正六边形的边长。因此超像素种子点在 $2S \times 2S$ 范围内, 与相邻的种子点竞争周围未分配标号的像素。未分配像素的标号 $L(n)$ 是 t 次局部随机游走过程后, 与之相关程度最高的超像素的序号, 即

$$L(n) = \underset{k \in [1, K]}{\text{argmax}} P_t(k, n) \quad (10)$$

其中, 标签矩阵 L 记录了所有像素的超像素标号, 是本次迭代新生成的超像素分割结果。

3.3 种子点位置更新

上述步骤结束后, 从标签矩阵 L 可以获取当前超像素的重心位置 $c(k)$, 作为下一轮迭代的种子点位置, 这个过程称为重心漂移(centroid shift)。迭代局部扩散过程和重心漂移两个步骤, 可以逐步优化超像素分割结果。

3.4 复杂度分析与理论保证

本文使用稀疏矩阵存储转移矩阵、标号矩阵等数据,数据存储的空间复杂度与像素数目 N 成正比。种子点与像素的相关矩阵 \mathbf{P}' 随迭代次数 t 增加而增大,其他矩阵的大小不变。由于随机游走步数最多为 S 步,矩阵 \mathbf{P}' 中非零元素的数目被限制在 $4N$ 以内,因此算法具有线性 $O(N)$ 的空间复杂度。

局部懒惰随机游走算法仅在矩阵非零元素上计算, S 次迭代的累计时间复杂度为 $O(S \cdot N)$ 。由于正六边形的边长 S 是一个较小的常数,因此算法具有线性 $O(N)$ 的时间复杂度。

文献[14,16]给出了局部懒惰随机游走算法,同时给出了关于传导率最小化的理论证明,从而为本文提出的传导率作为超像素质量度量提供了理论保证。由于篇幅所限,具体的证明过程不再赘述,详细的证明过程请参阅相关文献。

综合上述关于空间复杂度、时间复杂度和理论证明的描述,可知本文提出的 LLRW 超像素分割方法除了具有线性的时间复杂度和线性的空间复杂度,还有超像素分割质量的理论保证。

4 实验分析与性能评价

为了验证本文算法的有效性,笔者在最新的 Berkeley 分割数据集 (BSDS500)^[18] 上对比了不同的超像素算法。BSDS 数据集中含有 500 张自然图像,每张图像均由多人标注出精确的图像边界和区域位置。图 2 给出了同一幅图像上,LLRW 方法输出的超像素分割结果,超像素的数目 K 分别为 $K = 2400, 600, 150$ 。从图中可以看出,对于变化较小、纹理简单的均匀区域,采用较少数目的超像素即可较好地分割区域;对于变化较快、纹理复杂的区域,需要较多的超像素才能取得更好的效果。

本文采用公认的欠分割错误率 (undersegmentation error, UE)、边界召回率 (boundary recall, BR)、可达分割精度 (achievable segmentation accuracy, ASA) 和紧凑性 (compactness, CO),作为超像素分割精度的度量。其中边界召回率 BR、可达分割精度 ASA 和紧凑性 CO 越高越好,而欠分割错误率 UE 则越低越好。

欠分割错误率 $UE^{[8]}$ 度量超像素从人工标注的分割中泄露的像素比例。人工标注的分割结果记为 $G = \{G_1, G_2, \dots, G_{n_G}\}$, 其中 n_G 为人工标注中图像

块的数目, $|G_i|$ 表示图像块 G_i 的面积。欠分割错误率 UE 的定义为

$$UE_G(S) = \frac{\sum_i \sum_{k: |S_k \cap G_i| \geq B} |S_k - G_i|}{\sum_i |G_i|} \quad (11)$$

其中 $B = |S_k| \times 5\%$ ^[8], 超像素 S_k 从图像块 G_i 中泄露的像素数记为 $|S_k - G_i|$ 。所有人工标注图像块上泄露的像素数目累加,除以图像大小 $\sum_i |G_i|$ 得到欠分割错误率。

边界召回率 $BR^{[7]}$ 度量与超像素边界重合的自然图像边界的比例,表示为标注的边界在 ϵ 像素距离的近邻内找到至少一个超像素边界像素的比例:

$$BR_G(S) = \frac{\sum_{p \in \delta G} I(\min_{q \in \delta S} \|p - q\| < \epsilon)}{|\delta G|} \quad (12)$$

其中, δS 和 δG 分别表示超像素边界和标注的边界集合。指示函数 I 查最近邻像素是否在 ϵ 距离内,实验中通常选择 $\epsilon = 2^{[7]}$ 。

可达分割精度 $ASA^{[12]}$ 计算超像素作为图像基元时,最好的物体分割性能。将超像素分配给最大重合面积的人工标注图像块,可达分割精度为正确标注的像素比例为:

$$ASA_G(S) = \frac{\sum_k \max_k |S_k \cap G_i|}{\sum_i |G_i|} \quad (13)$$

超像素 S_k 的紧凑性 Q_k 是与相同周长 L_S 的圆的面积的比值^[19]:

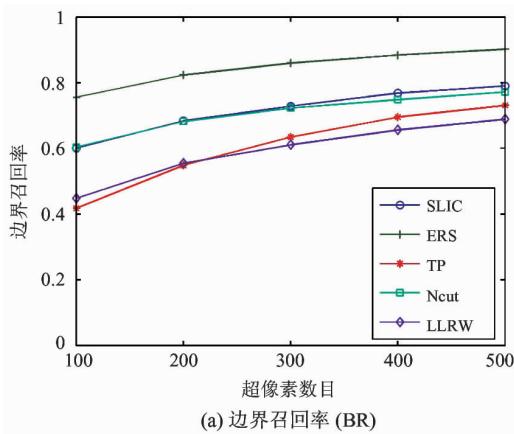
$$Q_k = \frac{A_S}{A_C} = \frac{4\pi A_S}{L_S^2} \quad (14)$$

所有超像素紧凑性的面积加权和表示当前分割的紧凑性 $CO^{[19]}$:

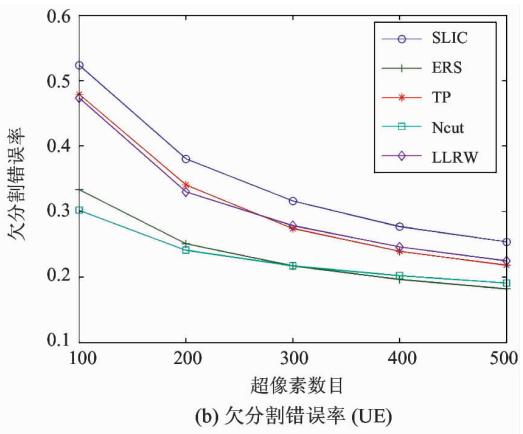
$$CO = \sum_{k=1}^K Q_k \cdot \frac{|S_k|}{\sum_{k=1}^K |S_k|} \quad (15)$$

在 BSDS500 数据集上,超像素分割的精度由图 3 展示。本文绘制了超像素数目从 100 到 500 变化时,5 种不同算法的边界召回率 BR(图 3(a))、欠分割错误率 UE(图 3(b))、可达分割精度 ASA(图 3(c)) 和紧凑性 CO(图 3(d)) 曲线。

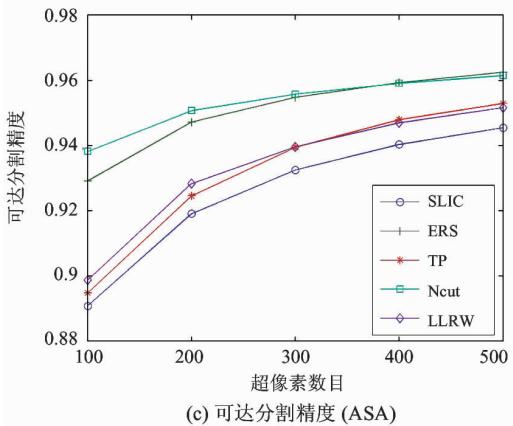
本文提出的 LLRW 算法在超像素紧凑性(如图 3(d)所示)上明显高于其他方法,其他性能指标上接近其他最新的超像素分割算法。由于紧凑性和边界召回率存在负相关性^[19],较高的紧凑性会降低边界对齐的性能,因此 LLRW 算法的边界召回率比



(a) 边界召回率 (BR)



(b) 欠分割错误率 (UE)



(c) 可达分割精度 (ASA)

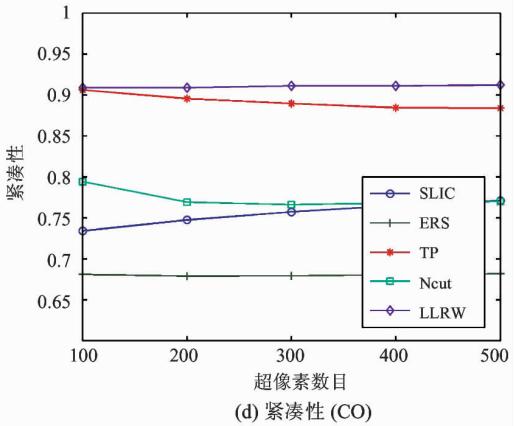


图 3 不同的超像素数目的情况下超像素分割的定量性能对比

其他方法略低, 图 4 的视觉对比可以更好地展示紧凑性与边界对齐性能的折衷。由于本文优化的目标函数与 Ncut 算法^[10]相似, 笔者对比了 Ncut 算法与

本文算法的计算效率。实验表明, Ncut 算法生成一张图像的超像素需要 240s 左右, LLRW 算法仅需 5s 左右。



为了便于观察图像细节, 图中第 2、4 行是第 1、3 行结果的中心部分放大的展示

图 4 不同方法输出超像素的视觉对比

为了更好地观察不同算法输出的超像素分割的优缺点,图4展示了SLIC方法^[8]、ERS方法^[13]、TurboPixel方法^[7]以及本文提出的LLRW算法的超像素分割输出结果。对图像中心区域进行了放大以便更好地对不同算法进行视觉对比。从图4中可以看出,SLIC算法(图4(a))和ERS算法(图4(b))输出的超像素大小和形状变化比较剧烈,紧凑性较差,而边界对齐性能较好;相反,TurboPixel算法(图4(c))和LLRW算法(图4(d))输出的超像素大小相似、空间分布均匀,而在剧烈变化的图像局部边界对齐边界的性能相对前两种方法略差。

针对不同的计算机视觉任务,需要根据需求选择不同的超像素分割算法,现在还没有可以同时满足所有需求的超像素方法。如果应用要求边界对齐的准确度较高,而不用考虑紧凑性等特性,可以考虑使用SLIC或者ERS等算法;反之,若应用要求超像素具有均匀的大小、形状或者要求稳定的空间拓扑关系,则应当优先考虑TurboPixel算法或本文提出的LLRW算法。

5 结 论

本文提出了一种基于局部图划分的超像素分割方法——基于局部懒惰随机游走(LLRW)的算法,并给出了其生成的紧凑的图像过分割结果。首先将超像素分割形式化为像素邻接图的局部划分问题,并提出了一种直观合理的超像素分割质量的度量方法。本文提出的LLRW算法由种子点位置初始化、概率局部扩散竞争、重心漂移三个步骤组成。通过分析表明,LLRW算法具有线性的时间复杂度和线性的空间复杂度,而且有分割质量的理论保证,可以高效地生成大小相似、空间分布均匀、形状紧凑的超像素分割结果。在数据集BSDS500上的大量实验表明,LLRW算法对不同复杂度的自然图像,均能取得较好的超像素分割结果。

超像素分割是一个“病态”问题,不存在唯一最优分割结果,应当探索多种超像素分割方法以满足不同应用的需求。本文提出的局部图划分方法克服了全局图划分的计算复杂度等问题,同时给出了直观的分割质量定义,可以为后续的研究提供思路借鉴。

参考文献

[1] Fulkerson B, Vedaldi A, Soatto S. Class segmentation

and object localization with superpixel neighborhoods.

In: Proceedings of the IEEE International Conference on Computer Vision, Kyoto, Japan, 2009. 670-677

- [2] Zitnick C L, Kang S B. Stereo for image-based rendering using image over-segmentation. *International Journal of Computer Vision*, 2007, 75(1): 49-65
- [3] Yang F, Lu H, Yang M H. Robust superpixel tracking. *IEEE Transactions on Image Processing*, 2014, 23(4): 1639-1651
- [4] Vincent L, Soille P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1991, 13(6): 583-598
- [5] Comaniciu D, Meer P. Mean shift: a robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24(5): 603-619
- [6] Vedaldi A, Soatto S. Quick shift and kernel methods for mode seeking. In: Proceedings of the European Conference on Computer Vision, Marseille, France, 2008. 705-718
- [7] Levinstein A, Stere A, Kutulakos K N, et al. Turbopixels: fast superpixels using geometric flows. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(12): 2290-2297
- [8] Achanta R, Shaji A, Smith K, et al. SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(11): 2274-2282
- [9] Felzenszwalb P F, Huttenlocher D P. Efficient graph-based image segmentation. *International Journal of Computer Vision*, 2004, 59(2): 167-181
- [10] Shi J, Malik J. Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 888-905
- [11] Moore A P, Prince S, Warrell J, et al. Superpixel lattices. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Anchorage, USA, 2008. 1-8
- [12] Liu M Y, Tuzel O, Ramalingam S, et al. Entropy rate superpixel segmentation. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Providence, USA, 2011. 2097-2104
- [13] Liu M Y, Tuzel O, Ramalingam S, Chellappa R. Entropy-rate clustering: cluster analysis via maximizing a submodular function subject to a matroid constraint. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 36(1): 99-112

- [14] Spielman D A, Teng S H. Nearly-linear time algorithms for graph partitioning, graph sparsification, and solving linear systems. In: Proceedings of the thirty-sixth annual ACM symposium on Theory of computing, New York, USA, 2004. 81-90
- [15] Kannan R, Vempala S, Vetta A. On clusterings: good, bad and spectral. *Journal of the ACM (JACM)*, 2004, 51(3): 497-515
- [16] Chung F R. Four proofs for the cheeger inequality and graph partition algorithms. In: Proceedings of ICCM, Hangzhou, China, 2007. 1-22
- [17] Wang J, Wang X. Vcells: simple and efficient superpixels using edge-weighted centroidal voronoi tessellations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(6): 1241-1247
- [18] Arbelaez P, Maire M, Fowlkes C, et al. Contour detection and hierarchical image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(5): 898-916
- [19] Schick A, Fischer M, Stiefelhagen R. An evaluation of the compactness of superpixels. *Pattern Recognition Letters*, 2014, 43(0): 71-80

Superpixel segmentation based on local random walk

Ma Zhiguo^{*}, Miao Jun^{*}, Qing Laiyun^{**}, Chen Xilin^{*}

(^{*} Key Lab of Intelligent Information Processing of Chinese Academy of Sciences (CAS), Institute of Computing Technology, CAS, Beijing 100190)

(^{**} School of Computer and Control Engineering, University of Chinese Academy of Sciences, Beijing 100049)

Abstract

A novel approach to generate superpixels based on local lazy random walk (LLRW) was proposed to improve the compactness of superpixels and reduce the computational complexity. The superpixel segmentation was formulated as a problem of local partition of pixel adjacency graphs, and an intuitive quality measure for superpixel segmentation was given. The LLRW approach firstly initializes the centroids of uniformly titled hexagons as the positions of superpixel seeds, and then uses the local lazy random walk (LLRW) algorithm to calculate the correlation between nearby pixels and superpixel seeds, and sets the label of each pixel as the label of its most correlated seed. Finally, it calculates the new centroids of superpixels as the next iteration's seed positions, and iterates these steps to refine the superpixel segmentation result. This algorithm has the linear time complexity and the space complexity, as well as a theoretical guarantee on the quality of superpixels. The experimental results show that the new method can preserve smooth boundaries and generate compact superpixels, so it is an ideal algorithm for real-world applications.

Key words: superpixel segmentation, normalized cut, local graph partition, conductance, local lazy random walk (LLRW)