文章编号:2096-1472(2024)03-0030-06

基于皮尔森相关系数的自适应 SLIC 超像素分割算法

梁皓涵, 王志强, 崔 鹏

(哈尔滨理工大学计算机科学与技术系,黑龙江 哈尔滨 150000)
 ☑ 1448200309@qq.com; 15216806589@163.com; 641397290@qq.com



摘 要:针对简单线性迭代聚类(Simple Linear Iterative Clustering, SLIC)算法对不同图像自适应性差的问题, 提出了一种基于皮尔森相关系数的自适应 SLIC 超像素图像分割算法。首先,通过量化非间隔进行图像预处理,并 计算颜色熵作为图像复杂度,从而确定所需分割的超像素个数。其次,利用皮尔森相关系数作为相似性度量函数。 最后,通过纹理特征对类内异常点进行滤除,确保种子点更新的准确性。实验结果表明,在超像素个数相同的情况下, 基于皮尔森相关系数的自适应 SLIC 超像素图像分割算法相比主流超像素分割算法,可以获得更高的边缘命中率以及 更低的欠分割率,性能优于 LSC(Linear Spectral Clustering)、SLIC 和 SLIC0(Simple Linear Iterative Clustering Zero) 算法。

关键词:SLIC 算法;自适应性;皮尔森相关系数;超像素图像分割;图像复杂度中图分类号:TP391 文献标志码:A

Adaptive SLIC Superpixel Segmentation Algorithm Based on Pearson Correlation Coefficient

LIANG Haohan, WANG Zhiqiang, CUI Peng

(Department of Computer Science and Technology, Harbin University of Science and Technology, Harbin 150000, China) ⊠ 1448200309@qq.com, 15216806589@163.com; 641397290@qq.com

Abstract: This paper proposes in adaptive Simple Linear Iterative Clustering (SLIC) superpixel image segmentation algorithm based on Pearson correlation coefficient to address the issue of poor adaptability of SLIC algorithm to different image. Firstly, image preprocessing is performed by quantifying non-intervals, and color entropy is calculated as the image complexity to determine the number of superpixels required for segmentation. Secondly, Pearson correlation coefficient is utilized as the similarity measurement function. Finally, texture features are used to filter out intra-class outliers, ensuring the accuracy of seed point updates. Experimental results demonstrate that, under the same number of superpixels, the proposed algorithm can achieve higher edge hit rate and lower under-segmentation rate, compared to the mainstream superpixel segmentation algorithms on the BSD500 dataset. The performance of the proposed algorithm surpasses that of LSC (Linear Spectral Clustering), SLIC, and SLIC0 (Simple Linear Iterative Clustering Zero) algorithms.

Key words: SLIC algorithm; adaptability; Pearson correlation coefficient; superpixel image segmentation; image complexity

0 引言(Introduction)

REN 等^[1]首次提出了超像素分割的概念,超像素分割已被 广泛应用于图像处理的各个领域,如图像处理、图像分割、目标 识别等。图像分割的质量直接关系到后续图像处理和分析任务 的效果,因此研究超像素算法已经成为图像分割领域的重要 课题。

目前,超像素算法可以分为基于图论和基于梯度下降的方法。基于图论的方法将图像视为带权无向图,像素点代表图中

的顶点,相邻关系为边,相似性为边的权值,利用各种分割准则 实现图像分割,基于梯度下降的方法从粗聚类开始,不断更新 聚类直至收敛^[2]。以上方法包括 Ncut^[3](归一化割)、Graph-Based^[4](基于图割)、Watershed^[5](分水岭)、Mean-Shift^[6](均 值漂移)、Turbopixel^[7](基于几何流的超像素)、SLIC^[8](简单 线性迭代聚类)和 FSLIC^[9](模糊简单线性迭代聚类)等,其中 SLIC 算法因生成的超像素形状规则、分布紧凑而得到广泛关 注,但是 SLIC 算法需要人工设置相关参数,并且在批量化分割 图像时表现不佳。

本文针对 SLIC 算法的缺陷,提出了基于皮尔森相关系数 的自适应 SLIC 超像素分割算法:首先将 Lab 颜色空间下的三 分量不均匀地划分为一维向量作为新的颜色空间,利用颜色熵 评估图像的复杂度用于计算超像素的个数;其次采用皮尔森相 关系数作为相似性度量方法,计算像素点与种子点之间的相似 性程度;最后计算新颜色空间下一维颜色分量的共生矩阵的同 质度和相关性,用于滤除类内异常像素点。实验结果表明:该 算法能够自动有效地生成紧密贴合轮廓边缘的超像素区域,实 现更精确的分割。

1 SLIC 算法(SLIC algorithm)

SLIC 算法本质上是一种基于 Kmeans 聚类的超像素算法,它通过将像素点的位置信息考虑到标签分割的标准当中, 从而获得更加紧凑且均匀的超像素,并且相较于 Kmeans 算法,SLIC 算法的时间复杂度有所降低。SLIC 算法的具体步骤 如下。

步骤1:

根据预先给定所需要分割超像素的个数对种子点进行初始化,假设图像的样本空间下总共有 N 个像素点,预分割的超像素个数为 K 个,每个超像素大小尺寸相同,那么每个超像素

的大小为N/K,相邻种子点的步长S为 $\sqrt{N/K}$ 。

步骤 2:

计算出种子点 3×3 邻域范围内斫有像素点的梯度值,将 种子点移至梯度值最小的像素点上。

步骤 3:

在种子点的 2S×2S 的邻域范围内进行搜索,根据公式 (1)计算出该范围内每个像素点与种子点之间的相似性程度, 并选取相似性程度最高的种子点作为该像素点的聚类中心。

$$d_{c} = \sqrt{(L_{i} - L_{c})^{2} + (a_{i} - a_{c})^{2} + (b_{i} - b_{c})^{2}}$$

$$d_{s} = \sqrt{(x_{i} - x_{c})^{2} + (y_{i} - y_{c})^{2}}$$

$$D = \sqrt{\left(\frac{d_{c}}{N_{c}}\right)^{2} + \left(\frac{d_{s}}{N_{s}}\right)^{2}}$$
(1)

其中:*i* 是第*i* 个像素点,*c* 是第*c* 个种子点,*d*_c 是颜色距离,*d*_s 是空间距离,*N*_s 是类内最大空间距离,*N*_c 是类内最大颜色距 离,*D* 是像素点与种子点在颜色空间和距离空间的相似性 度量。

步骤 4:

重复上述步骤 2 和步骤 3 的过程,使 K 个种子点逐渐收 敛到某一个固定值,当每个种子点的前后两次迭代大小变化差 异小于算法所设阈值时,SLIC算法停止,反之,则继续迭代。

SLIC 算法具有超像素分布规则、可控制性好且图像复杂 度较低的优点,但是需要人工确定超像素的个数以及类内的最 大颜色距离,并且类内的最大颜色距离会影响最终的分割效 果,若设置较小,则会出现过分割现象;若设置较大,则会出现 欠分割现象。

2 自适应 SLIC 超像素分割算法 (Adaptive SLIC superpixel segmentation algorithm)

针对 SLIC 算法存在的问题,本文提出基于皮尔森相关系数的自适应 SLIC 算法。首先,对 Lab 空间(一种基于设备的用于描述颜色感知的颜色空间)进行量化非间隔处理,计算出量化后新颜色空间下的颜色熵和共生矩阵,利用颜色熵计算图像复杂度,从而自适应地确定图像分割所需的超像素个数;其次,利用皮尔森相关系数计算相似性;最后,利用共生矩阵的同质度和相关性纹理特征对异常点进行滤除。

2.1 图像复杂度计算

2.1.1 Lab 空间

Lab 空间由一个亮度通道和两个颜色通道组成。在 Lab 空间中,每个颜色用La、b 三个分量表示,各个分量的定义如下:L 代表亮度,a 代表从绿色到红色的分量,b 代表从蓝色到黄色的分量。

在 Lab颜色模型中,*L* ∈ [0,100],*a* ∈ [-127,128],*b* ∈ [-127,128], 人类对于该模型的颜色感知能力相较于 RGB 模型(-+种基于人眼的用于描述颜色感知的颜色空间)而言更加 均匀,同时 Lab 空间比 RGB 空间大,并且它是以数字化方式描述人的视觉感应,与设备无关。

2.1.2 颜色量化处理

在 RGB 颜色空间下,可以表示的颜色共有 2²⁴ 种,但是通 常情况下,人眼所能感知的颜色数量以及一幅彩色图像的颜色 数量不可能达到这么多,因此可以对颜色空间的每一分量进行 量化处理。虽然颜色数量的减少可能会导致图像质量的下降, 但是通过量化处理后,可以快速地实现对图像特征的提取,同 时提取到的内容不会有太大的变化。在本文算法中,首先对 Lab 空间进行量化处理,其次根据人眼对图像的感知特点将 L,a,b 三个颜色分量进行非间隔处理。

颜色量化非间隔处理指的是将 L 分量以及 a、b 分量进行 不均匀划分,其具体划分方式如下:

$$L = \lfloor L/16 \rfloor$$

$$a = \lfloor a/4 \rfloor$$

$$b = \lfloor b/4 \rfloor$$
(2)

根据上述量化公式,可以得出关于三分量新的映射关系, 再根据人眼对于 Lab 空间三分量的敏感度大小进行权重的划 分,从而组成新的一维颜色空间。由于人眼对于亮度变化较为 敏感,因此可以假定 L 分量对于人眼感知颜色的影响最大,a、 b 二分量对于人眼感知颜色的重要性相等,因此三者线性组成 的矢量 f 的表达式如下:

$$f = 16 \times L + 4 \times a + 4 \times b \tag{3}$$

2.1.3 颜色熵

图像的颜色熵可以反映一幅图像所含信息量的大小,颜色 熵值大,则反映图像所含有的信息量大,说明图像颜色丰富;反 之,则反映图像所含有的信息量小,说明图像颜色少。对于人 眼感知一幅图像的复杂程度而言,通常从颜色的丰富程度出 发,因此,颜色熵可以看作对颜色复杂性的一种度量。颜色熵 的表达式如下:

$$C_{ent} = \sum_{i=1}^{N} p_i \log(1/p_i) = -\sum_{i=1}^{N} p_i \log p_i$$
(4)

其中:N表示灰度级个数,*p*_i表示第*i*个灰度级的概率直方图。由于超像素个数的取值通常与图像尺寸具有一定的关系,因此结合图像的长宽和颜色熵,得到自适应 *K* 值表达式如下:

$$K = |(r+c) \times C_{ent}/m| \tag{5}$$

其中:r表示图像的宽,c表示图像的长,C_{ent}表示图像的颜色 熵;m用于控制生成超像素的个数,本文m取值为6。

为了验证本文所设计的自适应 K 值算法的可行性,测试 了在不同 K 值下对分割结果的影响,图 1 为不同 K 值下的分 割结果比较。为了更好地判断分割结果的好坏,本文采用边缘 召回率(Boundary Recall, BR)对分割结果进行判定。BR 越 大,表明算法的分割结果越接近人工标注的真实分割结果。 图 1(d)和图 1(h)为自适应 K 值算法所分割的结果。图 1(b)、 图 1(c)、图 1(f)和图 1(g)为人工设置超像素个数得到的分割 结果。图 2 为不同 K 值下的 BR 比较,从图 2 中可以观察到, 采用自适应 K 值算法分割的结果得到的 BR 最高。通过对比 K=196 和 K=171 的 BR 发现,并非超像素的数量越多,分割 质量越高;对比 K=150 和 K=291 的 BR 发现,并非超像素数 量越少,分割质量越高。因此,只有合适的超像素数量,才能获 得最佳的分割结果。







Fig. 2 Comparison of BR under different K values

2.2 基于皮尔森相关系数的相似性度量

皮尔森相关系数是一种线性相关系数,是常用的相似性度 量准则,用来反映两个变量之间的相似性程度,取值范围为 -1~1,绝对值越大,说明二者的相似性程度越高。皮尔森相 关系数是对欧式距离的一种优化。因此,本文提出在迭代过程 中可以利用皮尔森相关系数作为 SLIC 算法中的距离度量函 数,具体步骤如下。

首先,初始化每个像素点与种子点之间的相似性程度;其次,在迭代过程中,提取像素点与种子点在颜色空间下三分量 以及位置空间下的二分量组合成五维特征向量,并根据公式 (6)计算出每个像素点与种子点之间的皮尔森相关系数;最后, 选取皮尔森相关系数最大的种子点作为该像素点的聚类中心。 用于计算像素点与种子点之间皮尔森相关系数的表达式如下:



其中:p表示像素点与种子点之间的皮尔森相关系数,pi和pc表示图像的像素点与种子点含有的五维特征向量。

为了验证皮尔森相关系数在 SLIC 算法中作为相似性度量 准则的可行性以及可靠性,测试了 SLIC 算法在不同 N_e 值下 的分割结果,并与本文算法的分割结果进行了比较。本文算法 与在不同 N_e 值下 SLIC 算法的分割结果比较如图 3 所示。



(a)原图 (b) $N_c = 16$ (c) $N_c = 32$ (d)本文算法 图 3 本文算法与在不同 N_c 值下 SLIC 算法的分割结果比较 Fig. 3 Comparison of segmentation results between the proposed

rig, o comparison of segmentation results between the propose

algorithm and SLIC algorithm under different $N_{\scriptscriptstyle c}$ values

从图 3(d)可以观察出,当使用皮尔森相关系数作为像素 点与种子点之间的相似性度量准则时,飞机机身和天空被准确 地分割出来,其分割结果比 SLIC 算法分割的结果更加贴合图 像边缘轮廓,边缘命中率高,欠分割现象少。从图 3(b)和 图 3(c)可以观察出,飞机机身与天空几乎被划分至同一超像素 区域内,出现明显的欠分割现象,并且超像素对于目标边缘的 命中率较低。

从视觉拟合的效果来看,本文算法具有较高的边缘命中率 和较低的欠分割率,但是为了可以更加准确地分析出皮尔森相 关系数作为相似性度量准则相较于加权欧氏距离具有更好的 判别能力,实验选取了边缘区域某一像素点与两个超像素区域 的种子点的皮尔森相关系数以及加权欧式距离进行测试比较。

选点方式为选取图 3(d)中两个超像素区域的种子点为交叉线 的中心点,其类别分别对应天空以及飞机机身,同时选取位于 两个超像素区域之间的边缘区域的像素点为"十"字线的中心 点。记天空区域种子点为 c1,飞机机身区域种子点为 c2,边缘 像素点为p,p到 c_1 和 c_2 的皮尔森相关系数分别记为 ρ_{p,c_1} 和 ρ_{p,c_0} , p 到 c_1 和 c_2 的加权欧氏距离分别记为 d_{p,c_1} 和 d_{p,c_2} ,其 中 c1 在距离空间和颜色空间的五维分量为[187,299,132, 128,120],c2在距离空间和颜色空间的五维分量为[205,315, 68,121,1297, p 在距离空间和颜色空间的五维分量为[200, 305,104,124,127]。通过计算可以得出, pp,c, = 0.990 492, $\rho_{p,c_2} = 0.990482; \ \exists N_c = 16 \ \exists t, d_{p,c_1} = 1.87526, d_{p,c_2} =$ 2. 288 09;当 $N_c = 32$ 时, $d_{p,c_1} = 1.01454$, $d_{p,c_2} = 1.18338$ 。 因此,若选择加权欧式距离对像素点与种子点进行相似性程度 计算,最终会导致 p 属于 c1 类别,从而出现欠分割现象,这是 因为此时的颜色空间分量散度大,对于加权欧氏距离的贡献率 高,而距离空间分量的散度小,对于加权欧氏距离的贡献率低, 导致颜色空间分量在相似性度量中占据主导地位,从而影响了 聚类效果。

2.3 异常点滤除

由于 SLIC 算法在每次迭代后,每个类内的像素点不一定 均与种子点具有较高的相似性,因此若不对某些异常点进行滤 除,容易导致聚类后的种子点在颜色空间以及距离空间上出现 误差,不仅导致迭代次数的增加,而且容易发生误差的传播,从 而影响后续聚类效果。

2.3.1 灰度共生矩阵

在图像处理中,通常采用灰度共生矩阵对纹理进行分析,不同于灰度以及颜色特征,纹理是一种反映图像中同质现象的视觉特征,体现了具有缓慢变化或者周期变化的物体表面结构组织排列属性,其是通过像素点以及周围领域的灰度分布表现的,因此对于一幅灰度图像而言,一定你域范围内的两个像素点之间一定存在某种联系,通过计算图像中具有灰度关系的像素点出现的次数获得灰度共生矩阵,灰度共生矩阵定义如下。

假设一幅图像经过量化处理后共含有 L 个灰度级,两个 像素点分别用 i,j 表示,用 d 表示两个像素点在空间之间的位 置关系,其中不同的 d 决定了两个像素点之间的距离和方向, 用 $P_d(i,j)$ 表示方向相距 d 的像素点出现的次数, θ 表示灰度 共生矩阵的生成方向,通常取值为 0°、45°、90°、135°。

当 *d* 确定后,两个像素点之间的距离和方向也随之确定, 生成了具有一定关系 *d* 下的灰度共生矩阵,如公式(7)所示:

$P_d(0,0)$	$P_{d}(0,1)$	•••	$P_{d}(0, j)$	•••	$P_d(0,L-1)$	
$P_{d}(1,0)$	$P_{d}(1,1)$		$P_d(1,j)$	•••	$P_{d}(1,L-1)$	
:	:		:		:	(7)
$P_{d}(i,0)$	$P_d(i,1)$		$P_d(i,j)$		$P_d(i,L-1)$	(7)
:	:		:		:	
$P_{d}(L-1,0)$	$P_{d}(L-1,1)$		$P_{d}(L-1,j)$		$P_d(L-1,L-1)$	

灰度共生矩阵的每一个元素代表一种灰度组合。例如, P_a(0,0)表示图像上位置关系为 d,并且两个像素点的灰度级 分别为 0 和 0 的出现次数。

2.3.2 灰度共生矩阵的特征

灰度共生矩阵共有 14 种纹理特征值,例如能量、对比度、 相关性、同质度、非相似性和熵等。本文选取同质度和相关性 表征图像的纹理特征。

同质度反映图像纹理的同质性,用于度量图像纹理局部变 化的强弱,该值越大,则说明图像不同的纹理区域间缺少变化, 局部非常均匀。同质度的计算式如公式(8)所示:

$$Hom = \sum_{i} \sum_{j} P_{d}(i,j) \frac{1}{1 + (i-j)^{2}}$$
(8)

相关性用于衡量灰度共生矩阵的元素在行或列方向上的 相似性程度。当矩阵元素像素值均匀相等时,则相关值就大; 相反,当矩阵像素值相差很大时,则相关值就小。若图像中有 水平方向的纹理,则水平方向矩阵的相关值大于其余矩阵的相 关值。相关性的计算式如公式(9)所示:

$$Cor = \frac{\sum_{0}^{L-1} \sum_{j=0}^{L-1} ij P_d(i,j) - \mu_1 \mu_2}{\sigma_1^2 \sigma_2^2}$$
(9)

计算特征值之前,要先确定计算过程中的相关参数。本文 使用量化后的颜色空间的一维分量 f 代替灰度值计算共生矩 阵,为了降低时间复杂度,将 f 由 265 个颜色级降至 8 个颜色 级,并选择 5×5 大小的滑动窗口对每个像素点进行特征提取, 室间位置关系 d 设置为 1,选取 4 个方向统计共生矩阵, θ 分别 为 0°、45°、90°、135°。

2.3.3 基于同质度和相关性纹理特征的异常点滤除

在每次迭代后,对类内与种子点在纹理特征空间上相似性 程度低的像素点进行滤除,再用类内剩余的像素点对种子点进 行更新。基于同质度和相关性纹理特征的异常点滤除算法的 表达式如下:

$$\boldsymbol{\omega}_{c} = (\|\boldsymbol{g}_{i} - \boldsymbol{g}_{c}\| \leqslant T) \bigcap G_{c}$$
(10)

其中:g表示同质度和相关性纹理特征所组成的二维向量, G_c 表示第c类内区域, ω_c 表示滤除异常点后第c类内区域;T 为常数,本文取值为 0.1。公式(10)表示当类内某一像素点的 同质度与相关性的值与种子点同质度和相关性的值的欧式距 离大于 T 时,将该点滤除,用剩余像素点对 G_c 进行更新,从而 得到新区域 ω_c 。

3 实验结果分析(Experimental results and analysis)

为了证明本文算法的可行性以及可靠性,采用 BR、分割覆盖 率(Segmentation Covering, SC)、概率兰德指数(Probabilistic Rand Index, PRI)和信息变化率(Variation of Information, VOI)4种 指标对本文算法进行性能验证。参与验证的对比算法有 LSC、 SLIC 和 SLIC0,其中 LSC 算法中超像素紧凑度因子参数设置 为 0.075;SLIC、SLIC0 与本文算法的迭代次数均设置为 10; SLIC 算法和 SLIC0 算法中的类内最大颜色距离均设置为 10。 实验数据集来自 BSD500 数据集。实验设备为英特尔 2.2 GHz 和 16 GB内存的"联想"笔记本电脑。

3.1 分割结果

超像素算法作为图像预处理算法,需要实现能生成紧密贴 合目标物体边缘轮廓的超像素区域,超像素生成的好坏将影响 后续算法的进行,因此超像素算法应该尽可能地提高自身对于 图像边缘的命中率。采用 BSD500 数据集对本文算法和 LSC、 SLIC 和 SLIC0 三种经典超像素算法进行比较,其分割结果如 图 4 所示。



(a)LSC
 (b)SLIC
 (c)SLIC0
 (d)本
 图 4 基于 BSD500 数据集的 4 种算法的分割
 结果对比图(K=386)

Fig. 4 Comparison of segmentation results of four algorithms based on the BSD500 dataset (K=386)

从图 4(a)可以观察出,SLIC 算法和 SLIC 算法和 JLCO 算法出现了欠 分割现象,均未将山体从背景区域件分割出来,而本文算法与 LSC 算法的分割效果相近,均将山体和背景区域完整地分割出 来,并产生了比较准确且贴合的轮廓,基本贴合图像中模糊的 山体的边缘区域;从图 4(b)可以观察出,本文算法将十字架标 志从背景区域中准确地分割出来,而 LSC 算法、SLIC 算法和 SLICO 算法均未将十字架从背景区域中分割出来,其欠分割现 象均出现在十字架标志下方的模糊区域。因此,本文算法对于 弱边缘的识别能力更强;从图 4(c)可以观察出,LSC 算法对边 缘贴合的程度和本文算法近乎一致,但 LSC 算法未将图像中 白色岩石区域与背景区域完整地分割出来,出现了少部分欠分 割的现象,而 SLIC 算法和 SLICO 算法均出现欠分割现象,并 且边缘命中率较低。

3.2 分割质量指标

分割质量指标侧重于测量算法的分割精度。一方面是量 化超像素算法获得的分割结果对于边缘拟合的能力,可以通过 BR进行评估;另一方面是量化分割过程中像素之间变化的程 度,可以通过 SC、PRI 和 VOI进行评估。 BR 可以衡量真实边缘落在超像素边界的程度,因此 BR 越高,则说明真实边缘越没有被遗漏,其中 BR 的定义如下:

$$BR(S) = \frac{\sum_{p \in B(g)} I(\min_{q \in B(s)} \|p - q\| < \varepsilon)}{Area(B(g))}$$
(11)

其中:B(g)和B(s)分别为人工标注的超像素边界值和算法生成的超像素边界值的集合;I(•)为指示函数,若算法生成的超像素中的边界像素位于超像素真值中的边界 ε 个像素范围之内,则返回1,否则返回0,ε 通常取值为2;Area(s)为集合 s 的面积。

SC 表示超像素算法获得的分割结果与人工标注的真实结 果之间的重叠程度,SC 越高,则说明超像素算法获得的分割结 果越接近真实的分割结果,其中 SC 的定义如下:

$$SC(G \to S) = \frac{1}{N} \sum_{R \in S} |R| \max_{R \in S'} \frac{|R \cap R'|}{|R \cup R'|}$$
(12)

PRI通过对超像素算法所分割的图像与人工标注的图像 中标签一致的像素进行统计,从而实现对分割质量的评价,PRI 越高,则说明分割结果与真实的分割结果越接近,其中 PRI 的 定义如下:

$$PRI(S, \{G_k\}) = T \sum_{i < j} [c_{ij} p_{ij} + (1 - c_{ij})(1 - p_{ij})]$$

(13)

VOI 是通过计算超像素算法获得的分割结果与人工标注 的真实分割结果之间的平均条件熵作为距离对分割质量进行 衡量的一个标准,VOI 越低,则说明超像素算法获得的分割结 果与真实结果之间信息熵差异越小,即分割结果越贴近真实结 界,其中 VOI 的定义如下:

$$VOI(S_i, S_j) = H(S_i) + H(S_j) - 2I(S_i, S_j)$$
(14)

图 5 给出了本文算法和 LSC、SLIC、SLIC0 算法在不同超 像素个数下在 BSD500 数据集中进行测试得到的 SC、PRI、VOI 及 BR 指标。从图 5 可以观察出,本文算法在超像素个数较少 的情况下,SC 和 BR 指标略低于 LSC 算法的相应指标;而当超 像素数量增加后,SC 和 BR 指标均高于 LSC 算法的相应指标。 相较于 SLIC 算法和 SLIC0 算法,本文算法的 BR 最高,SC 最 高,PRI 最高,VOI 最低,表明通过引入皮尔森相关系数作为相 似性度量准则和类内异常点滤除,既可以避免类内最大颜色距 离选择的合理性对聚类结果的影响,又可以保证聚类中心迭代 的准确性。





Fig. 5 Segmentation quality indicators

4 结论(Conclusion)

本文提出了一种基于皮尔森相关系数的自适应超像素图 像分割算法,其核心在于利用颜色熵对超像素数量进行估算, 以及采用皮尔森相关系数作为相似性度量准则,从而实现了算 法全过程的自适应性。颜色熵可以有效地表述图像的复杂程 度,与其他算法相比,能更好地理解图像复杂程度,对超像素数 量的估算更准确;采用皮尔森相关系数替代了 SLIC 算法的加 权欧式距离,充分考虑了图像相邻像素点之间的相关性,避免 了颜色距离不确定性对聚类结果的影响;此外,引入一个基于 同质度和相关性的纹理特征模型,准确地滤除异常点,使分割 的鲁棒性更强。开展实验验证了本文所提出的颜色熵自适应 确定参数、皮尔森相关系数和异常点滤除模型的有效性,并且 优于现有主流算法的分割结果。未来,将继续关注超像素算法 的分割效果,同时对处理大分辨率图像而言,算法优化、降低时 间成本也是后续的研究重点。

参考文献(References)

- REN X F, MALIK J. Learning a classification model for segmentation[C]//IEEE. Proceedings of the IEEE: 9th IEEE International Conference on Computer Vision. Piscataway: IEEE, 2003: 10-17.
- [2]王春瑶,陈俊周,李炜. 超像素分割算法研究综述[J]. 计算 机应用研究,2014,31(1):6-12.
- [3] SHI J B, MALIK J. Normalized cuts and image segmentation[J]. IEEE transactions on pattern analysis and machine intelligence, 2000, 22(8): 888-905.
- [4] FELZENSZWALB P F, HUTTENLOCHER D P. Efficient graph-based image segmentation [J]. International journal of computer vision, 2004, 59(2):167-181.
- [5] VINCENT L, SOILLE P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations [J].
 IEEE transactions on pattern analysis and machine intelligence, 1991, 13(6): 583-598.
 - 6] COMANICIU D, MEER P. Mean shift: a robust approach roward feature space analysis [J]. IEEE transactions on pattern analysis and machine intelligence, 2002, 24 (5): 603-619.
- [7] LEVINSHTEIN A, STERE A, KUTULAKOS K N, et al. TurboPixels: fast superpixels using geometric flows [J].
 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 [J]. IEEE transactions on pattern analysis and machine intelligence, 2012, 34(11): 2274-2282.
- [9] WU C, ZHENG J B, FENG Z N, et al. Fuzzy SLIC: fuzzy simple linear iterative clustering[J]. IEEE transactions on circuits and systems for video technology, 2020, 31(6): 2114-2124.

作者简介:

- 梁皓涵(2000-),男,硕士生。研究领域:图像滤波,超像素图像 分割。
- 王志强(1998-),男,硕士生。研究领域:图像处理,行人重 识别。
- 崔 鹀(1971-),男,博士,副教授。研究领域:图像处理,机器 学习。本文通信作者。