

基于均值漂移的自适应纹理图像分割方法^{*}

王爽^{1,2+}, 夏玉^{1,2}, 焦李成^{1,2}

¹(西安电子科技大学 智能感知与图像理解教育部重点实验室, 陕西 西安 710071)

²(西安电子科技大学 智能信息处理研究所, 陕西 西安 710071)

Mean Shift Based Adaptive Texture Image Segmentation Method

WANG Shuang^{1,2+}, XIA Yu^{1,2}, JIAO Li-Cheng^{1,2}

¹(Key Laboratory of Intelligent Perception and Image Understanding of Ministry of Education, Xidian University, Xi'an 710071, China)

²(Institute of Intelligent Information Processing, Xidian University, Xi'an 710071, China)

+ Corresponding author: E-mail: shwang@mail.xidian.edu.cn

Wang S, Xia Y, Jiao LC. Mean shift based adaptive texture image segmentation method. *Journal of Software*, 2010,21(6):1451-1461. <http://www.jos.org.cn/1000-9825/3723.htm>

Abstract: This paper presents an unsupervised texture segmentation method based on wavelet analysis and mean shift. The adaptive multiscale segmentation is realized by applying mean shift cluster algorithm to features which generated by wavelet pyramid. The unsupervised texture segmentation method does not require either training or prior knowledge of the number of textures. With a proper strategy, those features are propagated through finer scales adaptively. The center of a homogenous texture is analyzed by using features in coarse resolution, and its border is detected in finer resolution so as to locate the boundary accurately. This method has an analogy with human psychophysical measurements of image appearance. Experiments on synthetic and real images demonstrate that the proposed method leads to a successful unsupervised segmentation.

Key words: texture image; unsupervised segmentation; mean shift; wavelet

摘要: 提出了一种基于小波多尺度分析和均值漂移的无监督纹理分割方法。该方法利用均值漂移聚类实现基于小波特征的完全无监督自适应多尺度分割,既不需要进行训练也不需要分割类别数等先验知识。该方法根据一定的策略在尺度间进行信息传递,自适应地为图像不同区域确定合适的分割尺度,即纹理内部区域使用粗尺度特征而不同纹理间的交界处使用较细尺度特征,这样就在保证区域一致性的同时更准确地定位图像边缘。对比实验结果表明,该方法在合成纹理和真实纹理图像中都有较好的性能,其多尺度的分割过程类似于人类视觉系统感知,并且较之有监督的传统分割方法也更具优势。

* Supported by the National Natural Science Foundation of China under Grant Nos.60702062, 60971128, 60703109, 60970066, 60972148 (国家自然科学基金); the National High-Tech Research and Development Plan of China under Grant Nos.2008AA01Z125, 2009AA12Z210 (国家高技术研究发展计划(863)); the National Basic Research Program of China under Grant No.2006CB705700 (国家重点基础研究发展计划(973)); the Shaanxi Provincial Natural Science Foundation of China under Grant No.2007F09 (陕西省自然科学基金); the China Postdoctoral Science Foundation under Grant Nos.200902587, 20090461285 (中国博士后科学基金); the Program of Introducing Talents of Discipline to Universities of China under Grant No.B07048 (高等学校学科创新引智计划)

Received 2008-07-28; Revised 2009-04-27; Accepted 2009-08-19

关键词: 纹理图像;无监督分割;均值漂移;小波

中图法分类号: TP391 文献标识码: A

纹理图像分割是图像处理中的一个基本问题,其主要任务是将图像划分成一组具有相对一致纹理特征的区域.它需要解决的两个核心问题是:纹理区域的一致性和相邻区域边界的准确性.目前,进行纹理分割的主要方法有统计法、结构法、模型法和空间/频域联合分析法等4类^[1,2].统计学方法考虑的是纹理中灰度的空间分布,该方法倾向于使用较大的特征提取窗口以提高分割结果的区域一致性,但却无法保证对图像边缘的准确定位.结构法假设纹理由精确定义的纹理基元组成,但现实中很多纹理都并不满足这个条件,因此该方法较少使用.模型法假设纹理是以某种参数控制的分布模型方式形成的,从纹理图像的实现来估计模型参数,以参数为特征或采用某种分类策略进行图像分割,该方法需要训练得到模型参数,并且自然纹理很难用单一的模型表达,因此在某些应用中具有局限性.空间/频域方法主要包括基于 Gabor 变换^[3]和小波变换^[4-6]等多尺度分析的方法,它们与人类视觉过程相似,因此近年来常与模型法结合进行纹理分析并能得到较好效果,如小波域隐马尔可夫树模型等^[7,8].以上这些方法多数是有监督的,即必须在已知部分标识样本等先验知识的条件下进行分割.例如,小波域隐马尔可夫树模型是基于窗口特征的似然比检验的,其缺点和统计法相似,即窗口过大会淹没小区域,不利于准确定位分割边缘;窗口过小又会影响到区域一致性.此外,该方法不仅需要事先给定分类个数,还必须对每类纹理进行训练以得到模型参数,这些都限制了其在自动图像分割等方面的应用.

针对这些问题,本文提出了一种基于小波多尺度分析的无监督纹理分割方法.该方法可以自适应地为图像的不同区域选用合适的分割尺度.在粗尺度上主要进行不同区域间的分离,而在细尺度上处理分割边界定位等细节问题,并且根据一定的策略把粗尺度结果逐层传递至较细尺度.图1是用该算法进行多尺度纹理分割的原理图.由于小波变换的粗尺度系数矩阵大小是更细尺度系数的1/4,因此粗尺度上的1个系数就对应细尺度的4个.图1(b)中的较大窗口,表示使用较粗尺度的特征.自适应分割就是在同一类纹理区域内部使用小波系数的粗尺度特征进行分割,而边缘区域使用较细尺度特征来更准确地定位纹理边界.这种尺度由粗到细、分割精度逐层提高的过程类似于人类视觉系统对图像的感知过程,不仅能够不同尺度上对图像进行表征和分析,而且能够最大程度地保证区域一致性和边缘准确性的统一.

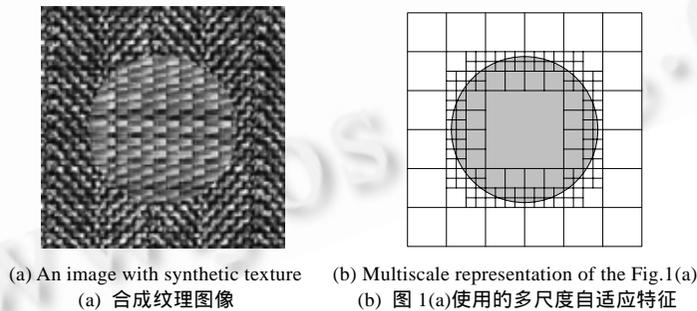


Fig.1 Multiscale representation of a two-texture image

图1 两类纹理的多尺度分割原理图

另一方面,为了使该算法能够自动确定分割类别数,本文采用均值漂移(mean shift)算法对特征进行聚类.均值漂移^[9]是一种基于数据密度的无监督、非参数的聚类算法,它能够发现任意形状的数据类,较之只能处理凸数据集的 k -均值等传统聚类算法更具优势.但是,多维均值漂移算法复杂度较高.针对这个问题,本文根据正交小波系数间的不相关性,提出了针对正交小波特征的多维快速均值漂移算法.

1 小波特征提取

小波变换^[7]为纹理分析提供了一种多尺度的集频谱、结构和统计方法于一体的综合分析方法,具有良好的

空间-频率分解特性,而且更符合人类视觉系统的多分辨多通道特性.其标准的分解过程是采用金字塔算法,即递归分解信号的低频部分以生成下一尺度的各个频带,通常也称为塔形小波变换.函数 $f(x)$ 的连续小波变换为

$$W_f(a,b) = |a|^{-\frac{1}{2}} \int_{-\infty}^{+\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt \tag{1}$$

其中,函数 $\psi(x) \in L^2(R)$ 是母小波, a 为伸缩因子, b 为平移因子.对连续小波变换的尺度因子进行二进离散化,同时也对平移因子离散化,即 $a=2^j, b=2^j k, k \in Z$,这样就可以得到对尺度-时间都离散化的小波变换.

在纹理分割中,小波基的选取要从小波变换是特征提取工具的角度出发,并在一定程度上考虑其正交性,以使所提取的纹理特征之间尽可能不相关,从而提高特征的有效性和分割性能.综合考虑小波基的正交性、紧支性和消失矩的阶数,本文选用 Daubechies 4 小波基.

特征提取是为了获得纹理测度,用于区分不同纹理.对小波分解的低频系数,本文使用大小为 $(2n_1+1) \times (2n_1+1)$ 窗口内系数的均值作为特征;对高频系数,使用 Laws 定义的一种窗口上的标准差作为分割特征,本文使用的窗口大小为 $(2n_1+1) \times (2n_1+1)$.

$$s(i,j) = \frac{1}{(2n_1+1)^2} \sum_{k=i-n_1}^{i+n_1} \sum_{l=j-n_1}^{j+n_1} |g(k,l) - m(i,j)| \tag{2}$$

其中, $g(k,l)$ 是原始小波系数, $m(i,j)$ 为窗口内原始小波系数的平均值.

由于纹理区域边缘附近的像素邻域内有可能包含属于不同纹理的像素,这会导致得到的纹理测度出现偏离期望的情况.因此,有必要对公式(2)得到的特征作进一步的平滑,即

$$S(i,j) = \frac{1}{(2n_2+1)^2} \sum_{k=i-n_2}^{i+n_2} \sum_{l=j-n_2}^{j+n_2} s(k,l) \tag{3}$$

该平滑窗口大小为 $(2n_2+1) \times (2n_2+1)$.

2 尺度间自适应特征传递

小波分解得到的系数是一个从粗尺度到细尺度渐变的过程,在纹理分割过程中使用较粗尺度特征,就相当于使用了较大的特征分析窗口,这虽然可以有效地捕获图像不同纹理区域的主体轮廓,但却丢弃了不同纹理区域之间的局部边界细节;而较细尺度特征则在很大程度上弥补了这一损失.本文根据这个特点,在小波分解的每一层中结合纹理特征和空间信息进行图像的无监督分割,如图 1 所示.

令特征分析窗口为 $\Delta\omega$,当 $\Delta\omega$ 较大时,接近纹理边缘处的窗口会因为包含多种纹理导致误分割;而 $\Delta\omega$ 较小时,虽然能够提高边缘的分割准确度,但图像的区域一致性会变差.因此,要将两者有效地结合,必须实现为图像的不同区域选用合适的分割尺度,即进行自适应的特征分析.自适应特征分析的核心思想是:如果 $\Delta\omega$ 中不包含图像边缘,就使用较大的特征分析窗口进行分割;如果含有图像边缘,则缩小该窗口,直至其中不再包含任何边缘为止^[10].该思想可以通过搜索当前窗口的初分割邻域性质实现,即如果当前窗口和其邻域窗口在粗尺度特征空间中的分割结果都被分为同一类,那么就认为该窗口内不包含边缘并进行标记,否则不标记.这里,未被标记的区域就认为其中包含图像边缘,即为不同纹理间的交界区,对此再使用更细尺度的特征对其进行分割.也就是说,特征分析窗 $\Delta\omega$ 的大小是由其上一级分割的区域一致性及其邻域特性决定的.

图 2 所示为图像当前窗口 s 的 4 邻域和 8 邻域,本文使用 8 邻域进行搜索.



Fig.2 Feature window's 4 neighborhoods and 8 neighborhoods, s is the feature window

图 2 特征窗口的 4 邻域和 8 邻域, s 是当前窗口

令 S 表示一组特征, s 表示当前窗口中心点的特征, $\{b_s\}$ 是分割结果. 其中, $s \in S, b_s \in N, N$ 是无监督确定的分割类数, $a_s \in A, A = \{1, 0\}$ 是窗口区域的标记, 设 $a_s = 1$ 表示特征窗口内不包含边缘, 否则 $a_s = 0$, 用公式表达为

$$a_s = \begin{cases} 1, & \text{if } b_s = b_{s+q}, q \in Q \\ 0, & \text{otherwise} \end{cases} \quad (4)$$

其中: Q 表示窗口的 8 邻域, 即 $Q = \{(1,0), (1,1), (0,1), (-1,1), (-1,0), (-1,-1), (0,-1), (1,-1)\}$; b_s 是均值漂移得到的分割类别, 这部分内容将在第 4 节详细讲述. 根据这一标记来判断当前窗口是否要进行下一级特征分析.

定义 $B = \{B_s(b_s, a_s) | s \in S, b_s \in N, a_s \in A\}$, 其中, B_s 是定义在 S 上的随机变量. 当公式(5)成立时, 小波系数特征满足马尔可夫性质, 即当前窗口的性质只取决于其邻域窗口性质, 而与其他窗口无关.

$$P(B_s | B_{S-s}) = P(B_s | B_{s+q}, q \in Q) \quad (5)$$

这时,

$$P(a_s = 1 | b_s, b_{s+q}, q \in Q) = \prod_{q \in Q} \delta(b_s, b_{s+q}) \quad (6)$$

公式(6)说明, 如果 $\{s | a_s = 0\}$, 即 s 与其 8 邻域类别不同, 就进行下一级的特征分析.

由于本文所采用正交小波分解得到的每一尺度系数矩阵大小都是之前较细尺度系数的 1/4, 即每个小波系数都对下一级的 4 个系数. 在较粗尺度中, 如果特征窗口 $\Delta\omega$ 为 1 且 $a_s = 0$, 则对该区域(例如纹理边界区域)使用更细尺度的特征进行进一步处理, 也就相当于在下一尺度中把 $\Delta\omega$ 一分为 4. 具体分割过程如图 3 所示, 首先在小波分解的最粗尺度特征中应用均值漂移进行初分割并标记, 然后把初分割结果扩展为原来的 4 倍, 未标记区域即 $a_s = 0$ 的区域, 使用其对应的较细尺度特征, 而标记区作为一个整体使用相同分割区域内的特征均值作进一步分割, 直至得出最细尺度下的分割结果.

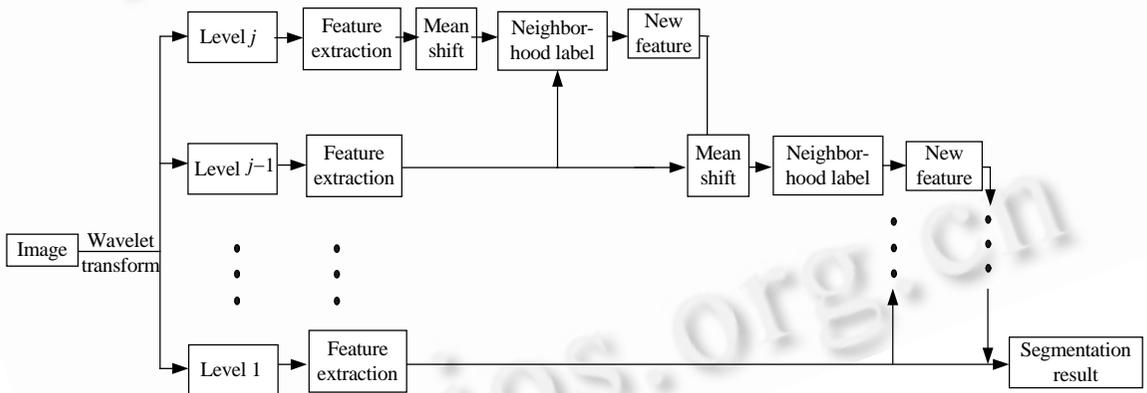


Fig.3 Proposed algorithm in this paper

图 3 本文算法框架

本文方法具体步骤如下:

- Step 1. 特征提取: 图像进行正交小波变换, 按照第 2 节中所述特征提取方法, 分别对各尺度的高频和低频系数进行特征提取, 其中, 低频系数使用滑动窗口内均值作为特征, 高频系数提取滑动窗口内的能量特征;
- Step 2. 初分割: 对 4 组最粗尺度特征 S 使用均值漂移算法进行无监督分割得到初分割结果 $\{b_s\}$;
- Step 3. 尺度间特征传递: 对初分割结果进行标记, 并通过标记指导尺度间的特征传递, 实现下一层的均值漂移分割;
 - Step 3.1. 搜索初分割结果中每个点的 8 邻域 Q , 如果该点和其 8 邻域都属于同一类, 那么就认为该点对应的图像区域不包含边缘并进行标记, 令 $a_s = 1$; 否则不标记, 仍令 $a_s = 0$;
 - Step 3.2. 将标记过的初分割结果扩展为原来的 4 倍, 使之与下一层较细尺度特征对应;

- Step 3.3. 对应标记区 $a_s=1$,使用初分割结果 $\{b_s\}$ 中标识相同的点在较细尺度上的特征均值作为新的特征,而未标记区 $a_s=0$ 直接使用细尺度特征,对该特征进行进一步的分割;
- Step 4. 由粗尺度到细尺度逐步进行分割,最后得到最细尺度上的分割结果.

3 均值漂移聚类

均值漂移是 Fukunaga 和 Hostetler 在 1975 年提出的一种目标跟踪和分类方法.直到 1995 年,Cheng^[11]论文的发表才引起人们的研究兴趣,掀起了研究和应用均值漂移算法的热潮.作为一种有效的统计迭代算法,均值漂移算法的收敛性研究是应用的基础,Comaniciu^[12]、李乡儒^[13]和文志强^[14]等人分别对均值漂移算法的收敛性进行了证明.近年来,均值漂移算法已被成功应用于目标跟踪、图像分割、滤波、边缘提取和信息融合等图像处理的多个领域.该算法是一种非参数的核密度估计理论,是在概率空间中求解概率密度极值的优化算法.它让每个点漂移到密度函数的局部极大值处,即均值漂移向量的方向是与数据的密度梯度估计方向一致.这种方法可以实现无监督、非参数的聚类^[9].

3.1 基本原理

使用核密度估计(即模式分类中的 Parzen 窗法)进行数据的概率密度估计时,假设特征维数为 d ,概率密度 $f(x)$ 的一组取样点为 $X=\{X_1, \dots, X_N\} \subset \mathcal{R}^d$,那么使用核函数 $K(x)$ 和大小为 h 的窗口在 x 点得到的概率密度估计为

$$\hat{f}(x) = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x-x_i}{h}\right) \quad (7)$$

为找到概率密度最大点,对上式求导并另其导数为 0,即

$$\hat{\nabla} f_{h,k}(x) = \frac{2C_{k,d}}{nh^{d+2}} \left[\sum_{i=1}^n g\left(\left\|\frac{x-x_i}{h}\right\|^2\right) \right] \left[\frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)} - x \right] = 0 \quad (8)$$

其中, $g(x)=-k'(x)$.由公式(7)可以看出,公式中第 1 部分 $\sum_{i=1}^n g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)$ 与在 x 处用核函数 G 进行概率密度估计的

结果成正比,第 2 部分 $\left[\frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)} - x \right]$ 就是均值漂移向量,即

$$m_{h,G}(x) = \frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)} - x \quad (9)$$

公式(9)说明,均值漂移向量指向概率密度的最大增量方向.因此,在实际应用中我们使用如下迭代公式:

$$y_{j+1} = \frac{\sum_{i=1}^n x_i g\left(\left\|\frac{y_j-x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{y_j-x_i}{h}\right\|^2\right)}, j=1,2,\dots \quad (10)$$

其中, y_{j+1} 是第 j 次迭代得到的特征, x 是当前数据点.文献[12]证明,当满足特定条件时,序列 y_j 能够收敛到 y' ,则 y' 点被称为数据 x 对应的模式.

在图像处理问题中,除了我们提取的特征之外,每个像素点的空间信息也是很重要的.因此,有必要把图像

的空间信息加入特征向量组中,这时,核函数如下:

$$K_{h_s^2, h_r^2}(x) = \frac{C}{h_s^2 h_r^2} k\left(\left\|\frac{x^s}{h_s}\right\|^2\right) k\left(\left\|\frac{x^r}{h_r}\right\|^2\right) \quad (11)$$

其中, x^r 是空间位置特征, x^s 是我们提取的特征, h_s 和 h_r 是所使用的带宽, C 是归一化常数. 使用均值漂移对这样一组特征(即本文方法中某一尺度上的特征)进行分割的过程为:

令 x_i 和 $z_i, i=1, \dots, n$ 分别表示输入特征和滤波后图像的像素, 对每个像素:

Step 1. 初始化, $j=1$ 且 $y_{i,1}=x_i$;

Step 2. 用公式(10)计算 $y_{i,j+1}$ 直至收敛, $y=y_{i,c}$;

Step 3. 令 $z_i = (x_i^s, y_{i,c}^r)$, 其中, 上标 s 和 r 表示向量的特征域和空间域信息;

Step 4. 对每一个 z_i , 把在频域和空间域中与 z_i 距离分别小于 h_s 和 h_r 的点分为同一类;

Step 5. 可以设定一个 M 值, 去除像素点个数少于 M 的类别.

3.2 基于多维小波特征的均值漂移及复杂性分析

均值漂移算法在图像处理和计算机视觉等领域的应用十分广泛. Comanicu 等人^[12]提出利用图像灰度和位置信息进行均值漂移可以得到较好的自然图像分割结果, 但是该方法很难直接用于纹理图像分割. 这是因为纹理图像灰度变化较快且不断重复相似的纹理单元, 如果仅仅使用图像灰度值作为特征, 均值漂移算法搜索概率密度时就会陷入纹理单元的局部极值点, 从而产生过分割结果. 这就必然要求使用一些更加有效的多维特征进行分割. 本文提出一种基于多维正交小波特征的快速均值漂移算法.

理论上, 正交小波分解的 3 个子带系数是相互独立的, 故对其进行线性变换得到的特征相互间也是不相关的. 另一方面, 均值漂移算法就是在多维特征空间中求解其联合概率密度的极值, 对于如正交小波这种互不相关的特征, 我们不需要考虑其多维特征空间, 而只需分别估计各特征的概率密度并相乘即得到所需的联合概率密度. 若 n 个像素点的特征空间为 R^d , 特征为 $x_i^d, i=1, \dots, n, d=1, \dots, m$, 则公式(7)变为

$$\hat{f}(x^1, \dots, x^d) = \frac{1}{n^d h^{d^2}} \sum_{i=1}^n K\left(\frac{x^1 - x_i^1}{h}\right) \dots \sum_{j=1}^n K\left(\frac{x^d - x_j^d}{h}\right) = \frac{1}{n^d h^{d^2}} \sum_{i=1}^n K^d\left(\frac{x^1 - x_i^1}{h}, \dots, \frac{x^d - x_i^d}{h}\right) \quad (12)$$

令上式导数为 0, 得到

$$m_{h,G}(x) = \frac{\sum_{i=1}^n x_i^d g^d\left(\left\|\frac{x^1 - x_i^1}{h}\right\|^2, \dots, \left\|\frac{x^d - x_i^d}{h}\right\|^2\right)}{\sum_{i=1}^n g^d\left(\left\|\frac{x - x_i}{h}\right\|^2, \dots, \left\|\frac{x^d - x_i^d}{h}\right\|^2\right)} - x \quad (13)$$

即在各个特征空间内分别进行均值漂移, 用上一次迭代得到的特征组合进行下一轮迭代, 最终得到所需的模式.

多维均值漂移算法的时间复杂度主要取决于在特征空间中寻找每个数据的近邻点这一操作, 因此, n 个 d 维数据均值漂移聚类算法的复杂度达到 $O(dn^2)$. 本文所提出的多维快速均值漂移算法, 由于在特征向量中加入了像素的空间位置信息, 缩小了近邻点寻找的范围, 算法复杂度被降低至 $O(dnh_r)$, 其中, h_r 是空间带宽.

4 对比实验及分析

本文的相关实验是在奔腾 IV, 2.4GHz, 1G 内存的 PC 机上进行的, 编程环境为 Matlab 7.0.

实验 1. 选用 8 幅 Brodatz 纹理库中的纹理合成的图像, 如图 4(a)、图 5(a)、图 6(a)、图 7(a)所示. 图像大小均为 256×256 , 其中包含 2 类~5 类纹理的合成图像各两幅. 进行 Daubechies 4 正交小波分解, 分解层数为 4, 对小波分解的高频系数分别提取 $(n_1, n_2) = \{(3, 1), (3, 1), (3, 3), (5, 3)\}$ 的 laws 特征, 低频系数提取窗口 $w = \{1, 3, 3, 5\}$ 的系数均值特征, 然后使用本文方法进行无监督分割, 其中每层均值漂移带宽参数的选择见表 1. 本文方法各尺度的分割结果如图 4~图 7 所示, 各尺度分割错误率、类别数及运行时间见表 1.

从图 4~图 7 和表 1 中可以看出,本文方法对以上图像都能得到正确的分割类别数和较为理想的分割结果,并且对规则纹理和不规则纹理都有较好的分割结果.该方法在粗尺度的分割错误率较高,均值漂移搜索得到的类别数也过多,而且产生了明显的锯齿形分割边缘.但是随着由粗尺度到细尺度的逐步分割,之前过分割的类别逐渐相互合并,分割边缘的准确度也在不断提高;同时,区域一致性也被进行了有效的传递,最终的分割结果在保持了较好区域一致性的同时,获得了更为准确的分割边界.

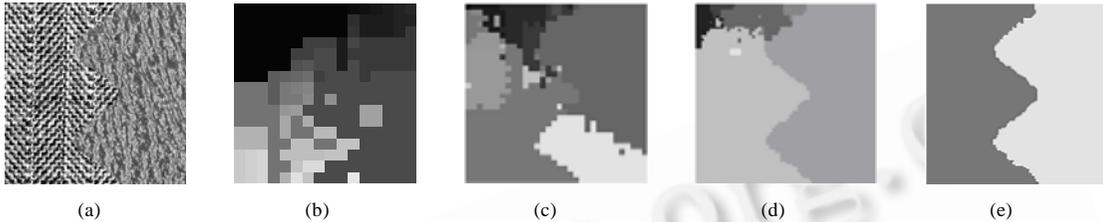


Fig.4 Original images with two different textures and segmentation of (a) in different scales (b)~(e)

图 4 两类纹理合成图像(a)及本文方法在由粗到细不同尺度下的分割结果(b)~(e)

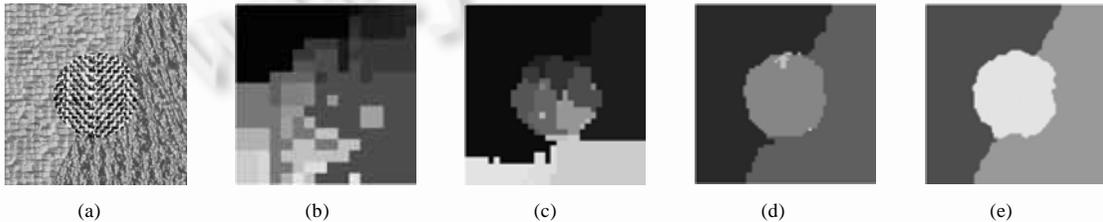


Fig.5 Original images with three different textures and segmentation of (a) in different scales (b)~(e)

图 5 3类纹理合成图像(a)及本文方法在由粗到细不同尺度下的分割结果(b)~(e)

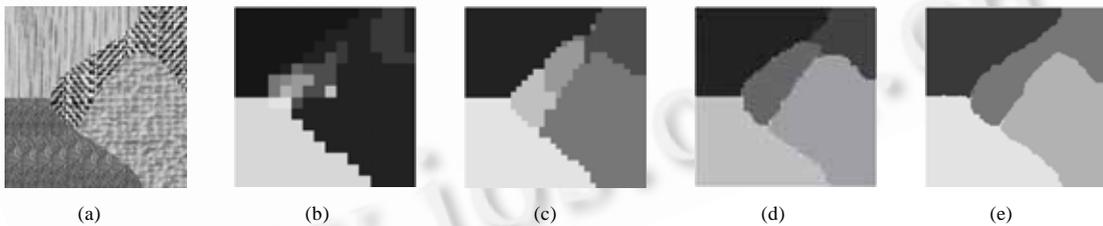


Fig.6 Original images with four different textures and segmentation of (a) in different scales (b)~(e)

图 6 4类纹理合成图像(a)及本文方法在由粗到细不同尺度下的分割结果(b)~(e)

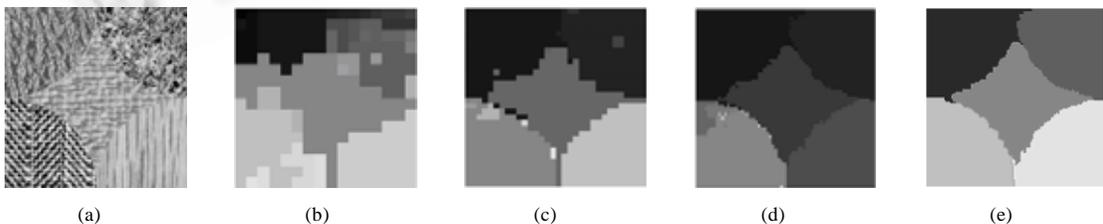


Fig.7 Original images with five different textures and segmentation of (a) in different scales (b)~(e)

图 7 5类纹理合成图像(a)及本文方法在由粗到细不同尺度下的分割结果(b)~(e)

Table 1 Results of proposed algorithm
表 1 本文方法在合成纹理图像分割中的实验结果

Image	Bandwidths of mean shift	Number of classes	Error rate (%)	Time (s)	
Fig.4	(b)	(3,0.08)	36	42.66	0.714 1
	(c)	(5,0.1)	16	37.27	2.653
	(d)	(5,0.12)	7	9.96	15.13
	(e)	(5,0.08)	2	0.93	278.2
Fig.5	(b)	(3,0.08)	40	42.22	0.668 2
	(c)	(3,0.1)	19	40.07	2.186
	(d)	(5,0.14)	5	2.20	14.08
	(e)	(5,0.1)	3	1.73	280.5
Fig.6	(b)	(5,0.1)	12	21.48	0.844 2
	(c)	(5,0.14)	6	15.14	2.309
	(d)	(5,0.14)	7	11.72	17.81
	(e)	(5,0.1)	4	2.61	256.5
Fig.7	(b)	(3,0.08)	35	45.31	0.638 2
	(c)	(5,0.1)	13	10.74	2.258
	(d)	(5,0.1)	12	8.50	13.36
	(e)	(5,0.08)	5	3.74	243.9

实验 2.我们把本文方法与文献[9]改进的均值漂移分割算法、模糊 C -均值聚类算法(FCM)^[15]和文献[16]的基于流行距离的免疫聚类方法(GAC)进行了比较.文献[9]的改进均值漂移算法的分割结果如图 8~图 11 第 2 列所示.从图中可以明显看出,文献[9]的算法对纹理图像的分割效果较差,只能得到过分割的结果.虽然该算法较之 Comaniciu^[12]所使用的均值漂移基本算法在运算速度和有效性上都有所提高,但它仍然是在灰度空间中进行搜索的,而纹理图像灰度值的较大起伏会使得搜索陷入局部极值点,该方法对于较平滑的区域分割比较有效(如图 9(a)左下角所示),但对灰度变化较剧烈的区域没有作用,该实验结果表明了本文基于小波多尺度自适应窗算法的有效性.另一方面,为了对本文的多维快速均值漂移算法的有效性进行分析,我们使用 FCM 和 GAC 对同样的特征并按照本文特征传递的方法进行自适应分割,结果如图 8(c)、图 8(d)、图 9(c)、图 9(d)、图 10(c)、图 10(d)、图 11(c)、图 11(d)所示.为了能够更好地度量这几种算法的区域一致性和边界准确度,除了使用分割错误率之外,我们还使用文献[17]提供的基于区域和边界的图像分割质量评价指标.在基于边界的评价方法中,如果用 G 和 B 分别表示真实边界和分割所得边界,则 G 上各点到 B 的最小距离和 B 上各点到 G 的最小距离分别构成了两个分布 D_G^B 和 D_B^G ,它们的均值 $\mu D_G^B, \mu D_B^G$ 和方差 $\sigma D_G^B, \sigma D_B^G$ 可以被用来度量 G 和 B 之间的偏离,单位为像素.数值越小则 G 和 B 的吻合程度越高,即边界准确度就越高.另一方面,在基于区域的评价方法中,文献[17]定义了基于标准化 Hamming 距离的分割性能度量函数 p ,其值域为 $[0,1]$.分割区域与真实区域吻合程度越高,则 p 越接近于 1;并在此基础上定义了区域分割的漏检率 e ,该误差越小,则分割性能越好.对比实验的上述评价参数计算结果见表 2.

由图 8~图 11 和表 2 的实验结果可以看出,与文献[16]的 GAC 算法相比,FCM 的分割区域一致性相对较好,而 GAC 分割边界更为准确;同时,GAC 对于大部分图像分割错误率也更低一些.但是该方法的稳定性较差,例如图 11(d)所示,GAC 的分割错误率就明显高于 FCM 方法,分割错误率接近 20%.由图 8~图 11 的实验结果可以较直观地观察到,本文方法在边界准确性和区域一致性方面均优于基于 FCM 和 GAC,算法稳定性也较好.从表 2 的量化指标中也可以看出,本文方法在分割错误率、基于边缘的量化指数及基于区域的量化指数方面总体上也优于其他算法的.这主要是因为 FCM 只对凸数据集聚类比较有效,但文献[9]证明了图像数据并不完全是凸数据集.文献[16]的 GAC 方法采用流行距离来进行相似性度量,虽然可以提高分割边界的准确性,但是当数据不符合流行分布的时候,算法的效果就会急剧下降,因此影响了该方法的稳定性.而均值漂移算法是一种基于密度的聚类算法,它通过数据密度发现任意形状类别,对凸数据集和非凸数据集同样有效,具有较好的稳定性.另外,FCM 和文献[16]的 GAC 方法虽然不需要训练,但是都需要事先给定分割类别数,而本文算法可以自动决定类别,并且在以上实验中均能找到正确的类别数,因此从完全无监督的意义上来说也优于其他算法.

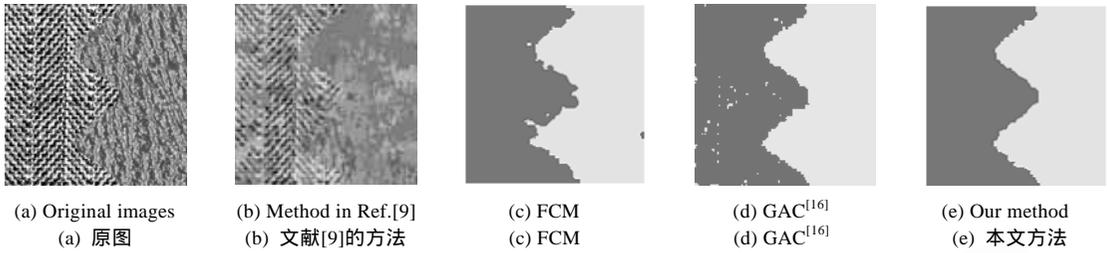


Fig.8 Segmentation results of the compared methods (two-texture image)

图 8 对比算法分割结果(两类纹理)

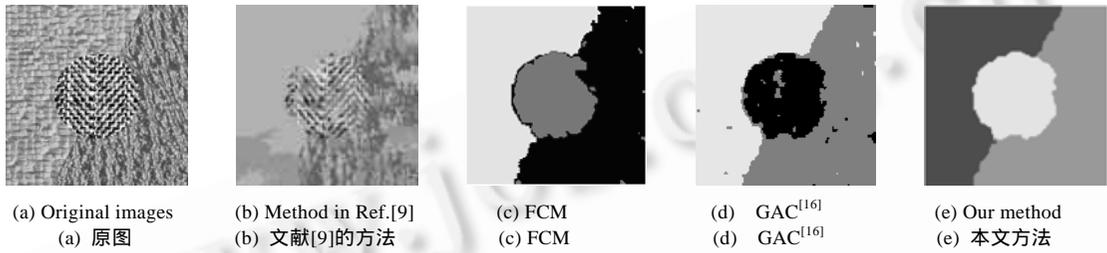


Fig.9 Segmentation results of the compared methods (three-texture image)

图 9 对比算法分割结果(三类纹理)

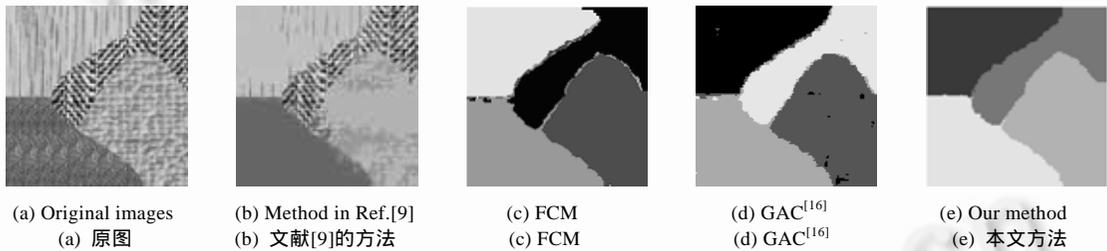


Fig.10 Segmentation results of the compared methods (four-texture image)

图 10 对比算法分割结果(四类纹理)

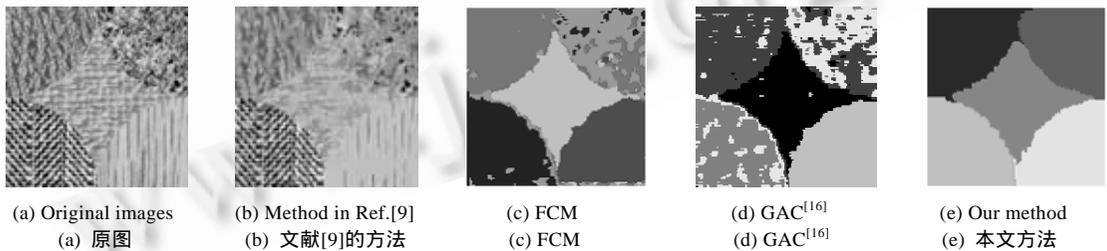


Fig.11 Segmentation results of the compared methods (five-texture image)

图 11 对比算法分割结果(五类纹理)

Table 2 Comparison of different methods

表 2 不同方法对比实验结果

Image		Region-Based			Boundary-Based				Error rate (%)
		e_1	e_2	p	μD_G^B	σD_G^B	μD_B^G	σD_B^G	
Fig.8(a)	FCM	0.020 7	0.019 4	0.979 9	3.636 1	9.550 1	1.025 0	0.830 8	2.07
	GAC	0.015 9	0.009 8	0.987 1	0.505 1	0.675 6	0.386 3	0.598 2	1.59
	Our method	0.009 3	0.009 3	0.990 6	0.637 7	0.635 1	0.593 1	0.606 6	0.93
Fig.9(a)	FCM	0.036 2	0.027 0	0.968 4	4.849 1	10.577 8	0.926 9	1.108 7	7.20
	GAC	0.036 4	0.022 5	0.970 6	0.803 6	1.128 3	0.409 3	0.689 5	3.64
	Our method	0.017 3	0.017 3	0.982 7	0.855 6	1.041 5	0.782 9	0.903 3	1.73
Fig.10(a)	FCM	0.038 1	0.029 5	0.966 2	1.407 3	2.441 4	0.777 0	1.006 0	4.40
	GAC	0.038 0	0.017 6	0.972 2	0.684 5	0.754 6	0.585 6	0.710 7	3.79
	Our method	0.017 2	0.026 1	0.978 4	0.605 2	0.678 5	0.929 4	1.158 5	2.61
Fig.11(f)	FCM	0.127 1	0.037 3	0.917 8	13.042 5	16.482 5	0.530 2	0.630 4	12.50
	GAC	0.210 8	0.069 8	0.859 7	7.002 4	8.757 3	1.890 0	1.562 5	19.93
	Our method	0.025 0	0.037 8	0.968 6	0.764 0	1.350 0	1.056 5	1.028 7	3.74

实验 3.第 3 组实验是真实纹理图像的分割实验,图 12 原图的图 12(a)、图 12(f)取自 Berkeley 图像数据库.为了能够提取其正交小波特征,我们截取原图的 320×320 大小子图进行分割,对每一级的低频系数取窗口 $w=\{1,3,3,5\}$,对 4 层高频系数分别提取 $(n_1, n_2)=\{(3,1), (3,1), (3,1), (5,3)\}$ 的 laws 特征,各层均值漂移带宽系数都为 $(h_s, h_r)=(5, 0.14)$.实验结果如图 12(b)~图 12(e)、图 12(g)~图 12(j),分别给出了使用本文方法在 4 个不同尺度下的分割结果.可以看出,本文方法不仅对纹理合成图像有效,对真实纹理图像也能得到较为理想的效果.

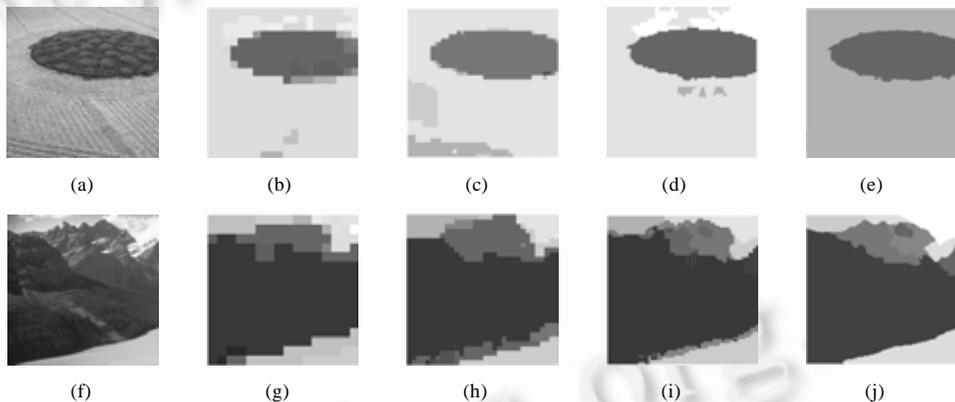


Fig.12 Segmentation results of real texture images

图 12 真实纹理图像分割结果

5 结 论

本文从图像分割的区域一致性和边缘准确性要求出发,结合正交小波变换和均值漂移聚类,提出了一种无监督的自适应多分尺度纹理图像分割方法.该方法基于正交小波变换子带系数的不相关性,提出了快速的多维均值漂移算法,能够较快地实施多维数据处理,并采用小波自适应特征窗口在不同尺度上进行无监督分割,通过尺度间的信息传递,在粗尺度分割的基础上,利用更细尺度特征对先前的不确定区进一步分割,最终得到分割结果.对比实验结果表明,该方法对人工纹理和自然纹理都具有较好的效果,其区域一致性和边缘准确度都比较高.由于引入了均值漂移算法,使得该方法不需要训练样本,也不需要任何有关类别数的先验知识,实现了完全无监督的分割过程,在实际应用中有很大潜力.

References:

- [1] Tuceryan M. Analysis T. The Handbook of Pattern Recognition and Computer Vision. 2nd ed., World Scientific Publishing Co., 1998. 207-248.

- [2] Randen T, John HH. Filtering for texture classification: A comparative study. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1999,21(4):291–311. [doi: 10.1109/34.761261]
- [3] Honen J, Kamarainen JK, Paalanen P, Hamouz M, Kittler J, Kalviainen H. Image feature localization by multiple hypothesis testing of Gabor features. *IEEE Trans. on Image Processing*, 2008,17(3):311–325. [doi: 10.1109/TIP.2007.916052]
- [4] Selvan S, Ramakrishnan S. SVD-Based modeling for image texture classification using wavelet transformation. *IEEE Trans. on Image Processing*, 2007,16(11):2688–2696. [doi: 10.1109/TIP.2007.908082]
- [5] Scharcanski J. A wavelet-based approach for analyzing industrial stochastic textures with applications. *IEEE Trans. on Systems, Man, and Cybernetics—Part A: Systems and Humans*, 2007,37(1):10–21. [doi: 10.1109/TSMCA.2006.886345]
- [6] Huang K, Aviyente S. Wavelet feature selection for image classification. *IEEE Trans. on Image Processing*, 2008,17(9):1709–1719. [doi: 10.1109/TIP.2008.2001050]
- [7] Fan GL, Xia XG. Wavelet-Based texture analysis and synthesis using hidden Markov models. *IEEE Trans. on Circuits and Systems I: Fundamental Theory and Applications*, 2003,50(1):106–120. [doi: 10.1109/TCSI.2002.807520]
- [8] Dasgupta N, Carin L. Texture analysis with variational hidden Markov trees. *IEEE Trans. on Signal Process*, 2006,54(6):2353–2356. [doi: 10.1109/TSP.2006.872588]
- [9] Christoudias CM, Georgescu B. Synergism in low level vision. In: *Proc. of the 16th Int'l Conf. on Pattern Recognition*, Vol.4. Quebec City, 2002. 150–155.
- [10] Liang KH, Tjahjadi T. Adaptive scale fixing for multiscale texture segmentation. *IEEE Trans. on Image Processing*, 2006,15(1):249–256. [doi: 10.1109/TIP.2005.860340]
- [11] Cheng YZ. Mean shift, mode seeking, and clustering. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1995,17(8):790–799. [doi: 10.1109/34.400568]
- [12] Comaniciu D, Meer P. Mean shift: A robust approach toward feature space analysis. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2002,24(5):603–619. [doi: 10.1109/34.1000236]
- [13] Li XR, Wu FC, Hu ZY. Convergence of a mean shift algorithm. *Journal of Software*, 2005,16(3):365–374 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/16/365.htm> [doi: 10.1360/jos160365]
- [14] Wen ZQ, Cai ZX. Convergence analysis of mean shift algorithm. *Journal of Software*, 2007,18(2):205–212 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/18/205.htm> [doi: 10.1360/jos180205]
- [15] Sun JG, Liu J, Zhao LY. Clustering algorithms research. *Journal of Software*, 2008,19(1):48–61 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/19/48.htm> [doi: 10.3724/SP.J.1001.2008.00048]
- [16] Gong MG, Jiao LC, Bo LF, Wang L, Zhang XR. Image texture classification using a manifold distance based evolutionary clustering method. *Optical Engineering*, 2008,47(7):077201-1–077201-10.
- [17] Huang Q, Dom B. Quantitative methods of evaluating image segmentation. In: *Proc. of the IEEE Int'l Conf. on Image Processing*. Washington: IEEE Computer Society, 1995. 53–56. <http://www.ieeexplore.ieee.org/iel3/4052/11608/00537578.pdf>

附中文参考文献:

- [13] 李乡儒,吴福朝,胡占义.均值漂移算法的收敛性. *软件学报*,2005,16(3):365–374. <http://www.jos.org.cn/1000-9825/16/365.htm> [doi: 10.1360/jos160365]
- [14] 文志强,蔡自兴. Mean Shift 算法的收敛性分析. *软件学报*,2007,18(2):205–212. <http://www.jos.org.cn/1000-9825/18/205.htm> [doi: 10.1360/jos180205]
- [15] 孙吉贵,刘杰,赵连宇. 聚类算法研究. *软件学报*,2008,19(1):48–61. <http://www.jos.org.cn/1000-9825/19/48.htm> [doi: 10.3724/SP.J.1001.2008.00048]



王爽(1978 -),女,陕西礼泉人,博士,副教授,CCF 高级会员,主要研究领域为多尺度几何分析,图像处理,SAR 图像处理.



焦李成(1959 -),男,博士,教授,博士生导师,CCF 高级会员,主要研究领域为智能信息处理,自然计算,机器学习,图像处理.



夏玉(1984 -),女,硕士生,主要研究领域为图像分割.