

基于自适应超像素分割的点刻式 DPM 区域定位算法研究

王娟¹ 王萍¹ 王港¹

摘要 为解决点刻式直接零件标志 (Direct part mark, DPM) 码基本单元分割困难、区域定位欠精确等问题, 提出使用超像素分割和谱聚类相结合的算法, 对含有 DPM 区域的图像进行初步分割和精确定位. 首先为提高超像素分割的准确、快速和完整性, 本文利用近邻传播聚类思想实现自动聚类得到超像素区域, 并引入边缘置信度调整超像素边缘, 形成自适应边缘简单线性迭代聚类 (Adaptive edge simple linear iterative clustering, AE-SLIC) 算法. 该算法改进了简单线性迭代聚类 (Simple linear iterative clustering, SLIC) 超像素分割算法存在的未明确界定超像素区域边缘信息和分割数目无法自适应确定等问题; 其次, 将超像素作为谱聚类中图的顶点进行二次聚类, DPM 区域内超像素因相似度高而被聚集为一类, 从而完成点刻式 DPM 区域的精确定位. 经实验测试和分析, 本文算法得到的超像素分割结果在完整性、运算复杂度等方面优于常见的超像素分割算法. 与基于像素点运算的传统定位算法相比, 本文算法具有良好的实时性、定位准确率和鲁棒性.

关键词 超像素, 自适应边缘简单线性迭代聚类算法, 谱聚类, 精确定位

引用格式 王娟, 王萍, 王港. 基于自适应超像素分割的点刻式 DPM 区域定位算法研究. 自动化学报, 2015, 41(5): 991–1003

DOI 10.16383/j.aas.2015.c140233

Stippled Direct Part Mark Location Based on Self-adaptive Super-pixels Segmentation

WANG Juan¹ WANG Ping¹ WANG Gang¹

Abstract In order to solve the problem existing in segmentation and location of the stippled direct part mark (DPM) code, this paper combines the advantages of super-pixels segmentation and spectral clustering algorithm to pre-segment and precisely locate the DPM area. First, we propose an adaptive edge simple linear iterative clustering (AE-SLIC) super-pixels segmentation algorithm to achieve accurate, fast and integral segmentation. The super-pixels are generated by affinity propagation automatically and edges of super-pixels are adjusted by edge confidence in AE-SLIC, which has improved the problems of unclear definition of edge and non-adaptive number of super-pixels in the simple linear iterative clustering (SLIC) algorithm. Second, the super-pixels are treated as the vertexes of spectral clustering. Then the location of stippled DPM code is completed by the clustered group of the super-pixels. The experimental results demonstrate the superior performance of the AE-SLIC algorithm in terms of segmentation accuracy and computation efficiency. Through comparison with the traditional location algorithm based on the operation of pixels, the proposed algorithm shows its property of real-time, location accuracy and robustness to the noise disturbance.

Key words Super-pixels, adaptive edge simple linear iterative clustering (AE-SLIC) algorithm, spectral clustering, accurate location

Citation Wang Juan, Wang Ping, Wang Gang. Stippled direct part mark location based on self-adaptive super-pixels segmentation. *Acta Automatica Sinica*, 2015, 41(5): 991–1003

直接零件标志 (Direct part mark, DPM)^[1] 条码 (DPM 码) 是物联网工业生产领域中一类重要的信息源, 是使用特殊工艺手段生成的二维条码, 目前被广泛应用于机械电子行业的零部件、汽车制造、制药医疗、军队枪械管理等领域.

根据 DPM 码中基本单元的形状, 可分为以矩形块为基本单元的点阵式和以圆形或椭圆形为基本单元的点刻式^[1]. 由于 DPM 码多应用于金属、铸铁、木材、玻璃等材质中, 因此需要使用通过激光点刻、蚀刻、击打撞机等手段点刻而成, 以保证 DPM 码的永久性和不易磨损性. 而在背景复杂的条件下, DPM 码的特征较为隐蔽, 容易与工件上的其他信息混淆, 有效信息部分也易出现在凹凸不平的介质上, 从而导致定位困难.

目前, 国内外对 DPM 码尤其是点刻式 DPM 码的定位识别研究较少. 以往, 二维码定位算法多利用二维码的几何形态, 采用边缘提取、几何检测

收稿日期 2014-04-08 录用日期 2014-12-23
Manuscript received April 8, 2014; accepted December 23, 2014
河北省科技支撑项目 (12213519D) 资助
Supported by Science and Technology Support Program of Hebei Province (12213519D)
本文责任编辑 章毓晋
Recommended by Associate Editor ZHANG Yu-Jin
1. 天津大学电气与自动化工程学院 天津 300072
1. College of Electrical and Automation Engineering, Tianjin University, Tianjin 300072

等^[2-4]方法定位和分割二维码,其优点是对于背景简单、标记清晰的二维码的定位速度较快.但在背景复杂、对比度低的 DPM 二维码上使用时,误检率极高.而国外少数几家大公司利用顶尖的硬件技术^[5-6]弥补软件检测算法的缺陷,同时在定位过程中加入辅助线或定位点预定位条码区域,然后提取条码数据,以便提高其准确率.但此种方法约束较多,对实时在线检测点刻码的适用性不高.

以上提及算法多数停留在使用由单个像素组成的二维矩阵来表示二维码结构,即通过对图像中基于像素的特征来描述图像内容.对于像素点聚集特征明显的 DPM 码图像来说,以像素为单位计算效率较低.而超像素^[7]方法在反映区域特性、计算快速等方面具有优势.目前,鲜有研究者从超像素分割的角度定位 DPM 区域.

超像素分割算法可分为两类,一类是基于图论的方法,包括 Graph-based 方法^[8]、规范割准则(Normalized cuts, N-cuts)方法^[9]、Superpixel Lattice 方法^[10]和基于熵率方法^[11];另一类是基于梯度下降的分割方法, Turbopixels 算法^[12]、快速漂移(Quick shift, QS)算法^[13]、分水岭算法^[14]以及简单线性迭代聚类(Simple linear iterative cluster, SLIC)算法^[15-16]等属于此类.其中, N-cuts 使用最小割算法,采用新颖的归一化割标准,度量区域间的差异和区域内的相似性.算法特点是可以控制超像素的数量,且形状比较规整和紧凑.但是 N-cuts 算法速度较慢,尤其对于尺寸比较大的图片,计算量大,实用性较低. Turbopixels 算法是基于几何流的水平集方法,该算法通过膨胀初始化聚类中心,并结合曲率演化模型和背景区域的骨架化过程,将图像分割为网格状的超像素.但对边界的保持很差. SLIC 算法提出了一种基于颜色和距离相似性进行超像素分割的算法,该算法思想简单,可产生大小均匀、形状规则的超像素,但存在着分割数目需人为指定和超像素边缘划分不清晰等缺点.

综上所述,本文在讨论 SLIC 分割算法的基础上,提出一种改进算法,即自适应边缘简单线性迭代聚类(Adaptive edge simple linear iterative clustering, AE-SLIC)算法,该算法引入近邻传播思想和边缘置信度约束,达到自适应分割和准确界定超像素边缘的目的.同时,在深入分析点刻式 DPM 码特征后,将 AE-SLIC 算法和谱聚类算法有机结合,实现对 DPM 码区域的准确定位.实验测试中,分别选取基于图论的 N-cuts 算法和梯度下降的 Turbopixels 算法、SLIC 算法及本文算法进行对比实验.通过效率、欠分割错误率(Under-segmentation error)^[12]和边界召回率(Boundary recall)^[12]的比较,分析和验证本文算法的有效性.同时,将本文的

DPM 码区域定位算法与经典定位算法在计算时间和定位准确率等方面进行对比,说明本文算法的快速性和准确性.

1 相关算法概述

超像素是指图像中局部区域内连通的、亮度相近的像素集合^[7].超像素分割后图像的结构粒度大大提高,有利于后期算法的处理.

1.1 SLIC 算法

SLIC 算法^[15]将含 N 个像素点的 RGB 彩色图像转化为 CIELAB 颜色空间和 X - Y 坐标下的 5 维特征向量 $C_i = (l_i, a_i, b_i, x_i, y_i)$, $i = 1, \dots, N$, 然后对 5 维特征向量构造相似度度量,对图像像素进行局部聚类,形成超像素区域.文献[17]利用 GPU 和 NVIDIA、CUDA 等硬件处理速度快的优势,将 SLIC 算法速度提高 10~20 倍,促使 SLIC 算法能应用于人工可干预的实时系统中.文献[18]在用 SLIC 算法得到超像素分割区域的基础上,提出具有核心化特征结构图像分割算法,然后建立以超像素为节点、空间相邻节点间关系为边连接的图模型实现基于超像素的图像分割.

SLIC 算法具体实现^[15]如下:

步骤 1. 初始化聚类中心

假设图像有 N 个像素点,预先设定分割出 K 个超像素,并设每个超像素大小近似为 N/K ,以间距 $S = \sqrt{N/K}$ 选择 K 个初始种子.

为了避免聚类中心位于对象的边缘,将初始聚类中心在以它为中心的 3×3 的邻域窗口内移动到梯度值最小的位置.图像梯度计算公式为

$$G(x, y) = \|l(x+1, y) - l(x-1, y)\|^2 + \|l(x, y+1) - l(x, y-1)\|^2 \quad (1)$$

其中, $l(x, y)$ 是特征向量 C_i 的前三个分量.由此得到初始聚类中心 p_i , $i = 1, \dots, K$.

步骤 2. 相似度度量

SLIC 算法中相似度度量方法如下:

$$d(i, k) = d_{lab} + \frac{m}{S} d_{xy} \quad (2)$$

$$d_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (3)$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (4)$$

其中, d_{lab} 为像素点间的色差, d_{xy} 为像素点间的空间距离, $d(i, k)$ 为第 i 个像素点与第 k 个聚类中心之间的相似度,取值越小,两者越相似. $m \in [1, 20]$ 为平衡参数,以平衡颜色值与空间信息在相似度度量中的比重.

步骤 3. K 均值聚类^[19]方法更迭聚类中心

假定在 $X-Y$ 平面上聚类中心的关联像素点位于其 $2S \times 2S$ 区域^[16] 内. 所有像素点被关联到最近的聚类中心后, 新聚类中心更改为同类别中所有像素点 5 维向量的平均值. 重复此过程, 直到收敛, 停止迭代.

步骤 4. 形成超像素

将最相似的聚类中心标签赋给像素点, 形成 K 个超像素.

1.2 SLIC 算法分析

从上述 SLIC 算法实现过程可以看出, SLIC 算法存在分割数目固定和边缘界定不清晰等缺陷.

SLIC 算法的分割数目 K 是由研究者自行设定的, K 值一旦确定将不再变化. 若指定调整分割的数目欠妥, 易出现欠分割或过分割的现象. 以含有 DPM 码区域的图像为例, 将 SLIC 算法中 K 值分别取 100、250、300. 从分割效果可以看出, 尽管 K 的取值不断地人为调整, 但仍未能找到合适的分割数目. DPM 码区域内的基本单元出现欠分割 (图 1(a)) 和过分割 (图 1(b) 和图 1(c)) 现象. 因此, SLIC 算法在未准确获知先验知识的情况下实用性较低.

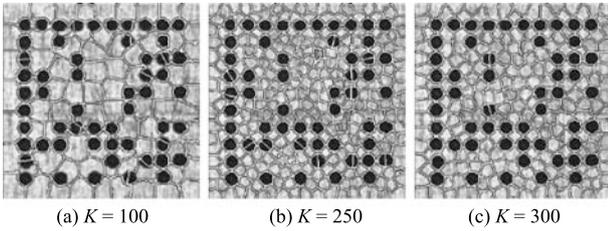


图 1 不同 K 值 SLIC 算法分割结果

Fig. 1 Segmentation results of different K using SLIC

另外, 待分割物体的边缘是描述或识别目标以及解释图像的重要特征, 是纹理特征的重要信息源和形状特征的基础. 而在 SLIC 算法中, 聚类中心的迭代选择依赖于邻域窗口的大小, 并未充分考虑待分割物体边缘信息. 这一缺陷将影响到图像的分割质量 (见图 1) 及后续的特征提取和分析理解.

2 AE-SLIC 算法

2.1 自适应确定超像素数目

本文针对分割数目固定带来的问题, 借鉴近邻传播^[20] 算法思想, 减小分割对初始条件的依赖, 即通过吸引函数 (式 (5)) 和归属函数^[20] (式 (6)) 在迭代中调整聚类中心的数量和位置, 完成超像素自适应分割.

定义 1. 用 i 和 k 两个像素点之间的吸引函数反映 k 点吸引 i 点作为其聚类中心的可能性, 记为 $r(i, k)$.

$$r(i, k) = s(i, k) - \max_{k' \neq k} \{a(i, k') + s(i, k')\} \quad (5)$$

其中, $s(i, k) = -d(i, k)$ 为 i 点与 k 点之间的相似度, $s(i, k') = -d(i, k')$ 为 i 点与非 k 点之间的相似度, $a(i, k')$ 为 i 点与非 k 点的归属函数.

定义 2. 用 i 和 k 两个像素点的归属函数反映 i 点选择 k 点作为其中心的可能性, 记为 $a(i, k)$.

$$a(i, k) = \begin{cases} \min_{i \neq k} \{0, r(k, k) + \sum_{i' \neq i, k} \max[0, r(i', k)]\}, & i \neq k \\ \sum_{i' \neq k} \max[0, r(i', k)], & i = k \end{cases} \quad (6)$$

其中, $r(k, k)$ 为 k 点自身吸引函数, $r(i', k)$ 为非 i 点与 k 点的吸引函数.

为避免数据震荡, 本文加入阻尼系数 $\lambda \in [0, 1)$ ^[20] (根据实验, $\lambda = 0.9$), 吸引函数和归属函数的迭代关系定义如式 (7) 和式 (8) 所示. 式中, t 为迭代次数.

利用吸引函数和归属函数, 不断地对可能的聚类中心传递此两种类型的消息, 增加其成为聚类中心的可能性, 直到成为局部区域中的最大值. 即 $r(i, k)$ 与 $a(i, k)$ 之和越大, 则 k 点作为聚类中心的可能性就越大, 并且 i 点隶属于该类的可能性也就越大, 则将该点更迭为新的聚类中心. 此时吸引力强

$$r^{(t)}(i, k) = \lambda r^{(t-1)}(i, k) + (1 - \lambda) \left\{ s(i, k) - \max_{k' \neq k} [a^{(t-1)}(i, k') + s(i, k')] \right\} \quad (7)$$

$$a^{(t)}(i, k) = \begin{cases} \lambda a^{(t-1)}(i, k) + (1 - \lambda) \min_{i \neq k} \left\{ 0, r^{(t-1)}(k, k) + \sum_{i' \neq i, k} \max [0, r^{(t-1)}(i', k)] \right\}, & i \neq k \\ \lambda a^{(t-1)}(i, k) + (1 - \lambda) \left\{ \sum_{i' \neq k} \max [0, r^{(t-1)}(i', k)] \right\}, & i = k \end{cases} \quad (8)$$

且归属感高的点选为新的聚类中心, 而新聚类中心的个数及位置取决于信息传递的能量分布, 与当前聚类中心的个数及位置无关.

在 $r(i, k)$ 和 $a(i, k)$ 的迭代过程中, 若所有像素点均参与计算, 数据量较大. 因此, 本文首先对待分割图像进行区域预划分, 在局部区域内计算 $r(i, k)$ 和 $a(i, k)$. 经过多次迭代后, 当聚类中心的位置不再发生变化时, 停止迭代, 超像素的聚类中心数及聚类中心位置便自适应地确定下来.

2.2 基于边缘信息的修正

SLIC 算法在聚类中心均匀分布的前提下通过 K 均值聚类得到超像素区域, 未顾及边缘信息, 易造成图像对象被割断或分割区域过大等问题. 为此, 本文在聚类完成后加入基于边缘置信度测度的调整^[22], 提高分割的准确性.

在此, 考虑使用边缘像素的邻域标准差^[23] 作为边缘置信度的度量. 设超像素的边缘像素 $p(x, y)$ 在图像 I 中相应的邻域标准差为

$$\xi_{x,y}^p = \sqrt{\frac{1}{m^2 - 2} \sum_{p(x,y) \in U_m} (p(x,y) - \bar{\mu}_{x,y})^2} \quad (9)$$

其中, U_m 是 $p(x, y)$ 的不包含最大最小灰度值的 $m \times m$ 邻域中像素点的集合, $\bar{\mu}_{x,y}$ 为 U_m 中像素点灰度值的均值. 设

$$\xi'_{x,y} = \frac{\xi_{x,y}^p}{T_\xi} \quad (10)$$

其中, $T_\xi = \max(\xi_{x,y}^I)$ 是图像 I 中最大邻域标准差, $\xi'_{x,y}$ 是对 $\xi_{x,y}^p$ 的归一化处理. 邻域相对标准差说明局部区域内的灰度变化趋势, 其值越大, 则灰度变化越显著, 存在边缘的可靠性越高; 其值越小, 则灰度变化越平缓, 存在虚假边缘的可能性越大. 因此, 构造敏感于边缘真伪的置信度函数 f 如下:

$$f(\xi'_{x,y}) = \begin{cases} \frac{1 + \sqrt{2\xi'_{x,y} - 1}}{2}, & \xi'_{x,y} \geq 0.5 \\ 2(\xi'_{x,y})^2, & \xi'_{x,y} < 0.5 \end{cases} \quad (11)$$

当 $\xi'_{x,y} < 0.5$ 时, 置信度 $f(\xi'_{x,y})$ 受到抑制, $f(\xi'_{x,y})$ 越小对应的边缘像素的真实性越低, 相应受到的抑制越显著; 当 $\xi'_{x,y} \geq 0.5$ 时, 置信度 $f(\xi'_{x,y})$ 被放大, 边缘的可靠性增高. 对于置信度较低的超像素边缘像素点, 使用式 (1) 计算其邻域 δ 内各点的梯度. 并搜索到该邻域内梯度最大的点, 计算此点梯度方向为

$$\theta = \arctan \frac{G(x, y)}{G(x-1, y-1)} \quad (12)$$

其中, $G(x, y)$ 为此点的梯度. 而后将 δ 内满足置信度阈值条件且其梯度方向为 θ 的点定义为新的边缘点, 从而实现边缘的回缩或延伸.

为提高计算效率, 对一幅含有 N 个像素点的图像, 本文算法将预划分的区域大小定义为 S' , 区域个数为 $n' = N/S'$, $n' \in [10, 20]$. 综合上述内容, AE-SLIC 算法具体步骤总结于算法 1.

算法 1. AE-SLIC 算法

步骤 1. 令 $a^{(0)} = r^{(0)} = 0$, $\lambda = 0.9$, $t = 1$, 标记各预分区域为 α , $\alpha \in [1, n']$.

步骤 2. 在第 α 个区域内依次计算两点之间的相似度 $s(i, k) = -(d_{lab} + (m/\sqrt{S'})d_{xy})$. 设 $s(k, k) = \sum s(i, k)/S'$.

步骤 3. 利用数据之间的信息传递, 并根据式 (7) 和式 (8) 依次计算 $r^{(t)}(i, k)$ 和 $a^{(t)}(i, k)$, 开始迭代.

步骤 4. 若 $r^{(t)}(i, k)$ 和 $a^{(t)}(i, k)$ 不再发生改变或到达最大迭代次数, 则停止迭代. 将 $r^{(t)}(i, k)$ 与 $a^{(t)}(i, k)$ 之和最大的点作为聚类中心 p_i^α , $i = 1, \dots, K_\alpha$.

步骤 5. $\alpha = \alpha + 1$, 重复步骤 3~5, 直到遍历整幅图像.

步骤 6. 最终确定自适应的超像素数 $K' = \sum_{\alpha=1}^{n'} K_\alpha$.

步骤 7. 对分割好的超像素的边缘点进行边缘置信度计算, 并根据梯度方向一致性原则对边缘进行延伸或回缩, 直到置信度符合阈值条件为止.

为评价 AE-SLIC 算法的聚类结果, 将每个像素点和它所属类的中心点之间距离的平方和定义为失真度^[21], 即

$$Distortion = \sum_{k=1}^K \sum_{i=1}^{N_K} d_{xy}^2 \quad (13)$$

其中, k 是点 i 所属类的中心, N_K 为 i 点所属类别中的像素点数. 失真度越小, 表明相似度越高, 则聚类效果越好. 以图 2 中图像为例, 分别计算 SLIC 算法和本文算法中聚类的失真度, 结果如图 3 所示.

通过失真度的比较, 可知本文 AE-SLIC 算法失真度小于 SLIC 算法. 同时, 本文算法的自适应性规避了 SLIC 算法需人工干预的缺点.

2.3 时间复杂度分析

本文算法以近邻传播算法为聚类基础, 只需进行一次相似度计算. 在迭代过程中, r 和 a 的计算是一次型的. 而对于相同的迭代次数, 基于 K 均值的 SLIC 算法每次迭代需要进行误差平方和的二次计算. 同时本文算法中对边缘信息的调整只涉及到边缘置信度低的边缘点梯度的计算, 与聚类过程相比,

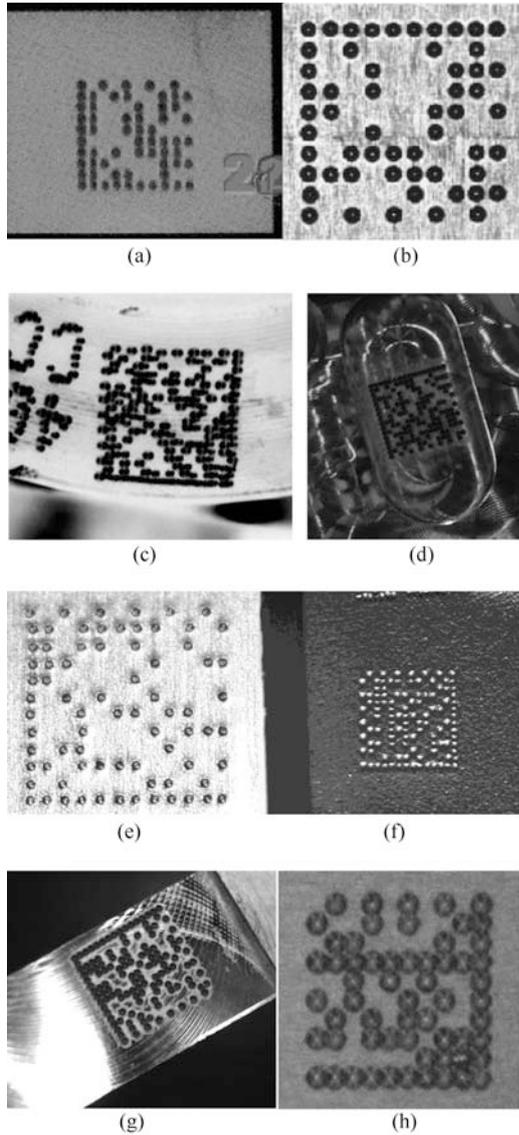


图 2 DPM 码实例

Fig. 2 Examples of DPM barcode

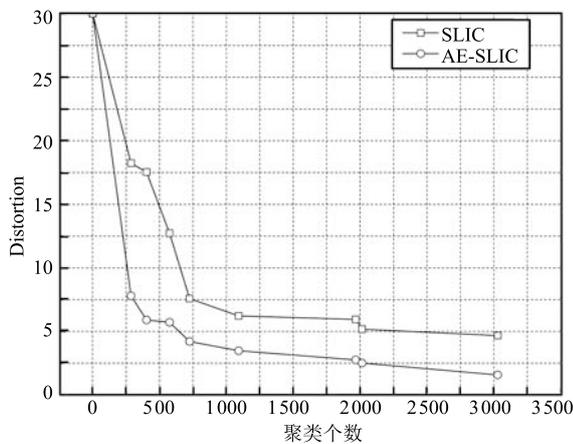


图 3 失真度比较

Fig. 3 Comparison of distortion

其计算量可忽略. 因此, 在算法复杂度方面, 本文算法优于 SLIC 算法 (第 5.1 节的实验验证了此优势).

3 DPM 码的特征分析

点刻式 DPM 码根据对表面的破坏与否和工艺生产条件^[24], 可分为非侵入式和侵入式直接标印.

非侵入式直接标印是指对零部件的性能无影响, 在零件的制造过程中通过添加标印介质形成标印符号. 常用的非侵入式直接标印方法有: 整体法、漆印、喷墨法、丝网印等, 如图 2 (a) 和图 2 (b) 所示.

侵入式直接标印主要通过雕刻、腐蚀、汽化等方式改变零部件或物体的物理表面, 使物体表明发生形变组成 DPM 码区. 常用的侵入式直接标印方法有: 吹砂法、激光蚀刻/雕刻、打点标印、电化学标印、雕刻、金属压印等, 如图 2 (c)~2 (h) 所示.

从图 2 可以看出, 无论是侵入式还是非侵入式生成方法, 由于 DPM 条码所处工况环境和载体介质的不同, DPM 码图像多出现图像模糊 (图 2 (h))、噪声干扰 (图 2 (d) 和图 2 (g))、对比度低、光照不均等情况. 同时, DPM 码区的基本单元的颜色和形状特征相似或相近, 如果将每个基本单元看作独立的区域, 则适于超像素的使用. 因此本文将首先使用 AE-SLIC 算法对含有 DPM 码的图像进行超像素分割, 而后通过二次聚类, 完成对条码区域的准确定位.

4 点刻式 DPM 码的精确定位

4.1 AE-SLIC 算法的使用

首先, 需要将在不同材质和环境中所采集到的点刻式 DPM 二维码图像依照算法 1 的步骤 1~7 进行超像素分割. 针对 DPM 码图像中易出现对比度较低、图像模糊的现象, 通过修改相似度 $s(i, k)$ 中 d_{lab} 分量的比重, 可减弱相似度度量对颜色对比度的敏感度, 即

$$s(i, k) = \frac{1}{\rho} d_{lab} + \sqrt{\frac{m}{S'}} d_{xy}$$

$$\rho = \frac{\sum_{i=1}^t \sqrt{(l_i - \bar{l})^2 + (a_i - \bar{a})^2 + (b_i - \bar{b})^2}}{t} \quad (14)$$

其中, ρ 为局部区域内色彩平均方差, $t = N/n$. 修改颜色分量比重后, 在低对比度情况下使得超像素分割结果更符合 DPM 码的特征.

受工况环境和图像采集时光照变化的影响, DPM 码区域中出现的非均匀光照现象包括光照突变、曝光过度、曝光不足等现象. 本文的自适应聚类是基于局部区域内像素点的吸引和归属运算, 同时相似度度量中欧氏距离约束了超像素区域的聚集

规模和紧凑度, 而颜色分量的约束则使超像素中对比度相差较小. 因此在自适应聚类运算过程中, 利用其内部像素点的相似性, 聚集出超像素区域, 从而降低了非均匀光照的影响. 第 5.2 节的实验也验证了算法在抑制光照不均现象时的有效性.

其次, 利用式 (10) 和式 (12) 分别计算每个超像素边缘像素点的边缘邻域标准差和置信度. 若边缘置信度较低, 则依据式 (13) 对超像素区域进行收缩或延伸, 使其更符合基本单元分割的要求.

通过 AE-SLIC 算法的使用, 含有 DPM 码的图像能够在复杂背景下获得边缘较为清晰、分割较为合理的超像素.

4.2 二次聚类

本文选取谱聚类^[25]方法实现二次聚类, 目的是找到以 DPM 码区中基本单元所对应的超像素簇, 实现码区定位. 谱聚类算法建立在谱图理论上, 与传统的聚类算法相比, 它具有能在任意形状的样本空间上收敛于全局最优解的优点. 算法 2 描述了谱聚类的具体实现过程.

算法 2. 基于超像素的谱聚类算法

步骤 1. 将 AE-SLIC 算法分割得到的超像素集映射为带权无向图 G , 并构建对象集的相似性矩阵 $W_{ik} = \exp(-\|i - k\|^2/2\sigma^2)$ ($i = 1, \dots, K', k = 1, \dots, K', \sigma$ 为邻域尺度), 当 $i = k$ 时, $W_{ik} = 1$.

步骤 2. 构建对角矩阵 D , 其中, $D(i, i) = \sum_{k=1}^N W_{ik}$, 其他元素为 0.

步骤 3. 建立拉普拉斯矩阵 $L_{sym} = D^{-1/2}LD^{-1/2}$, 计算出前 m 个最大特征值所对应的特征向量 e_1, e_2, \dots, e_m , 然后构造矩阵 $X = [e_1, e_2, \dots, e_m] \in \mathbf{R}^{n \times m}$ 组成特征空间.

步骤 4. 归一化 X 的行向量, 并将归一化后的矩阵记为 Y , $Y_{ij} = X_{ij}/(\sum_j X_{ij}^2)^{1/2}$.

步骤 5. 使用 K 均值算法对特征向量进行聚类. 若矩阵 Y 的第 i 行被划分为第 j 类, 那么相应的超像素区域也被划分到第 j 类.

超像素分割后得到的 K' 个超像素作为谱聚类的顶点 V , 将顶点间的相似度量作为相应顶点连接边 E 的权值, 即可得到一个基于相似度的无向加权图 $G(V, E)$, 于是聚类问题就转化为图的划分问题.

由于本文所研究的 DPM 码区域表现为距离均衡的团状簇, 而 K 均值聚类算法隐含的带有球形的空间结构, 适合发现类球状簇, 这是本文选择 K 均值算法对特征向量进行聚类的重要依据. 但此处使用的特征向量的聚类方法针对性较强, 在实际应用中还需斟酌.

经过谱聚类后, 会将 DPM 码区域中的基本单元聚集于一类, 由此得到精确定位的 DPM 码区域.

对于含有 N 个像素点的图像来说, 直接使用谱聚类时, 其复杂度^[25]为 $O(N^3)$, 矩阵维数较高时, 计算时间过长. 而本文在超像素分割的基础上对超像素使用谱聚类, 大大降低拉普拉斯矩阵的计算维度, 计算复杂度也相应地降低到 $O(K'^3)$. 由于 $K' \ll N$, 则聚类效率得到明显提升.

4.3 噪声滤除策略

DPM 码在采集和使用的过程中, 难免会夹杂噪声干扰. 噪声类型可分为两种: 孤立噪声点和与 DPM 码基本单元类似的噪声斑块. 对于孤立噪声点, 由于与 DPM 码像素点差异明显, 在 AE-SLIC 算法中即可通过相似度比较、归属函数和吸引函数的计算将其滤除.

需要重点处理的是与 DPM 码基本单元在形状和颜色上相类似的噪声斑块. 如图 4 所示, 噪声斑块的分布可能存在于 DPM 码区域外部或内部. 为此, 对于处在不同位置的噪声斑块, 本文将采用不同的去噪策略.

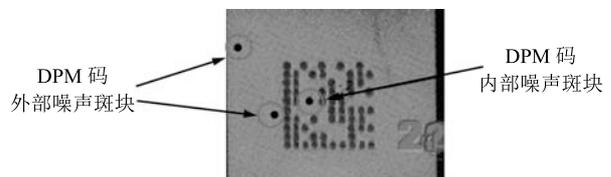


图 4 噪声点的可能分布

Fig. 4 Possibility distribution of noise

与 DPM 码区域位置相距较远的噪声斑块, 因二次聚类中使用欧氏距离为相似度量, 较易去除. 而在内部的噪声斑块, 则可以通过里德所罗门 (Reed-Solomon, RS) 纠错算法^[26]进行纠正.

临近条码区域的噪声斑块对 DPM 码的准确定位影响较大. 此类噪声斑块靠近条码区域, 且与基本单元相似, 二次聚类过程中容易被当作条码区域内部超像素区域处理. 因此, 本文通过对聚类后的 DPM 码区域最外围超像素进行递进式连线, 判断此连线是否为直线. 若非直线, 则说明存在外凸点, 用投票法去除; 若为直线, 则不存在此类噪声斑块.

噪声干扰的有效滤除, 使得算法具有一定的抗噪性, 从而增强该定位算法的鲁棒性.

5 实验评估

实验平台: 本文算法运行的操作系统为 Windows 7, Intel 处理器, 3.2 GHz. 算法在 VS 2010 上实现.

实验样本: 图像来自现场采集的 100 幅含有 DPM 码的图像. 受现场环境和拍摄设备的影响, 实验样本多为背景复杂、对比度低、光照不均匀的图

像. 因此, 对算法要求较高.

本文从超像素分割的计算复杂度、分割效果以及与传统二维码定位算法的对比等方面对本文算法进行评估. 同时使用边界召回率和欠分割错误率对超像素分割的效果进行评价, 验证所提出算法的有效性.

5.1 超像素分割算法复杂度对比

将 100 幅待测图像分为两组, 一组为点阵式 DPM 码 (61 幅), 一组为点刻式 DPM 码 (39 幅). 将本文算法给出的超像素的自适应个数作为公共参数, 分别使用 N-cuts 算法、Turbopixels 算法、SLIC 算法与本文算法在计算时间复杂度上进行比较, 平均计算时间统计于表 1.

表 1 超像素算法计算复杂度对比 (ms)
Table 1 Comparison on complexity (ms)

算法/样本	点阵式 DPM 码	点刻式 DPM 码
N-cuts 算法	> 1 小时	> 1 小时
Turbopixels 算法	2 157.5	2 363.6
SLIC 算法	2 013.9	1 804.2
本文算法	1 443.7	1 316.1

在实验过程中, 由于部分图片数据量较大, 使得 N-cuts 算法计算缓慢, 运行时间超过 1 小时, 因此平均时间也大于 1 小时. 统计结果显示, 本文算法与 Turbopixels 算法相比, 计算时间平均提高 38.9%, 比 SLIC 算法提高了 27.6%.

5.2 超像素分割效果对比

引入边缘置信度, 辅以超像素边缘伸缩或延伸处理后的 AE-SLIC 算法, 使超像素边缘更为准确. 与其他超像素算法相比, AE-SLIC 算法的边缘置信度均大于 0.5. N-cuts 算法、Turbopixels 算法、SLIC 算法与 AE-SLIC 算法的对比示例如图 5~7 所示.

由于其他三种算法均需要在人工干预下确定初始分割数目. 为便于对比, 特将四种算法的分割数目统一为本文算法自适应计算出的数目.

图 5 中三幅图像的分割数目分别为 1 092、287、375, 图 6 中三幅图像的分割数目分别为 3 029、575、667, 图 7 中三幅图像的分割数目分别为 1 967、725、1 235. 同时示例中提供局部放大图 (Local enlarging graphics, LEG), 放大部分所对应的位置在超像素分割图像中使用圆圈标注. 其他三种算法即使是在适合的分割数目的前提下, 因其算法的非自适应性和不关注边缘, 出现了过分割 (图 5 (a)~5 (f))、欠分割 (图 6 (a)~6 (f))、边缘分割模糊 (图 7 (a)~7 (f))

等现象.

图 5 中其他三种算法均出现了将 DPM 码的基本单元分割为两个或多个超像素, 且与待分割目标的边缘符合度较低的情况. 图 6 中其他三种算法将基本单元周围的亮度不同的像素点聚集在一起, 出现了欠分割现象. 而本文算法鲜见超像素过分割和欠分割的现象, 边缘划分较为清晰. 图 7 则为一组在非均匀光照条件下的 DPM 码的分割效果. 从图中可以看出, 其他三种算法在非均匀光照条件下、对比度较低的情况下无法正确分割出基本单元, 出现了边缘模糊的现象. 而本文仅在图像非均匀光照亮度明显过度区域 (图 7 第 3 幅图像) 时, 出现轻微边缘分割模糊. 这是本文算法尚需改进之处.

5.3 超像素分割效果评价

本文采用文献 [12] 提出的边界召回率和欠分割错误率对超像素的分割效果进行量化评价分析.

1) 边界召回率

边界召回率是指超像素分割的边缘与真实边缘 (人工分割边缘) 的符合程度, 即

$$BR = \frac{\sum |s_a|}{\sum |g_b|} \quad (15)$$

其中, $\sum |s_a|$ 为超像素分割得到的边界与人工分割边界重合的像素点之和, $\sum |g_b|$ 为人工分割边界上像素点之和. 边界召回率越高, 表明与实际边缘的贴合度越高, 分割效果越好. 本文算法与其他算法的边界召回率的比较如图 8 所示. 可以看出, 本文算法由于边缘置信度的判断和新边缘点的形成, 在边界召回率上优于其他超像素分割算法. 在不同分割数目的情况下, 本文算法比 SLIC 算法高出 2%~4%, 而比 N-cuts 算法和 Turbopixels 算法高 10% 左右. 当分割数目超过 3 000 时, 本文算法的边界召回率接近 90%.

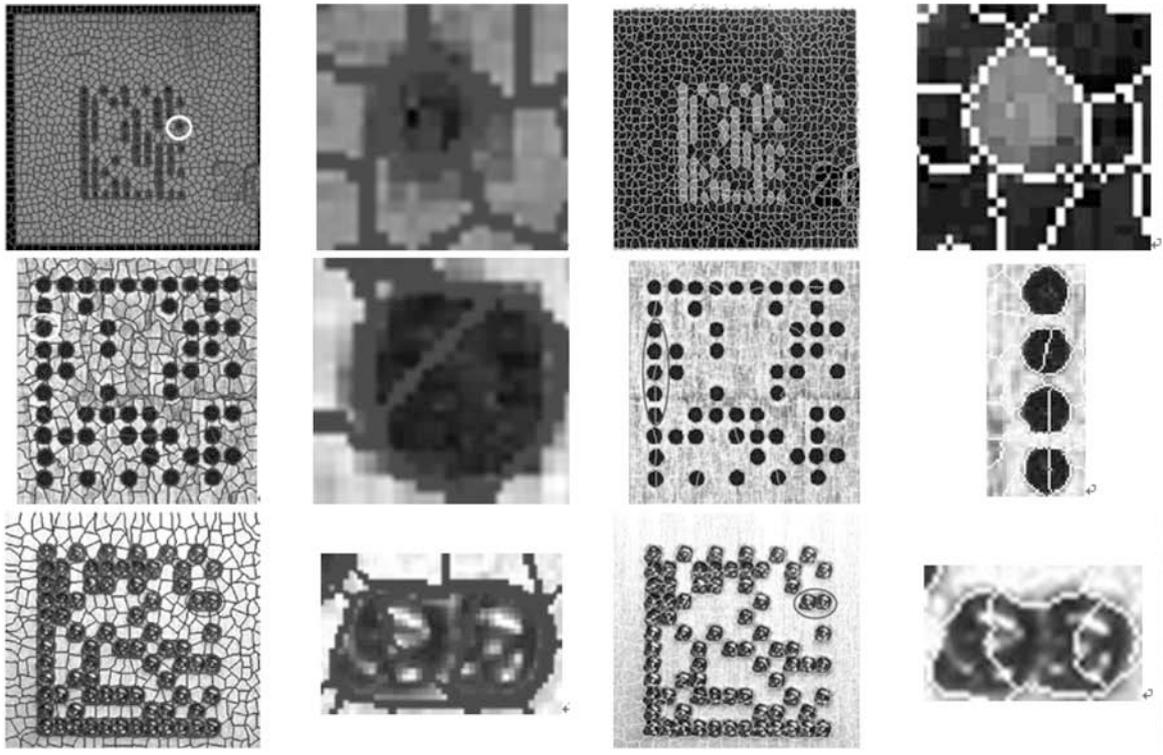
2) 欠分割错误率分析

欠分割错误率衡量的是超像素分割与人工分割之间的误差. 此误差是由超像素分割边缘超出人工分割边缘部分的平均累加值统计.

设人工分割的图像得到分割区域分别为 g_1, g_2, \dots, g_M , 而超像素分割输出的分割区域为 s_1, s_2, \dots, s_K , 则欠分割错误率 U 可量化表示为

$$U = \frac{1}{N} \left[\sum_{i=1}^M \left(\sum_{[s_j | s_j \cap g_i > B]} |s_j| \right) - N \right] \quad (16)$$

其中, N 是图像中像素点的个数. M 为人工分割的区域数, $s_j \cap g_i$ 表示超像素区域 s_j 与人工分割区域 g_i 重叠的像素数. B 是重叠像素的最小数目. 实验中,

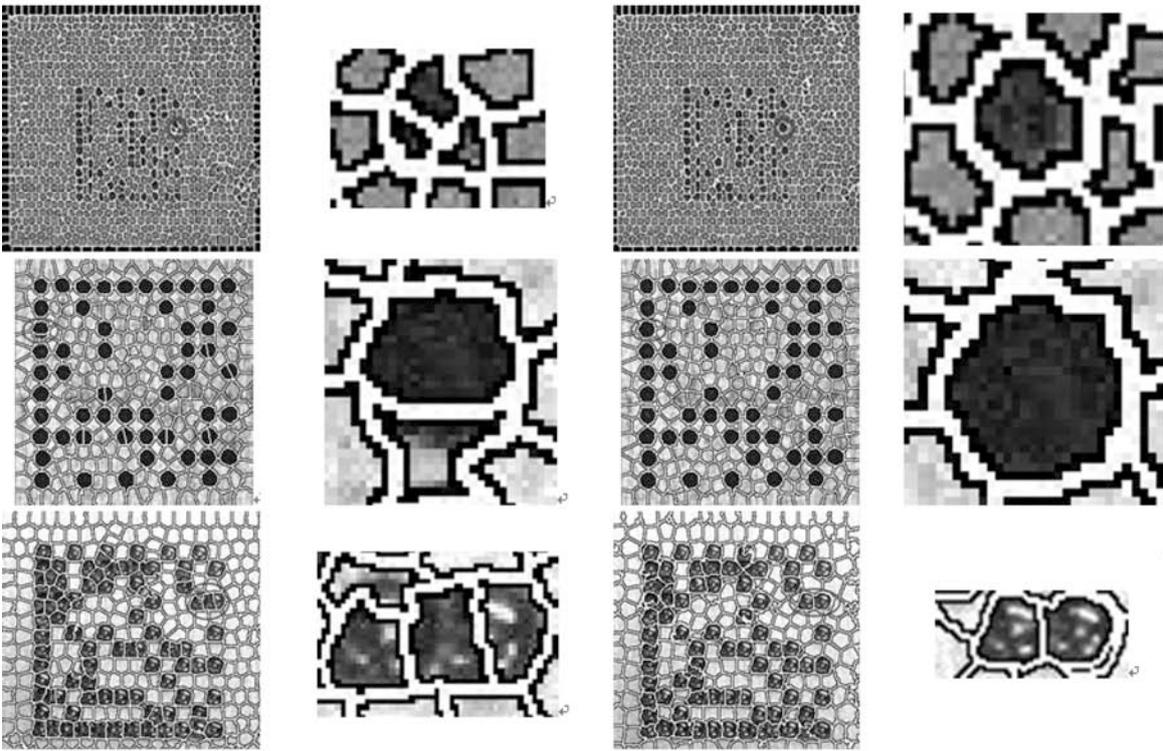


(a) N-cuts 算法
(a) N-cuts algorithm

(b) 局部放大图
(b) LEG

(c) Turbopixels 算法
(c) Turbopixels algorithm

(d) 局部放大图
(d) LEG



(e) SLIC 算法
(e) SLIC algorithm

(f) 局部放大图
(f) LEG

(g) AE-SLIC 算法
(g) AE-SLIC algorithm

(h) 局部放大图
(h) LEG

图 5 超像素边缘分割对比 (其他算法出现过分割)

Fig. 5 Comparison of superpixel edge segmentation (over-segmentation in other algorithms)

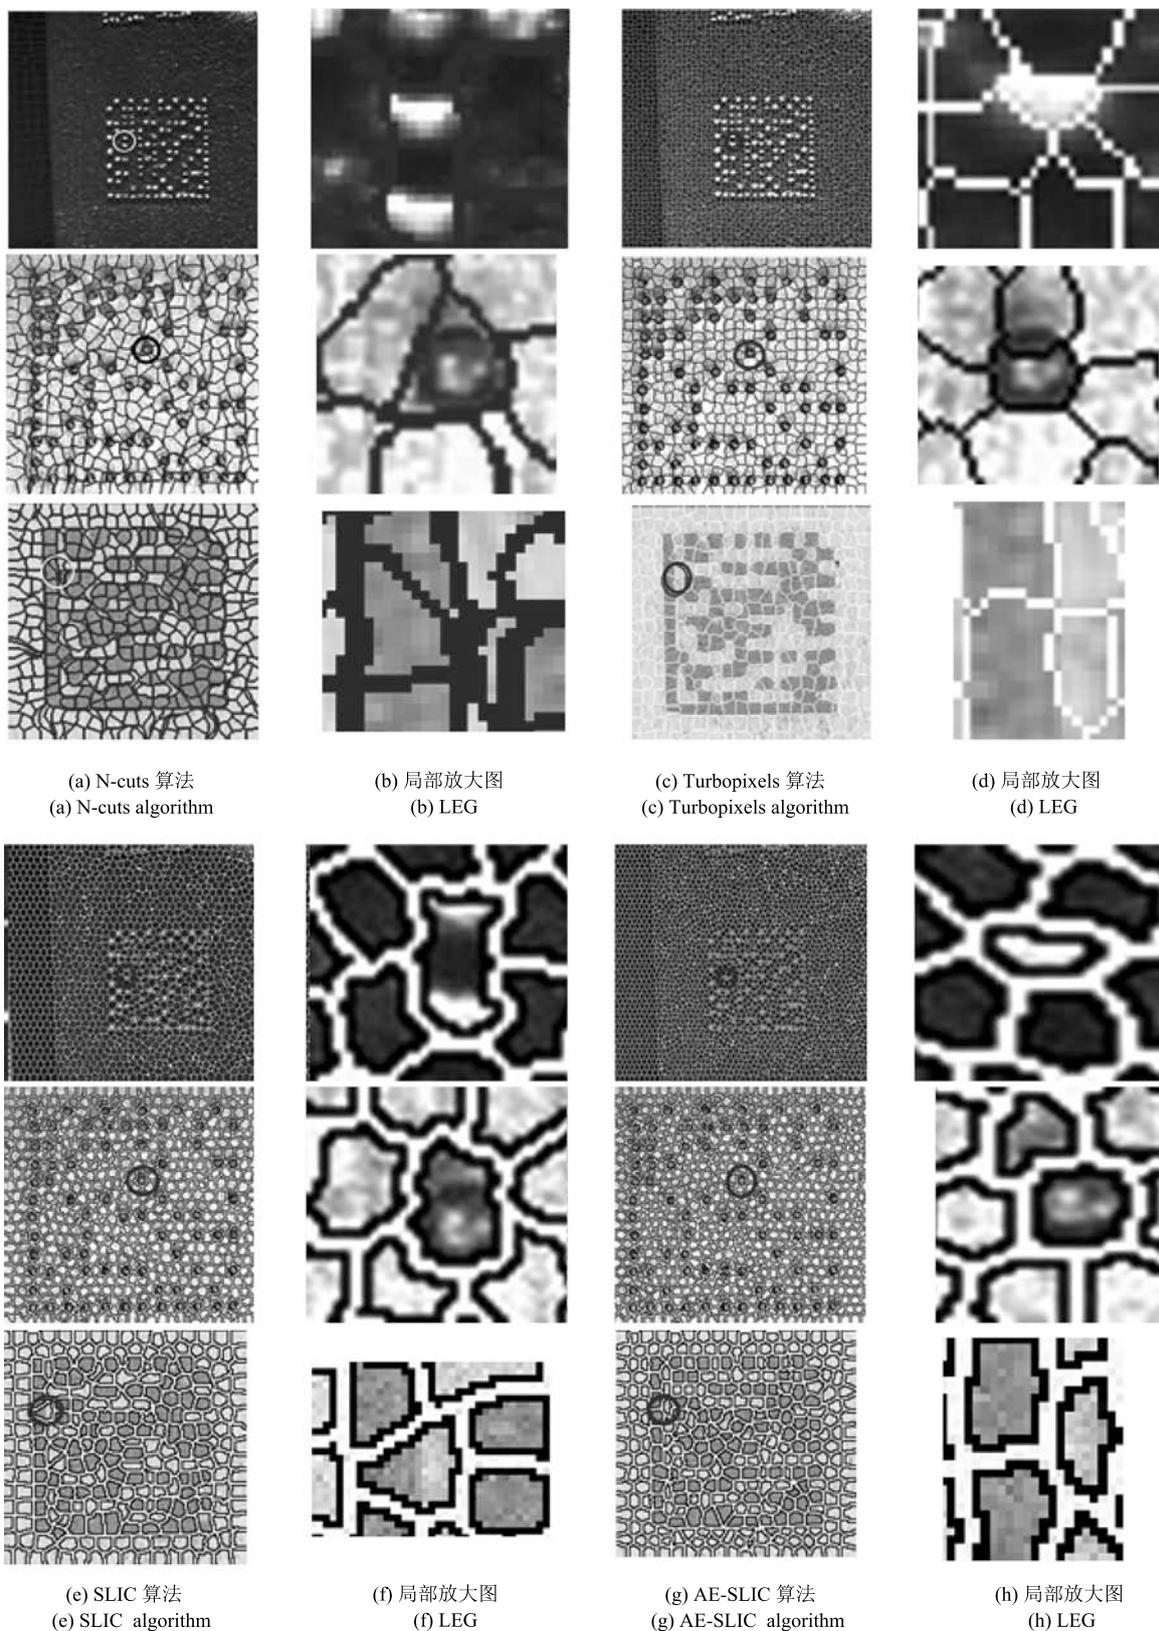


图 6 超像素边缘分割对比 (其他算法出现欠分割)

Fig. 6 Comparison of superpixel edge segmentation (under-segmentation in other algorithms)

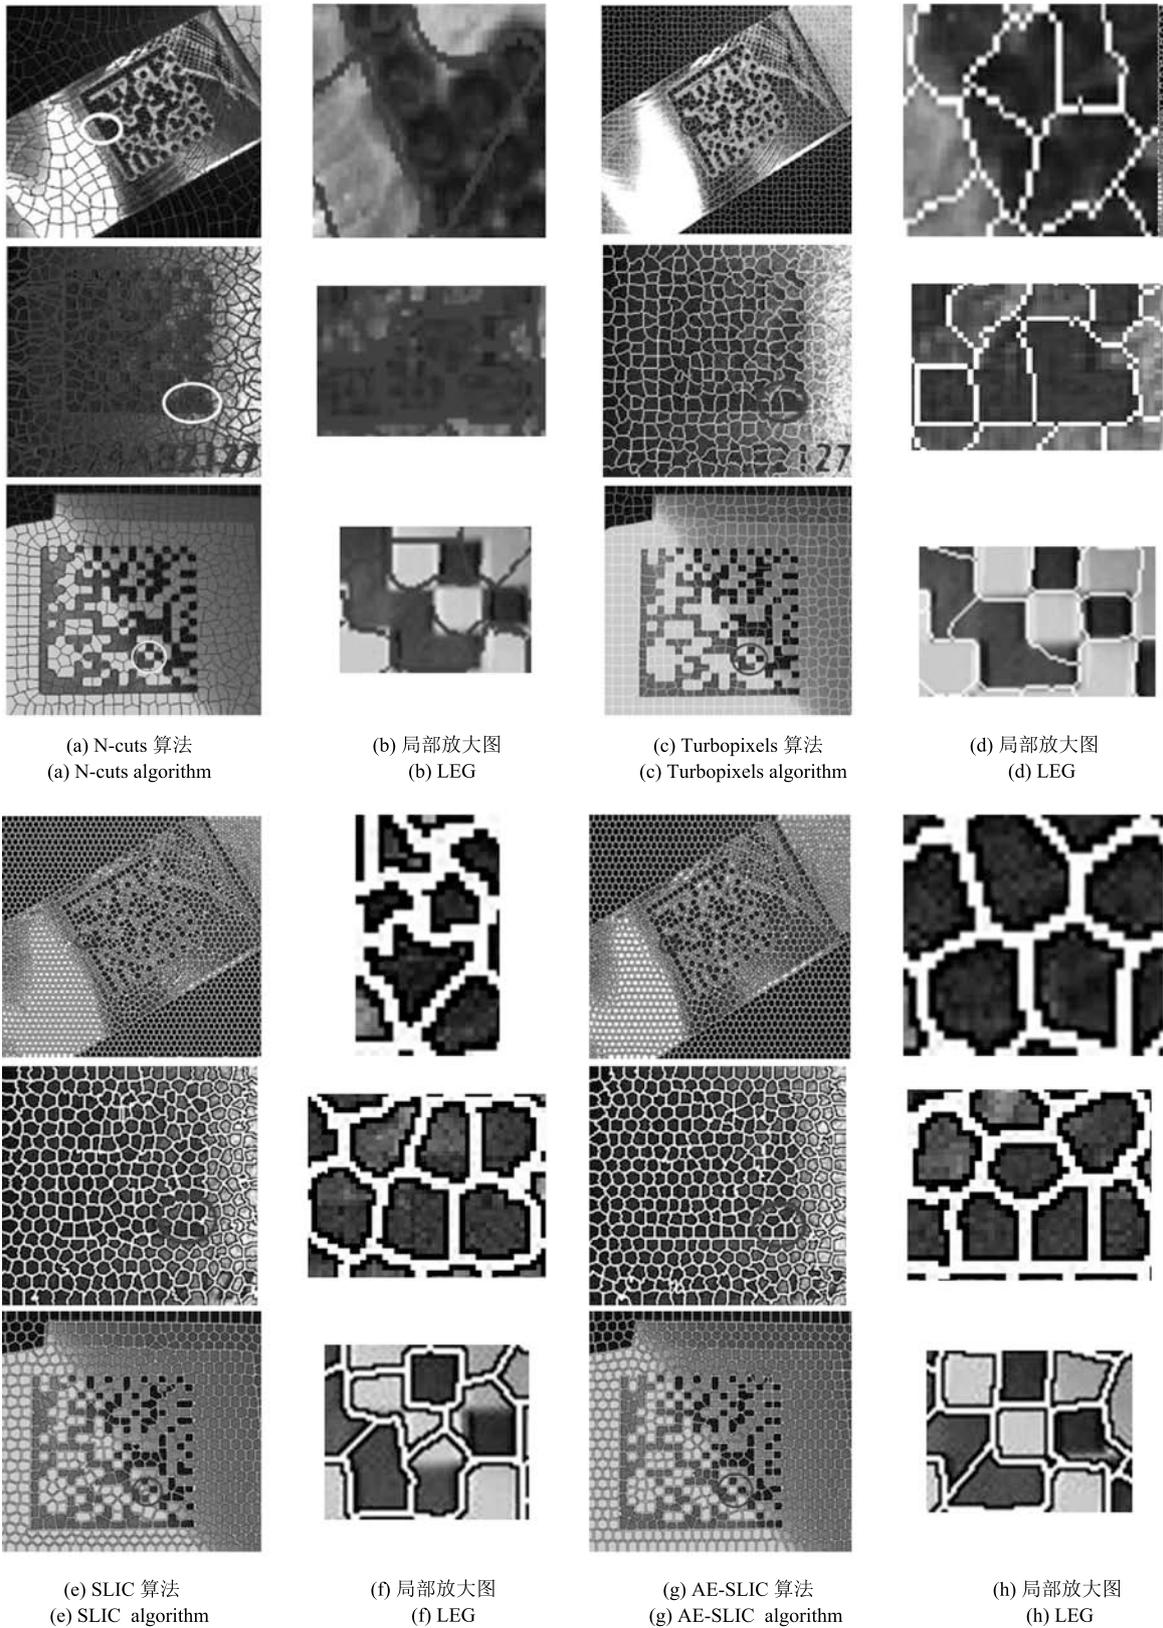


图 7 超像素边缘分割对比 (非均匀光照)

Fig. 7 Comparison of superpixel edge segmentation (uneven illumination)

设 B 为 5. $|s_j|$ 表示超像素分割区域中的像素点. 本文算法与其他算法的欠分割错误率的比较如图 9 所示.

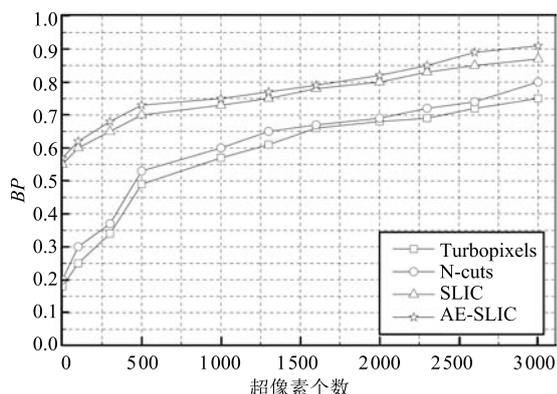


图 8 边界召回率对比曲线图

Fig. 8 Plot of the boundary recall

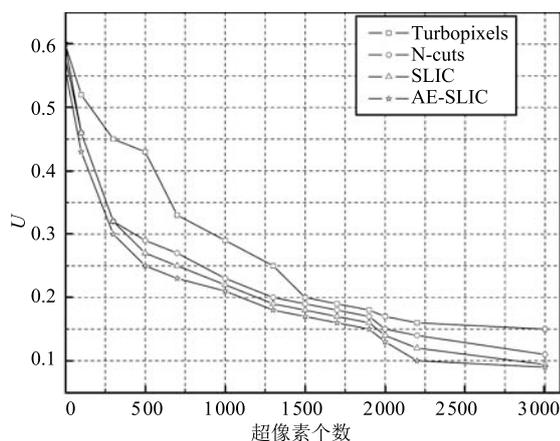


图 9 欠分割错误率对比曲线图

Fig. 9 Plot of the under-segmentation error

欠分割错误率越低, 表明超像素的分割越符合人工分割的结果, 分割效果越好. 与其他算法相比, 本文算法的欠分割错误率低 2%~8%.

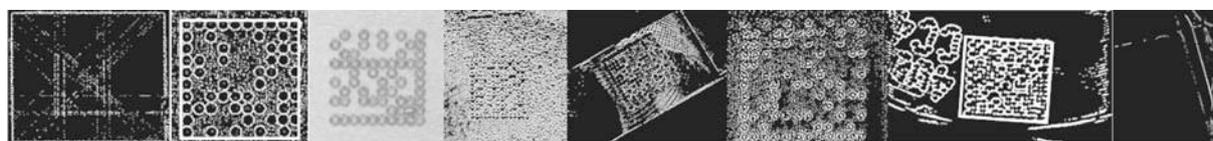
综上所述, 本文所提出的 AE-SLIC 自适应分割算法, 无需人工干预, 由图像内部数据的特征自适应调整分割数目. 在非人工干预的实时系统中, 有一定的优越性. 分割的准确性和计算效率均优于其他超像素分割算法, 与 DPM 码的边缘特征符合度较高.

5.4 与传统算法定位结果的对比及抗噪能力分析

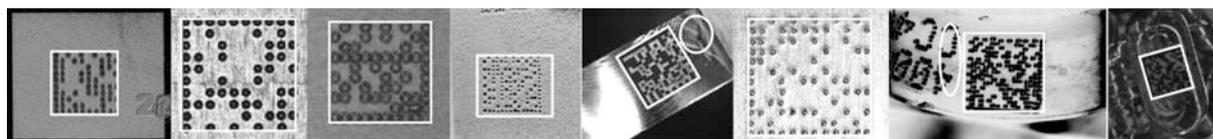
传统二维码定位算法是在像素点基础上使用边缘检测算法和霍夫 (Hough) 变换相结合的方法. 为了提高算法效率, 文献 [3] 和文献 [4] 在边缘检测的基础上使用快速 Hough 变换对 DPM 码进行定位. 因此本文对包含点刻式 (图 10) 和点阵式 (图 11) 在内的 100 幅 DPM 码图像, 分别使用文献 [3] 和文献 [4] 中的算法与本文算法在运算时间和定位准确性等方面进行对比, 检验本文算法的有效性.

在图 10 和图 11 所示的 16 幅图像中, 传统算法仅对其中的 5 幅图像定位成功. 其余几幅图像或没有定位成功, 或未检测出边缘 (图 10(a) 左 3、图 11(a) 右 1). 而本文算法则对其中的 14 幅图像中的 DPM 码区域定位成功. 特别是在存在明显噪声斑块干扰时 (圆框中为临近的类似基本单元噪声), 本文算法依然能够定位出 DPM 码区域. 为验证本文算法的实用性, 对 100 幅含有 DPM 码区域的待测图像样本进行运算效率测试对比, 结果如表 2 所示.

文献 [3] 和文献 [4] 中的算法是基于图像底层像素点进行的定位算法, 该算法对边界规整、背景简单、光照单一的 DPM 码区域定位准确率高. 算法中使用的快速 Hough 变换仍需要使用每个像素点



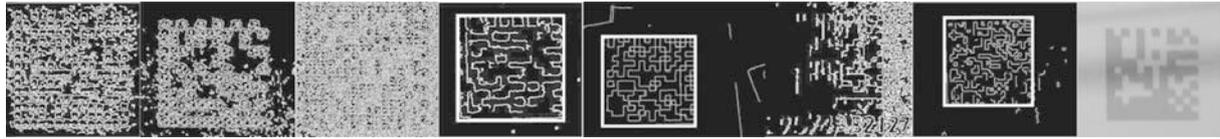
(a) 边缘检测 + 快速 Hough 变换算法的定位结果
(a) Results of edge detection plus fast Hough algorithm



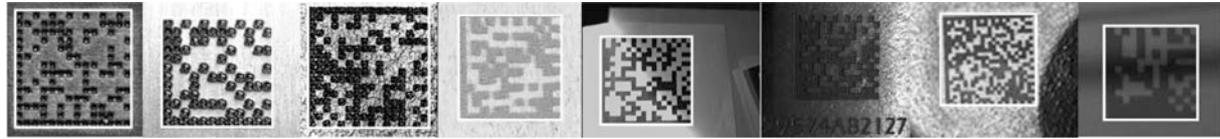
(b) 本文算法的分割定位结果
(b) Results of AE-SLIC plus spectral clustering

图 10 点刻式 DPM 码区域定位精度对比

Fig. 10 Comparison of positioning accuracy in stippled DPM



(a) 边缘检测 + 快速 Hough 变换算法的定位结果
(a) Results of edge detection plus fast Hough algorithm



(b) 本文算法的分割定位结果
(b) Results of AE-SLIC plus spectral clustering

图 11 点阵式 DPM 码定位精度对比

Fig. 11 Comparison of positioning accuracy in dot matrix DPM

表 2 定位算法性能对比

Table 2 Performance of different location algorithms

算法/样本	平均定位时间 (ms)	定位准确率 (%)
边缘检测 + 快速 Hough 变换 ^[3-4]	3 145.1	33
AE-SLIC + 谱聚类算法(本文)	1 682.2	90

计算参数, 因此运算复杂度较高, 使得算法整体耗时较长. 而本文算法则利用图像中层视觉特征——超像素为基础进行谱聚类定位, 与逐点运算的 Hough 变换相比, 计算的数据量锐减, 因而时间效率提高了 46.5%.

文献 [3] 和文献 [4] 中使用的基于形态学的边缘检测方法对噪声点比较敏感, 当面对背景复杂、倾斜或畸变严重、光照不均、噪声干扰影响大的 DPM 条码图像时, 边缘检测准确率较低. 特别是对于条件恶劣的图像样本(图 10(a) 左 3、图 11(a) 右 1), 还出现未检测到边缘的现象. 因此导致该算法在此类样本中定位准确率仅为 31.3%. 而本文算法通过超像素分割、噪声干扰的滤除, 可将定位准确率提高到 87.5%, 为后续 DPM 条码的识别奠定基础.

6 结论与展望

点刻式 DPM 码以圆形或椭圆形为基本单元组合而成, 分割定位难度高于以矩形为基本单元的点阵式 DPM 码. 本文根据 DPM 码基本单元的区域特征, 选用超像素及谱聚类方法定位图像中的 DPM 码区域. 针对 SLIC 算法存在的边缘划分不准确、超像素数目无法自适应等问题加以改进, 得到新的 AE-SLIC 算法. 而后使用谱聚类算法在超像素分割的基础上对 DPM 码区域实现精确定位. 实验结果

表明, AE-SLIC 算法分割结果与 DPM 码基本单元特征和边缘信息相吻合, 自适应分割算法的使用为实时定位 DPM 码区域提供了必要条件. 与谱聚类算法的配合使用, 在计算时间和定位精度上与传统算法相比均呈现出明显的优势. 另外, AE-SLIC 算法充分考虑了图像的颜色信息, 因此也可应用于彩色三维 DPM 码区域定位. 针对非均匀光照图像中渐变区域的分割和谱聚类中特征向量聚类方法的选择等问题, 本文算法尚有改进空间, 这正是本文的后续工作.

References

- 1 Information Technology — Automatic Identification and Data Capture Techniques—Guidelines for Direct Part Marking (DPM), ISO/IEC TR 24720-2008 (E), 2008.
- 2 Ha J E. A new method for detecting data matrix under similarity transform for machine vision applications. *International Journal of Control Automation and Systems*, 2011, **9**(4): 737–741
- 3 Wang W, He W P, Lei L, Guo G F. Polluted and perspective deformation DataMatrix code accurate locating based on multi-features fusion. *Chinese Journal of Electronics*, 2014, **23**(3): 550–556
- 4 Wang Wei, He Wei-Ping, Lei Lei, Guo Gai-Fang, Niu Jin-Bo. Accurate location of polluted DataMatrix code from multiple views. *Journal of Computer-Aided Design and Computer Graphics*, 2013, **25**(9): 1345–1353
(王伟, 何卫平, 雷蕾, 郭改放, 牛晋波. 污染及多视角下 DataMatrix 码精确定位. *计算机辅助设计与图形学学报*, 2013, **25**(9): 1345–1353)
- 5 Chu C H, Yang D N, Pan Y L, Chen M S. Stabilization and extraction of 2D barcode for camera phones. *Multimedia Systems*, 2011, **17**(2): 113–133
- 6 Yang H J, Jiang X D, Kot A C. Accurate localization of four extreme corners for barcode images captured by mobile phones. In: *Proceedings of the 17th IEEE International*

- Conference on Image Processing. Hong Kong, China: IEEE, 2010. 3897–3900
- 7 Han Shou-Dong, Zhao Yong, Tao Wen-Bing, Sang Nong. Gaussian super-pixel based fast image segmentation using graph cuts. *Acta Automatica Sinica*, 2011, **37**(1): 11–20 (韩守东, 赵勇, 陶文兵, 桑农. 基于高斯超像素的快速 Graph Cuts 图像分割方法. *自动化学报*, 2011, **37**(1): 11–20)
 - 8 Felzenswalb P F, Huttenlocher D P. Efficient graph-based image segmentation. *International Journal of Computer Vision*, 2004, **59**(2): 167–181
 - 9 Shi J, Malik J. Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, **22**(8): 888–905
 - 10 Moore A, Prince S, Warrell J, Mohammed U, Jones G. Superpixel lattices. In: Proceedings of the 2008 IEEE Conference on Computer Vision and Pattern Recognition. Anchorage, AK: IEEE, 2008. 1–8
 - 11 Liu M Y, Tuzel O, Ramalingam S, Chellappa R. Entropy rate superpixel segmentation. In: Proceedings of the 2011 IEEE Conference on Computer Vision and Pattern Recognition. Providence, RI: IEEE, 2011. 2097–2104
 - 12 Levinshstein A, Stere A, Kutulakos K N, Fleet D J, Dickinson S J, Siddiqi K. Turbopixels: fast superpixels using geometric flows. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, **31**(12): 2290–2297
 - 13 Vedaldi A, Soatto S. Quick shift and kernel methods for mode seeking. In: Proceedings of the 2008 Computer Vision — ECCV 2008. Berlin, Heidelberg: Springer, 2008. 705–718
 - 14 Zhu Jian-Yong, Gui Wei-Hua, Yang Chun-Hua, Wu Jia, Zhou Wen-Zhen. Reagent dosage control based on bubble size random distribution for copper roughing. *Acta Automatica Sinica*, 2014, **40**(10): 2089–2097 (朱建勇, 桂卫华, 阳春华, 吴佳, 周文振. 基于泡沫尺寸随机分布的铜粗选药剂剂量控制. *自动化学报*, 2014, **40**(10): 2089–2097)
 - 15 Achanta R, Shaji A, Smith K, Lucchi A, Fua P, Süsstrunk S. SLIC Superpixels. EPFL Technical Report 149300, Swiss Federal Institute of Technology in Lausanne, Swiss, 2010.
 - 16 Achanta R, Shaji A, Smith K, Lucchi A, Fua P, Süsstrunk S. SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, **34**(11): 2274–2282
 - 17 Ren C Y, Reid I. gSLIC: A Real-time Implementation of SLIC Superpixel Segmentation. Technical Report, Department of Engineering, University of Oxford, UK, 2011.
 - 18 Lucchi A, Li Y P, Smith K, Fua P. Structured image segmentation using kernelized features. In: Proceedings of the 12th European Conference on Computer Vision — ECCV 2012. Berlin, Heidelberg: Springer, 2012. 400–413
 - 19 Lin C H, Chen C C, Lee H L, Liao J R. Fast K-means algorithm based on a level histogram for image retrieval. *Expert Systems with Application*, 2014, **41**(7): 3276–3283
 - 20 Frey B J, Dueck D. Clustering by passing messages between data points. *Science*, 2007, **315**(5814): 972–976
 - 21 Zhang Jian-Peng, Chen Fu-Cai, Li Shao-Mei, Liu Li-Xiong. Data stream clustering algorithm based on density and affinity propagation techniques. *Acta Automatica Sinica*, 2014, **40**(2): 277–288 (张建朋, 陈福才, 李邵梅, 刘力雄. 基于密度与近邻传播的数据流聚类算法. *自动化学报*, 2014, **40**(2): 277–288)
 - 22 Wang Pei-Zhen, Mao Xue-Qin, Mao Xue-Fei, Gao Shang-Yi, Zhang Dai-Lin. Coke micrograph segmentation based on mean shift and edge confidence. *Journal of Image and Graphics*, 2010, **15**(10): 1478–1484 (王培珍, 毛雪芹, 毛雪菲, 高尚义, 张代林. 基于均值偏移和边缘置信度的焦炭显微图像分割. *中国图象图形学报*, 2010, **15**(10): 1478–1484)
 - 23 Dalal N, Triggs B. Histograms of oriented gradients for human detection. In: Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Diego, CA, USA: IEEE, 2005. 886–893
 - 24 Applying Data Matrix Identification Symbols on Aerospace Parts, NASA-STD-6002 A, 2008.
 - 25 Zhou Lin, Ping Xi-Jian, Xu Sen, Zhang Tao. Cluster ensemble based on spectral clustering. *Acta Automatica Sinica*, 2012, **38**(8): 1335–1342 (周林, 平西建, 徐森, 张涛. 基于谱聚类的聚类集成算法. *自动化学报*, 2012, **38**(8): 1335–1342)
 - 26 Shen J J, Hsu P W. A fragile associative watermarking on 2D barcode for data authentication. *International Journal of Network Security*, 2008, **7**(3): 301–309



王娟 2015 年获得天津大学博士学位。主要研究方向为模式识别与智能系统。E-mail: wangjuan85@tju.edu.cn (WANG Juan Received her Ph.D. degree from Tianjin University in 2015. Her research interest covers pattern recognition and intelligent system.)



王萍 天津大学电气与自动化工程学院教授。主要研究方向为模式识别方法及应用, 图像理解, 运动对象跟踪。本文通信作者。E-mail: wangps@tju.edu.cn (WANG Ping Professor at the College of Electrical and Automation Engineering, Tianjin University. Her research interest covers method and application of pattern recognition, image understanding, and object tracking. Corresponding author of this paper.)



王港 天津大学电气与自动化工程学院硕士研究生。2013 年获得河北工业大学智能科学与技术学士学位。主要研究方向为模式识别, 图像处理 and 三维重建。E-mail: wanggg@tju.edu.cn (WANG Gang Master student at the College of Electrical and Automation Engineering, Tianjin University. He received his bachelor degree in intelligence science and technology from Hebei University of Technology in 2013. His research interest covers pattern recognition, image processing, and three-dimensional scene reconstruction.)