

基于 EHMM-HMT 和 MSHWMT 的多尺度纹理图像分割^{*}

陈蓉伟^{1,2}, 刘芳^{1,2+}, 郝红侠^{1,2}

¹(西安电子科技大学 计算机科学与技术学院,陕西 西安 710071)

²(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)

Multi-Scale Texture Image Segmentation Based on EHMM-HMT and MSHWMT Models

CHEN Rong-Wei^{1,2}, LIU Fang^{1,2+}, HAO Hong-Xia^{1,2}

¹(Department of Computer Science and Technology, Xidian University, Xi'an 710071, China)

²(Key Laboratory of Intelligent Perception and Image Understanding of Ministry of Education of China, Xidian University, Xi'an 710071, China)

+ Corresponding author; E-mail: f63liu@163.com

Chen RW, Liu F, Hao HX. Multi-Scale texture image segmentation based on EHMM-HMT and MSHWMT models. *Journal of Software*, 2010,21(9):2206–2223. <http://www.jos.org.cn/1000-9825/3621.htm>

Abstract: Texture images have abnormal, microscopic characteristics, but some parts of the image maintain statistical regularity from a macroscopic point of view. In order to capture these characteristics that improve image segmentation results, a new wavelet-based, multi-scale Bayesian texture image segmentation method, based on EHMM-HMT (enhanced hidden Markov model-hidden Markov tree) and MSHWMT (multi-states weighted hidden Markov tree) modes, is proposed. The image blocks' relative interactions are described through the EHMM model effectively, and the homogenous raw segmentation, propitious to final fusion, is obtained on the coarsest scale. Subsequently, in order to reduce mislabeling the boundaries of raw segmentation and to decrease the computing complexity of the model, the MSHWMT model is proposed with better raw segmentations of high accurate boundary detection put on finer scales. Finally, a pixel level segmentation is reached through a multi-scale Bayesian fusing strategy that combines with the boundaries. The method is compared to HMTseg, HMT (boundary based+MAP), and EHMM-HMT (MAP) algorithm through several micro-texture images to demonstrate its competitive performance. It has also been found to improve the accuracy of macro-texture image segmentations.

Key words: EHMM-HMT; statistical information; MSHWMT; boundary detection; texture image segmentation

摘要: 纹理图像具有微观不规则但宏观存在某种统计规律性的特点。在图像分割中,为了捕捉此特性来改善分割效果,提出了 EHMM-HMT(enhanced hidden Markov model-hidden Markov tree)和 MSHWMT(multi-states weighted

* Supported by the National Natural Science Foundation of China under Grant Nos.60673097, 60601029, 60672126, 60702062 (国家自然科学基金); the National High-Tech Research and Development Plan of China under Grant Nos.2008AA01Z125, 2007AA12Z136, 2007AA12Z223 (国家高技术研究发展计划(863)); the National Research Foundation for the Doctoral Program of Higher Education of China under Grant Nos.20060701007, 20070701016 (国家教育部博士点基金); the Ministry & Commission-Level Research Foundation of China under Grant Nos.XADZ2008159, 51307040103 (国家部委科技项目资助项目)

Received 2008-10-17; Revised 2008-11-27, 2009-02-16; Accepted 2009-03-31

hidden Markov tree)模型的多尺度贝叶斯纹理图像分割方法.该方法通过 EHMM 模型有效地描述了图像块间的相互作用关系,在最粗尺度上并运用 EHMM-HMT 模型得到了有利于保持区域一致性的初分割.然后,为了减少初分割对边界造成的误判和降低计算复杂度,提出了 MSWHMT 模型,在各个细尺度上应用该模型实现了具有较好的边界检测效果的初分割.最后,通过结合边界信息的多尺度贝叶斯融合策略对纹理图像实现了像素级的分割.实验结果表明,与 HMTseg,HMT(boundary based+MAP)和 EHMM-HMT(MAP)方法相比,该方法不仅对微纹理图像有好的分割效果,对宏纹理图像也达到了较优的分割性能.

关键词: EHMM-HMT;统计信息;MSWHMT;边界检测;纹理图像分割

中图法分类号: TP391 **文献标识码:** A

纹理图像分割是图像分割中重要的研究内容之一^[1,2],其面临的难点^[3]是:一方面,要求同质纹理区内区域一致性好、无误分;另一方面,要求不同纹理区域间的边界保持良好、无误判.为此,国内外学者提出了许多纹理图像分割方法,主要有共生矩阵法、基于小波和 Gabor 滤波器的方法^[2]、马尔可夫随机场方法^[4]和多尺度纹理图像分割方法^[4~7]等.纹理图像具有微观不规则但宏观存在某种统计规律性的特点,因此人们越来越关注纹理图像的多尺度特征^[8],从不同的尺度层次来捕捉纹理的微观和宏观特性,多尺度思想在纹理图像分割领域也得到了广泛应用.

多尺度图像分割方法可分为基于变换域^[6,7,9]和空间(像素)域^[4,5]两大类.Crouse 等人^[10]提出的小波域 HMT (hidden Markov tree)模型能够有效地描述小波系数在尺度间、尺度内的统计相关性.基于该模型,Choi 等人提出了多尺度图像分割方法 HMTseg^[6],而后,侯玉华等人^[11]在 HMTseg 方法基础之上舍弃小波域 3 个子带间独立性假设,提出了改进的 HMT 分割方法.由于 HMT 是一个基于局部(图像块内)特征的统计模型,侧重于考虑图像块内的统计特性,故能较好地对图像块内(微观上)数据建模,但不能有效地描述纹理中图像块间(宏观上)的相关性.因此,HMTseg 及其改进方法对微纹理分割性能良好,但对于宏纹理其分割效果则有待提高.在空间域统计图像建模方面,Li 和 Gray 等人^[12]从加强对图像块间相互作用关系的描述出发提出了 2D-HMM(two-dimensional hidden Markov model).该模型将纹理图像分割成大小相同的图像块,强调了对图像块间的相互作用关系建模,却未能对图像块内的纹理特征进行准确高效的描述,致使该模型的分割效果并不尽如人意.为了全面地捕捉纹理图像的宏观和微观特征,Lu 和 Carin 等人^[13]将空间域的 HMM 模型和变换域的 HMT 模型相结合提出了 HMM-HMT 模型.该模型通过 HMM 和 HMT 分别对图像块间的相关性和图像块内的纹理特征建模,有效地描述了纹理的宏观和微观统计特征,故该模型在一个尺度上得到了较可靠的初分割结果.

然而,应用 HMM-HMT 模型计算从粗到细各个尺度上的初分割时需分别训练每个尺度上该模型的参数,这极大地增加了算法的计算复杂度;相反地,如果只计算最粗尺度上的模型参数而不计算其他各细尺度上的模型参数,那么只能得到最粗尺度上的初分割,而无法得到其他各细尺度上的初分割.显然,这难以得到区域一致性好且边界保持良好的最终分割结果.为了在降低模型计算复杂度的同时能够进一步提高模型对细尺度的分割效果,特别是对边界的感知能力,本文提出了基于 EHMM-HMT(enhaned hidden Markov model-hidden Markov tree)和 MSWHMT(multi-states weighted hidden Markov tree)模型的多尺度贝叶斯图像分割方法.该方法提出的 EHMM-HMT 模型能够对纹理图像块间的相关性精确建模,可增强文献[13]中 HMM-HMT 模型对块间相关性的描述,在最粗尺度上得到了更可靠的初分割.该方法在计算细尺度的初分割时运用与块隐状态相联系的两组 HMT 参数,提出了多状态加权 HMT(MSWHMT)模型.该模型在对块内纹理特征建模的同时实现了对复杂纹理中平滑图像块和奇异图像块的宏观估计,在降低模型计算复杂度的同时改善了各细尺度上的初分割及其边界检测结果.最后,结合边界信息的多尺度贝叶斯融合策略实现了对各尺度初分割结果的有效融合,得到了像素级分割.实验表明,与 HMTseg,HMT(boundary based+MAP)和 EHMM-HMT(MAP)方法相比,本文方法不仅对微纹理有好的分割效果,对于更富挑战性的宏纹理也达到了较优的分割性能.

本文第 1 节给出本文方法的流程图.第 2 节和第 3 节详细介绍本文提出的 EHMM-HMT 模型和 MSWHMT 模型.第 4 节介绍结合边界信息的多尺度贝叶斯融合策略.第 5 节列举实验结果.最后给出结论.

1 基于 EHMM-HMMT 和 MSHWMT 的多尺度贝叶斯分割算法总流程

本文在分析纹理图像常表现出来的微观不规则但宏观存在某种统计规律性特性的基础上,建立了一个基于 EHMM-HMT 粗尺度初分割、基于 MSHWMT 细尺度初分割和结合边界信息的多尺度 MAP 融合等 3 个主要步骤构成的处理流程,如图 1 所示。

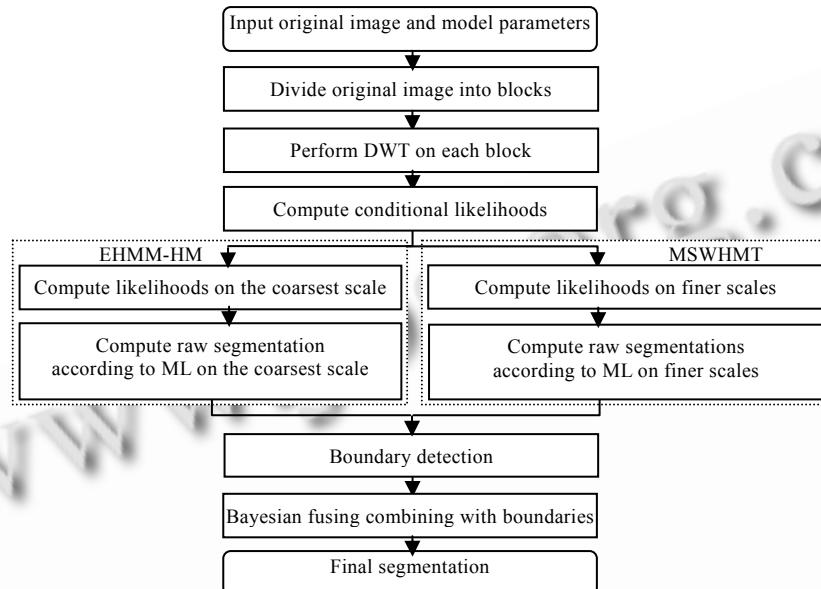


Fig.1 Total flow chart of the texture image segmentation algorithm

图 1 纹理图像分割算法的总流程图

2 EHMM-HMT 模型及其参数估计

2.1 HMT模型

HMT 是基于树结构的概率图模型,能有效地描述小波系数在尺度间、尺度内的统计相关性,是一种新的统计图像感知与识别方法.Crouse 等人将小波系数在尺度内的聚集性(intra-scale clustering)建模为高斯混合分布,两状态零均值的高斯混合模型(Gaussian mixture model,简称 GMM)可有效地逼近小波系数的非高斯分布;对尺度间的持续性(inter-scale persistence)则建模为隐马尔可夫树模型^[6,10],树型结构很好地描述了父子系数间持续性特点。

在小波域 HMT 模型中,一个两状态的 HMT 参数集可表示为

$$HMT = \{P_J^b(m), \varepsilon_{j,j-1}^b(m,n), \delta_{b,j,m}^2 \mid j=2, L, J; m, n = Small, Large; b = LH, HH, HL\},$$

其中, $P_J^b(m)$ 是 J 尺度内子带 b 上系数状态为 m 的概率, $\varepsilon_{j,j-1}^b(m,n)$ 是子带 b 上从尺度 j 到尺度 $j-1$ 的转移概率,而 $\delta_{b,j,m}^2$ 是尺度 j 内子带 b 上小波系数 W_j 在状态 $S=m$ 时的方差.HMT 参数可采用期望最大化(expectation maximum,简称 EM)算法^[10]训练得到。

2.2 HMM-HMT(hidden Markov model-hidden Markov tree)模型

分析 HMT 模型参数训练过程可知,EM 算法采用了系数绑定技术(lying technic),认为四叉树上相同深度的所有节点共享一组 HMT 参数,HMT 模型是一个基于局部(图像块内)特征的统计模型,可以较好地对图像块内的数据建模.系数“绑定”固然能降低 EM 算法的计算复杂度,但这必然使训练得到的 HMT 参数无法捕捉纹理图像在宏观上表现出的统计规律性.而在描述纹理的宏观统计规律性方面,由 Li 和 Gray 等人^[12]提出的 2D-HMM 有

较强的描述能力,该模型先将纹理图像分割成大小相同的图像块,并在考虑块内微观纹理特征的同时也从宏观上对图像块间的相关性建模。2D-HMM 模型不足的是不能对图像块内的纹理特征进行准确高效地描述,致使该模型的分割结果并不尽如人意。为了更全面地捕捉纹理图像的宏观和微观特征,Lu 和 Carin 等人^[13]提出了隐马尔可夫模型-隐马尔可夫树模型(HMM-HMT),该模型既能对图像块内的纹理特征建模又能对纹理的宏观统计规律性建模,可全面地描述纹理图像的微观和宏观特征。

基于 HMM-HMT 的算法思想简要描述如下:首先,将图像 X 剖分为 $M \times N$ 个图像块(一个图像块常选 16×16),并给每一个图像块联系一个块隐状态变量 S (依据图像块内的灰度变化情况,定义 S 为“奇异图像块”和“平滑图像块”共两个状态),这样,图像 X 即可视为由 $M \times N$ 个块隐状态变量构成的块隐状态图 X^B 。然后,运用 HMT 模型对每一个图像块分别建模,这里,每一个基于块的 HMT 是与该块的隐状态相关的,同时运用 HMM 对图像块间的相关性建模。这样,一方面 HMT 很好地描述了纹理图像中各个图像块内的微观特征,另一方面 HMM 很好地描述了纹理图像(可看作由多个图像块构成)的宏观统计规律性。

为方便描述,我们把与中心块记为 C ,它对应图 2(a)中的块 5,把与中心块直接相邻的 4 个块记为 I 类邻域块,把与中心块不直接相邻的 4 个块记为 II 类邻域块,如图 2(e)所示。文献[13]给出了 HMM-HMT 模型的两点假设:(1) 中心块与其不直接相邻的块是独立的;即块 C 与 II 类邻域块 6~块 9 是独立的;(2) 中心块与其直接相邻的块间的依赖(dependency)是各向同性的;即块 C 至 I 类邻域块 1~块 4 的状态转移概率是相同的。基于以上两点假设可以得到图 2(c)所示的块间马尔可夫关系图(其中,图 2(a)为 HMM 模型中中心块 5 与邻域块的作用关系,图 2(b)为 EHMM 模型中中心块 5 与邻域块的作用关系,图 2(c)为 HMM 模型中 9 个块间的马尔可夫依赖关系图,图 2(d)为 EHMM 模型中 9 个块间的马尔可夫依赖关系图,图 2(e)为 I 类邻域块和 II 类邻域块)。

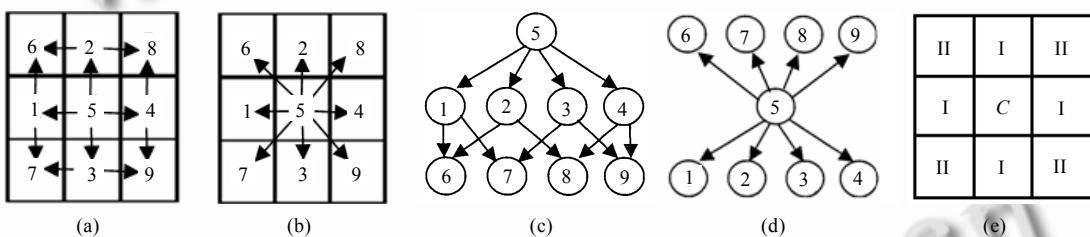


Fig.2 Blocks' neighbor figure

图 2 块邻域结构图

2.3 EHMM-HMT 模型

分析 HMM-HMT 模型提出的第 1 点假设我们不难发现,块 C 与 II 类邻域块是独立的。对于这样的假设是否太苛刻?于是我们给出了中心块与 I 类、II 类邻域块间的互信息,分析了它们之间的相关性。互信息最早于 1948 年由 Shannon^[14,15]提出,它反映了一个变量包含了另一个变量的信息量多少。如果两个变量相互独立则互信息为 0,而两个变量高度相关时则互信息接近 1。对于两个离散型随机变量 X 和 Y ,其互信息定义为

$$I(X;Y) = \sum_y \sum_x p(x,y) \log \left(\frac{p(x,y)}{p(x)p(y)} \right) \quad (1)$$

其中, $p(x,y)$ 表示随机变量 X 和 Y 的联合分布律, $p(x)$ 和 $p(y)$ 分别为 X 和 Y 的边缘分布律。

文献[15]给出了以下定理:

定理 1. 若 $X \rightarrow Y \rightarrow Z$, 则 $I(X;Z) \leq I(X;Y)$ 。

由定理 1 可知, X 与 Z 通过 Y 间接作用的互信息 $I(X;Z)$ 要比 X 与 Y 直接作用的互信息 $I(X;Y)$ 要小,即 II 类邻域块通过 I 类邻域块与中心块 C 发生间接联系,其互信息 $I(C;II)$ 比其发生直接联系的互信息 $I(C;I)$ 要小。但这并不表明 $I(C;II)$ 就远远小于 $I(C;I)$ 或等于 0。因此,文献[13]中的第 1 条假设有些过于简单。为了说明这一点,我们对 Brodatz 标准纹理库里典型的纹理图像做了仿真实验。在实验中,我们把纹理图像分为两种不同类型,分别是微纹理和宏纹理,如图 3 所示。我们分别求出了以下 6 幅纹理图像的块间互信息 $I(C;I)$ 和 $I(C;II)$,见表 1。从表 1 可知,

不论是哪种类型的纹理图像,虽然互信息 $I(C;I) > I(C;II)$,但 $I(C;II) \neq 0$ 且 $I(C;II)$ 不会远远小于 $I(C;I)$.当 $I(C;II)$ 较小时, $I(C;I)$ 也不大,见表 1 中的微纹理 D4 和宏纹理 D75.值得注意的是,当 $I(C;I)$ 较大时, $I(C;II)$ 也较大,如表 1 中的微纹理 D9、宏纹理 D42.通过实验结果和以上的分析我们认为,直接描述 II 类邻域块与中心块间之间的关系更合理,而不是把它们看成彼此独立的,如图 2(b)和图 2(d)所示.

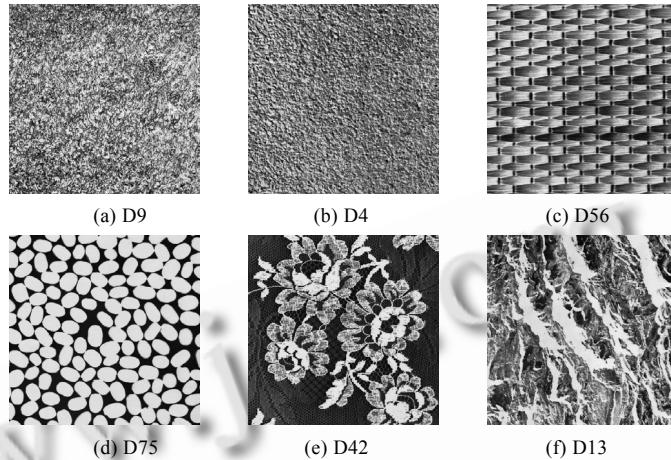


Fig.3 Micro-Texture images and macro-texture images chosen from the Brodazt texture database
图 3 Brodazt 标准纹理库中部分微纹理图像和宏纹理图像

Table 1 Mutual information between the central block and its I, II neighbors for different types of the textures
表 1 不同类型纹理的 I 类、II 类邻域块与中心块 C 间的互信息

Type	Mosaics	Mutual information	
		$I(C;I)$	$I(C;II)$
Micro-Textures	D9	0.13	0.05
	D4	0.03	0.02
Macro-Textures	D56	0.12	0.04
	D75	0.02	0.01
	D42	0.40	0.28
	D13	0.11	0.03

为了更好地捕捉纹理宏观统计规律性,本文提出了增强 HMM-HMT 模型.该模型的两点假设为:

- (1) 中心块 C 与其 8 邻域内的所有块互不独立,且有直接联系;
- (2) 中心块 C 与其直接相邻块间、不直接相邻块间的依赖(dependency)是各向同性的,且中心块 C 与其直接相邻块间的依赖程度和中心块与不直接相邻块间的依赖程度不同.

基于以上两点假设可以得到如下公式:

$$\begin{cases} p(S^1 | S^5) = p(S^2 | S^5) = p(S^3 | S^5) = p(S^4 | S^5) \\ p(S^6 | S^5) = p(S^7 | S^5) = p(S^8 | S^5) = p(S^9 | S^5) \end{cases} \quad (2)$$

于是,中心块 C 与其 8 邻域的联合概率为 $p(S^1, \dots, S^9)$:

$$\begin{aligned} p(S^1, \dots, S^9) &= p(S^5 | S^j, \forall j \neq 5) p(S^j, \forall j \neq 5) \\ &\approx p(S^5) p(S^1, S^2, S^3, S^4, S^6, S^7, S^8, S^9 | S^5) \\ &\approx p(S^5) \prod_{i=1}^4 p(S^i | S^5) \prod_{i=6}^9 p(S^j | S^5) \end{aligned} \quad (3)$$

基于以上两点假设,EHMM-HMT 模型有图 2(d)所示的块间马尔可夫关系图.我们不难得到 EHMM-HMT 模型的参数,分别是块隐状态概率 $\pi_k = p(B=k)$,其中, $k=\{sm,s\}$ (sm 代表平滑图像块, s 代表奇异图像块);中心块 C 至 I 类邻域块的隐状态转移概率 $\alpha_{m,n}$ 和中心块 C 至 II 类邻域块的隐状态转移概率 $\beta_{m,n}$,其中, $m,n=\{sm,s\}$;与块隐状态相联系的 HMT 参数 $HMT_k = \{HMT_{sm}, HMT_s\}$,其中 HMT_{sm} 和 HMT_s 分别代表平滑图像块组、奇异图像块组的 HMT

参数.HMT 参数详见第 2.1 节.

2.4 EHMM-HMT 模型参数估计

EHMM-HMT 参数估计过程与 HMM-HMT 模型的参数估计过程^[9,13]相似,可分为内外两层,其中内层训练基于块内的 HMT 参数,外层则训练基于块间的 EHMM 参数.HMT 参数的训练选用期望最大化算法(EM 算法),而 EHMM 参数的训练则采用类 Viterbi 算法^[13]实现.类 Viterbi 算法为每一个图像块联系一个块隐状态变量,则第 i 个图像块 B_i 的块隐状态属于 k 的似然 $l_k(W_{B_i})$ 表示为

$$l_k(W_{B_i}) = p(W_{B_i} | B_i = k), i = 1, \dots, Q \quad (4)$$

其中, B_i 表示第 i 个图像块的块隐状态变量, W_{B_i} 为第 i 个图像块的小波系数, $k = \{sm, s\}$.

与类 Viterbi 算法的介绍类似,我们通过公式(5)计算中心块 C 及其 8 邻域的联合状态概率 $\delta_{i,II}(k_{I,II})$.

$$\delta_{i,II}(k_{I,II}) = l_{k_I}(W_I) \times l_{k_{II}}(W_{II}) \times \max_{m=sm,s} \{\delta_C(k_C) \times \alpha_{m \rightarrow k_I} \times \beta_{m \rightarrow k_{II}}\} \quad (5)$$

其中,

$$\begin{cases} l_{k_I}(W_I) = l_{k_1}(W_1)l_{k_2}(W_2)l_{k_3}(W_3)l_{k_4}(W_4) \\ l_{k_{II}}(W_{II}) = l_{k_6}(W_6)l_{k_7}(W_7)l_{k_8}(W_8)l_{k_9}(W_9) \\ \alpha_{m \rightarrow k_I} = \alpha_{m,k_1}\alpha_{m,k_2}\alpha_{m,k_3}\alpha_{m,k_4} \\ \beta_{m \rightarrow k_{II}} = \beta_{m,k_6}\beta_{m,k_7}\beta_{m,k_8}\beta_{m,k_9} \\ \delta_C(k_C) = \pi_{k_C}l_{k_C}(W_C) \end{cases} \quad (6)$$

EHMM-HMT 参数的估计分 5 步进行,具体步骤如下:

Step 1. $t=1$, 输入纹理类别数 E .

Step 2. 对第 t 类纹理做 Step 3, Step 4.

Step 3. 将纹理分割成 16×16 (或 8×8)大小互不重叠的图像块,然后采用 db1 小波,对每一个图像块作二维离散小波变换并分解成 4(或 3)层,并对每一个图像块通过 EM 算法训练出各自的 HMT 参数 HMT_i ,其中, $i=1, 2, \dots, Q$, Q 为图像块的总个数.

Step 4. 训练 EHMM 参数:

- (1) 对于每一个图像块所联系的块隐状态变量,其初始值可任意赋值,并初始化 EHMM 参数 $\pi_k, \alpha_{m,n}, \beta_{m,n}, k = \{sm, s\}, m, n = \{sm, s\}$;
- (2) 依据块隐状态变量的值对所有图像块分成两组,然后通过求平均更新每一组的 HMT 参数(HMT_{sm} 代表平滑图像块组 HMT 参数, HMT_s 代表奇异图像块组 HMT 参数),最后计算每一个图像块 W_{B_i} 对块隐状态 k_i 的似然 $l_k(W_{B_i})$, $k = \{sm, s\}; i = 1, 2, \dots, Q$;
- (3) 通过公式(5)、公式(6)计算中心块 C 的后验概率 $\delta_C(k_C)$ 和中心块 C 与其 8 邻域的联合状态概率 $\delta_{i,II}(k_{I,II})$;
- (4) 对公式(5)求最大值,从而估计最可能的状态序列 $\{k_1, k_2, k_3, k_4, k_5, k_6, k_7, k_8, k_9\}$,并对中心块 C 的隐状态变量赋值为 k_C ;
- (5) 对每一个图像块均当作中心块 C 一次,并按步骤(3)、步骤(4)估计出每个图像块的隐状态变量的值;至此,即可从整幅图像的宏观层面上统计出块隐状态图 B 的块与块之间的块隐状态转移概率 $\alpha_{m,n}, \beta_{m,n}$ 和块隐状态概率 $\pi_k, k = \{sm, s\}$,从而达到更新 EHMM 参数的目的;
- (6) 终止条件判别(如参数收敛或满足最大迭代次数要求),若成立即停;否则,转步骤(2).

Step 5. 由 Step 2~Step 4 即可得到第 t 类纹理的 EHMM-HMT 参数 $\theta_t, \theta_t = \{HMT_{sm}^t, HMT_s^t, \pi_k^t, \alpha_{m,n}^t, \beta_{m,n}^t\}$, 其中, HMT_{sm}^t 和 HMT_s^t 分别代表平滑图像块组、奇异图像块组的 HMT 参数, $k = \{sm, s\}, m, n = \{sm, s\}$, $t \in \{1, 2, \dots, E\}$, E 为纹理类别数;若 $t=E$, 则算法结束;否则 $t=t+1$, 转 Step 2.

从以上算法流程的描述中可见,算法中的 Step 2~Step 4 计算每一类纹理的 EHMM-HMT 参数,而 EHMM 参数的估计主要由 Step 4 完成.

2.5 最粗尺度的初分割

基于 EHMM-HMT 模型的分割方法是一种基于块的分割方法,该方法通过对每一类纹理分别估计出 EHMM-HMT 参数后,即可在最粗尺度上计算中心块 C 属于第 t 类纹理的似然 $L(C|\theta_t)$,其表达式为

$$L(C|\theta_t) = \max_{k_1, \dots, k_q} \{\pi_{k_C}^t \times \alpha_{k_C \rightarrow k_1}^t \times \beta_{k_C \rightarrow k_{II}}^t \times l_{k_1}^t(W_{B_1}) \times l_{k_{II}}^t(W_{B_{II}})\} \quad (7)$$

其中, $l_{k_1}^t(W_{B_1})$ 和 $l_{k_{II}}^t(W_{B_{II}})$ 分别代表图像块 B_i 在 I 类、II 类邻域块作用下,它属于第 t 类纹理的似然,它们可由公式(4)求得.下面给出最粗尺度上初分割算法的详细描述.

算法 1. 最粗尺度上的初分割算法.

输入:测试图像、EHMM-HMT 参数和纹理类别数 E ;

Step 1. 将测试图像分割成 16×16 (或 8×8)大小互不重叠的图像块,然后采用 db1 小波对每一个图像块做二维离散小波变换并分解成 4(或 3)层,得到各图像块的小波系数 $W_{B_i}, i=1,2,\dots,Q$;

Step 2. 将每一个图像块当作中心块 C 计算它们属于各类纹理(每一类纹理的参数 θ_t)的似然 $L(C|\theta_t)$,其中, $t=1,2,\dots,E, E$ 为纹理类别数;

- (1) 对每一个图像块分别按照第 t 类纹理的参数 HMT_{sm}^t 和 HMT_s^t 计算该图像块属于两种块隐状态(平滑和奇异)的似然 $l_{k_i}^t(W_{B_i})$,其中, $k_i=\{sm,s\}, i=1,2,\dots,Q$;
- (2) 结合第 t 类纹理的 EHMM 参数 $\pi_k^t, \alpha_{m,n}^t, \beta_{m,n}^t$,将每一个图像块当作中心块 C 按公式(7)计算该块属于第 t 类纹理的似然 $L(C|\theta_t)$;

Step 3. 将每一个图像块当作中心块 C ,分别比较中心块 C 属于各类纹理的似然 $L(C|\theta_t)$,并记

$$Label_C = \arg \left\{ \max_{t=1,2,\dots,E} [L(C|\theta_t)] \right\},$$

$label_C$ 即为最粗尺度上中心块 C 的纹理类别标记;

输出:最粗尺度的初分割结果.

由最粗尺度的初分割算法描述可见,该算法在最粗尺度(由剖分的图像块的大小决定)上是基于最大似然准则(maximum likelihood,简称 ML)来计算初分割的,它通过 EHMM-HMT 模型更精确地捕捉了纹理的宏观和微观特征,得到了区域一致性好、可靠性高的初分割结果.

3 基于 MSWHMT 模型求解各细尺度的初分割

3.1 Multi-States weighted HMT(MSWHMT)模型

对于多尺度的图像分割方法而言,在最粗尺度上得到的初分割往往区域一致性好,但其低分辨率必然导致边界保持效果差;而细尺度上的初分割由于分辨率较高,因而对边界有良好的感知能力,边界保持效果好.由此可见,在得到了最粗尺度上可靠的初分割后,如何计算各细尺度上的初分割是至关重要的.然而,由于 Lu 和 Carin 等人提出的方法^[13]在不增加计算复杂度的情况下仅能得到最粗尺度上的初分割(这里不妨设最粗尺度所对应的图像块大小为 16×16 ,则尺度大小为 $j=4$,此时,更细尺度上的图像块大小如 $8 \times 8, 4 \times 4$ 和 2×2 则分别对应尺度 j 取 3,2 和 1).也就是说,若我们要计算某个细尺度上的初分割则需重新估计该细尺度上的 HMM-HMT 参数.于是,每多计算一个尺度的初分割就需增加 1 倍于最粗尺度上的模型训练所需计算量.分析得知,运用 HMM-HMT 模型计算各个尺度 $j(j=1,2,\dots,L)$ 上的初分割,其模型训练的时间复杂度为 $O(Lmn(N_s^8/2^{2L}+1))$,其中, N_s 是块隐状态的个数, m, n 分别为训练图像的行和列, L 是最粗尺度的尺度大小.需要注意的是, EHMM-HMT 和 HMM-HMT 的时间复杂度是相同的.更重要的是,通过仿真实验我们发现,除了 HMM-HMT 和 EHMM-HMT 具有计算复杂度高的不足外,两模型在更精细尺度上的边界检测精度也不尽如人意.

为了降低 HMM-HMT 的计算复杂度,文献[9]提出利用在最粗尺度上计算初分割时得到的块隐状态联合概率来计算各细尺度上的初分割,定义了中心块 C 内子块(节点)的似然:

$$L_{sub}(C | \Theta_i) = p(B_C = k_C, B_I = k_I, B_{II} = k_{II})f(T_C | B_C = k_C, \Theta_i)f(T_I | B_I = k_I, \Theta_i)f(T_{II} | B_{II} = k_{II}, \Theta_i) \quad (8)$$

其中, $p(B_C = k_C, B_I = k_I, B_{II} = k_{II})$ 是计算最粗尺度初分割时得到的中心块与邻域块的块隐状态联合概率, 它通过最大化公式(7)得到, T_b 是与块 b 对应的小波系数四叉树, $f(T_b | B_b, \Theta_i)$ 是块 b 属于纹理 i 的似然. 由于中心块与邻域块的块隐状态联合概率描述了纹理图像中各图像块间的统计关系, 因此文献[9]中的方法反映了相邻图像块对中心图像块 C 的影响. 显然, 该方法有利于保持初分割的区域一致性, 但不利于提高对边界的感知能力. 我们的实验也表明, 对于绝大多数纹理图像, 文献[9]中的方法对边界检测的效果不如 EHMM-HMT 好.

分析 EHMM-HMT 模型可知, EHMM 不仅是对纹理的宏观统计规律性关系建模, 同时也是对纹理图像中各类型图像块的统计关系建模. 一方面, EHMM 参数中的块隐状态转移概率 $\alpha_{m,n}, \beta_{m,n}$ 可捕获图像块间宏观统计关系; 另一方面, EHMM 参数中的块隐状态概率 π_k 则是对平滑图像块和奇异图像块的统计估计. 尽管如此, EHMM-HMT 模型仍然有高时间复杂度和在细尺度上低边界检测精度的不足. 基于此, 本文提出了多状态加权 HMT (multi-states weighted hidden Markov tree, 简称 MSWHMT) 模型.

在 EHMM-HMT 参数估计过程中, 可分别得到第 t 类纹理的平滑图像块组 HMT 参数 HMT_{sm}^t 和奇异图像块组 HMT 参数 HMT_s^t . 于是, MSWHMT 模型首先利用两组参数 HMT_{sm}^t 和 HMT_s^t 计算除在最粗尺度 L 上的根节点以外的图像块内各节点属于块隐状态 k 的似然, 即计算各细尺度如 j 上节点 T_i^j 属于块隐状态 k 的似然 $I_k^t(W_i^j)$, 其中, $k=\{sm, s\}, i=1, 2, \dots, Q, Q_j$ 表示第 j 尺度上的小波系数节点个数, $j=1, 2, \dots, L-1$; 然后, 利用最粗尺度上的 EHMM-HMT 模型参数 π_k 计算细尺度 j 上节点 T_i^j 属于纹理 t 的似然 $I_{\theta_t}(W_i^j | \theta_t)$, 我们把该似然定义为

$$I_{\theta_t}(W_i^j | \theta_t) = f(W_i^j | \theta_t) = \pi_{sm}^t I_{sm}^t(W_i^j) + \pi_s^t I_s^t(W_i^j) \quad (9)$$

其中, $t=1, 2, \dots, E, E$ 为纹理类别数, θ_t 为第 t 类纹理的 EHMM-HMT 参数, 而似然 $I_{sm}^t(W_i^j)$ 和 $I_s^t(W_i^j)$ 分别由参数 HMT_{sm}^t 和 HMT_s^t 在四叉树上通过一次自下而上的扫描过程^[6,10]计算得到, 其表达式为

$$\begin{cases} I_{sm}^t(W_i^j) = p(W_i^j | k_{T_i^j} = sm) \\ I_s^t(W_i^j) = p(W_i^j | k_{T_i^j} = s) \end{cases} \quad (10)$$

其中, T_i^j 表示由图像块内的小波系数构成的四叉树上的一个节点, 即尺度 j 上以第 i 个节点为根节点的小波系数子树. 由 db1 小波对信号表示的局部性可知, T_i^j 对应着原图像(空域上)的一个图像块, 故与处理最粗尺度上的图像块的方法类似, 本文对四叉树上的每一个节点都联系了一个块隐状态变量. $k_{T_i^j}$ 表示节点 T_i^j 的块隐状态. W_i^j 表示小波系数子树 T_i^j 所包含的小波系数.

Table 2 Comparison of the time complexity for 3 models

表 2 3 种模型的时间复杂度比较

Models	Time complexity	Description of parameter
EHMM-HMT	$O(Lmn(N_s^8 / 2^{2L} + 1))$	L is the coarse scale, N_s is the number of the hidden states, m and n are pixel numbers of the image's row and the column directions.
HMT ^[10]	$O(mn)$	
Ref.[9]	$O(mn(N_s^8 / 2^{2L} + 1))$	
MSWHMT	$O(mn(N_s^8 / 2^{2L} + 1))$	

公式(9)中的 $I_{sm}^t(W_i^j)$ 和 $I_s^t(W_i^j)$ 分别表示节点 T_i^j 属于第 t 类纹理的平滑图像块和奇异图像块的似然, 本质上, 式中的 $I_{\theta_t}(W_i^j | \theta_t)$ 是对似然 $I_{sm}^t(W_i^j)$ 和 $I_s^t(W_i^j)$ 的线性优化, 称为多状态加权 HMT(MSWHMT). 由于该模型不再像 HMM-HMT 模型和 EHMM-HMT 模型那样必须在各个细尺度上分别训练模型参数后再计算初分割, 只需训练最粗尺度上的模型参数, 故 MSWHMT 的时间复杂度为 $O(mn(N_s^8 / 2^{2L} + 1))$.

3.2 基于 MSWHMT 模型计算各细尺度上的初分割

由公式(9)不难得得到基于 MSWHMT 模型各个细尺度上各节点属于每一类纹理的似然; 然后, 可采用 ML 准则计算初分割. 对于尺度 j 上第 i 个节点的类别标记 $Label_i^j$ 可表示为

$$Label_i^j = \arg \left\{ \max_{t \in \{1, 2, \dots, E\}} [l_{\theta_t}(W_i^j | \theta_t)] \right\} \quad (11)$$

其中, $t=1, 2, \dots, E$, E 为纹理类别数, $j=1, 2, \dots, L-1, L$ 是最粗尺度的尺度大小, θ_t 为第 t 类纹理的 EHMM-HMT 参数, $l_{\theta_t}(W_i^j | \theta_t)$ 由公式(9)可得.

我们将 MSHWMT, HMT, EHMM-HMT 模型和文献[9]中的方法进行了分析比较后认为,与 HMT 模型相比, MSHWMT 与 HMT^[6,10]一样, 只需要训练一次模型参数就可以计算各个细尺度上的初分割; 但不同的是, MSHWMT 在判别第 t 类纹理各个细尺度上各个节点的类别属性时, 它使用了在最粗尺度上训练 EHMM-HMT 模型参数得到的 π'_{sm} 和 π'_s 全局统计信息量, 通过公式(4)来计算该节点属于第 t 类纹理的似然. 因而, 它比 HMT 模型能够更好地提高各个细尺度上边界检测精度和初分割的可靠性. 我们知道, 对 EHMM-HMT 模型来说, 每增加一个细尺度的初分割就需要重新估计该细尺度上的 EHMM-HMT 模型参数, 这样不但增加了 1 倍的模型训练所需的计算量, 而且由块间的邻域关系来捕捉到的该细尺度上的宏观统计信息也未必比在最粗尺度上由 EHMM-HMT 模型捕捉的宏观统计信息来的可靠, 原因有两点:(1) 由于 EHMM-HMT 在细尺度上剖分的块随尺度变小而变小, 而细尺度上较小的块却不能提供足够多的基本信息, 于是基于较小的块计算出的似然可信度差, 最终导致在此基础之上训练得到的 EHMM 参数并不能准确地描述纹理的宏观统计规律性;(2) 由于纹理特征通常以观察者所选取尺度的不同而变化, 对图像分割而言, 一幅图像针对某特定的应用总存在其最合理的尺度^[16]. 与 EHMM-HMT 模型相比, MSHWMT 模型在计算各个细尺度上的初分割时只需要 EHMM-HMT 模型在最粗尺度上的模型训练参数, 因而 MSHWMT 模型极大地降低了时间复杂度; 其次, MSHWMT 模型舍弃了各个细尺度上块与邻域块间的联系, 消除了块邻域成员对中心块的影响, 不再通过描述块间的邻域关系来刻画该细尺度上的宏观统计信息, 而采用基于局部(图像块内)的 HMT 模型来捕捉其微观特征, 进而提高了该模型在各个细尺度上对区域间边界的感知能力. 由于 MSHWMT 保留了最粗尺度上用于描述平滑图像块和奇异图像块的全局统计信息, 同时又能像 HMT 模型那样在较细尺度上可描述图像块内的微观特征, 从而实现了对复杂纹理图像中各类型图像块的宏观估计与局部描述的有机结合. 与 HMT 相比, MSHWMT 模型增强了对不同类别纹理的判别能力, 在各细尺度上最终达到了减少区域边界误分的目的.

4 结合边界信息的多尺度贝叶斯融合策略

对于多尺度的图像分割方法而言, 若欲得到像素级的最终分割, 在多尺度融合过程中选用何种融合策略是至关重要的^[6,7,17]. 一方面, 粗尺度分割能够有效地获取到图像不同纹理区域的主体轮廓, 在同一类纹理区域内区域一致性好. 而对于细尺度而言, 由于图像块较小, 缺乏足够的统计信息, 导致细尺度上的初分割区域一致性不如粗尺度上的好, 因此建立的上下文模型应反映粗尺度的分割信息对细尺度分割合理的指导关系; 另一方面, 细尺度分割在不同纹理间边界处比较精确, 对边界变化的感知能力比粗尺度分割要强, 可以达到良好的边界保持效果. 对图像分割而言, 良好的区域一致性和有效的边界保持是一对难以调和的矛盾, 我们要做的就是依据不同的应用背景对两方面做折衷. 本文充分考虑了区域一致性和边界保持两方面的因素, 提出了结合边界信息的多尺度贝叶斯融合策略. 该策略在融合过程中提出了边界节点(在最细尺度上是像素)与非边界节点的概念, 对边界节点采用多尺度贝叶斯融合策略, 对非边界节点直接取粗尺度的分割结果.

4.1 边界的定义及其检测

图像上纹理区域的边界是指不同类别纹理区域间的结合处. 众所周知, 纹理区域的准确边界是很难获得的, 这是因为纹理不是单个像素的特征, 而是其所在区域的二阶或高阶统计特征. 多年来, 国内外学者提出了多种边界检测方法, 其中以 Candy^[18]提出的边界检测算子最为流行. Yhann 等人^[3]认为, 高分辨率图像的边缘依赖于低分辨率图像边缘所包含的特征信息, 提出了一种多尺度边界定位方法. 该方法通过反复迭代最终收敛到真实的边界, 其计算复杂度较高.

本文借鉴文献[3]方法的思想, 提出了一种简单、有效的边界检测方法. 主要思想是, 将高分辨率图像边缘看作是低分辨率图像边缘的反映, 将包含在低分辨率(粗尺度)图像边缘中的全局信息去指导高分辨率图像中的边

界点的跟踪.考虑到复杂度因素,本文检测边界时仅用到了初分割时计算得到的似然及其初分割结果等信息来定位边界.

考虑到基于 MSWHMT 得到的是多尺度(多分辨率)的初分割结果,即粗尺度 j 上的一个节点对应着细尺度 $j-1$ 上的 4 个节点,故本文先对粗尺度 j 上的初分割以点对点按 1:4 扩展,使其与细尺度 $j-1$ 上的初分割的行列相同.这样,粗细相邻尺度上的各个节点一一对应.下面给出本文对纹理边界的定义.

在粗尺度 j 上某节点 s 若满足以下两条中的任一条即为边界节点:

1. 节点 s 的 8 邻域存在与节点 s 不同纹理类别的节点;
2. 节点 s 的标记 $label_s$ 与其细尺度 $j-1$ 上子节点 t 的标记 $label_t$ 不一致,即随着分辨率的提高,在细尺度上检测到了新的“边界”.为了确定它不是伪边界,则要求同时满足如下两个子条件:
 - 2.1. 对于粗尺度上节点 s 的似然 $l_s = (l_s^1, l_s^2, \dots, l_s^E)$,取 l_s 的各分量中次小者为候选纹理,且候选纹理类别与细尺度上子节点 t 的纹理类别 $label_t$ 一致;
 - 2.2. 以细尺度 $j-1$ 上子节点 t 为中心划 3×3 大小的窗口(该窗口包含了子节点 t 及其 8 邻域,不妨记子节点 t 及其 8 邻域为 $NB(t)$),将该窗口联系一个窗口似然矢量 $l_{NB(t)} = (l_1^{Label_t}, \dots, l_4^{Label_t}, l_5^{Label_t}, l_6^{Label_t}, \dots, l_9^{Label_t})$,其中,各分量(如 $l_1^{Label_t}$ 等)的下标代表窗口内 9 个节点的序号,序号 5 对应窗口的中心子节点 t ,序号 1~序号 4 和序号 6~序号 9 对应子节点 t 的 8 邻域;同理,对粗尺度 j 作以上处理,并将以子节点 s 为中心的窗口联系一个窗口似然矢量 $l_{NB(s)} = (l_1^{Label_s}, \dots, l_4^{Label_s}, l_5^{Label_s}, l_6^{Label_s}, \dots, l_9^{Label_s})$.则子节点 t 的窗口似然矢量 $l_{NB(t)}$ 的方差比节点 s 的窗口似然矢量 $l_{NB(s)}$ 的方差要大.即

$$var(l_1^t, \dots, l_4^t, l_5^t, l_6^t, \dots, l_9^t) > var(l_1^s, \dots, l_4^s, l_5^s, l_6^s, \dots, l_9^s) \quad (12)$$

其中, $var(l_1^t, \dots, l_4^t, l_5^t, l_6^t, \dots, l_9^t)$ 定义为

$$\begin{cases} var(l_1^t, \dots, l_4^t, l_5^t, l_6^t, \dots, l_9^t) = \frac{1}{9} \sum_{i=1}^9 (l_i^t - u)^2 \\ u = \frac{1}{9} \sum_{i=1}^9 l_i^t \end{cases} \quad (13)$$

条件 2.2 中的 $l_1^{Label_t}$ 是一个标量,它表示节点 t 的 8 邻域窗口内序号为 1 的节点属于纹理类别 $label_t$ 的似然.分析条件 2.1 和条件 2.2 可知,它们分别从不同的角度来定位边界,条件 2.1 通过比较各类纹理(除节点 s 初分割后的纹理类别)的可靠性并结合细尺度的初分割信息来定位边界,条件 2.2 则通过比较粗、细尺度上节点的 8 邻域内各节点似然的方差(稳定性)来定位边界.

4.2 结合边界信息的多尺度贝叶斯融合策略

本文采用 Choi 等人在文献[6]中提出的基于最大后验概率(maximum a posteriori,简称 MAP)的多尺度融合策略,该策略同时考虑了上下文信息 $v^{(n)}$ 和图像特征信息 $y^{(n)}$ 对类别标记 $x^{(n)}$ 的作用,其分割依据是

$$\hat{x}^{(n)} = \arg \max_{x^{(n)}} p_{x^{(n)}|v^{(n)}, y^{(n)}}(x^{(n)} | \hat{v}^{(n)}, y^{(n)}) \quad (14)$$

式中, $p_{x^{(n)}|v^{(n)}, y^{(n)}}(x^{(n)} | \hat{v}^{(n)}, y^{(n)})$ 可由贝叶斯公式可得:

$$p_{x^{(n)}|v^{(n)}, y^{(n)}}(x^{(n)} | \hat{v}^{(n)}, y^{(n)}) = \frac{p_{x^{(n)}}(x^{(n)}) p_{v^{(n)}|x^{(n)}}(\hat{v}^{(n)} | x^{(n)}) f(y^{(n)} | x^{(n)})}{\sum_{t=1}^E p_{x^{(n)}}(t) p_{v^{(n)}|x^{(n)}}(v^{(n)} | x^{(n)}) f(y^{(n)} | x^{(n)} = t)} \quad (15)$$

其中, $p_{x^{(n)}}(t)$ 是类别 t 在尺度 n 上的概率质量函数(probability mass function,简称 PMF); $f(y^{(n)}|t)$ 是图像块 $y^{(n)}$ 属于类别 t 的似然.本文对上下文信息 $v^{(n)}$ 的定义与 HMTseg 方法中介绍的一致,即 $v^{(n)} = \{P, NP\}$,其中, P 代表父节点, NP 代表 P 的 8 邻域各节点, NP 的类别按多数投票方法决定.

基于以上分析,本文综合区域一致性和边界保持两方面的因素,提出了结合边界信息的多尺度贝叶斯融合策略.该策略在融合过程中对边界节点采用基于 MAP 的多尺度融合策略^[7],以增强对边界节点的感知能力;对非

边界节点直接取粗尺度的分割结果,有利于细尺度上的融合结果保持区域一致性。显然,结合边界信息的多尺度贝叶斯融合策略不同于 HMTseg 方法中基于 MAP 的融合策略,前者是一个以边界检测为手段、以保持边界为目标的基于上下文的多尺度贝叶斯融合策略。

5 仿真实验及结果分析

本文将实验分为 3 个部分,第 5.1 节测试 EHMM-HMT 模型和 HMM-HMT 模型在最粗尺度上的初分割效果,第 5.2 节测试 EHMM-HMT 模型、HMT 模型、MSWHMT 模型和文献[9]中的方法在细尺度上的边界检测效果及其耗时,第 5.3 节针对 HMTseg 方法和本文方法 EHMM-HMT(boundary based+MAP)设计了两种方法,并分别给出它们对微纹理、宏纹理及其两者的混合纹理的分割性能。以下实验所用的各纹理图像均选自 Brodatz 标准纹理库里的纹理,该纹理库中的 112 张纹理图大小均为 640×640 像素,文中训练数据取自纹理图像左上角 256×256 大小的数据,测试数据则统一取其右下角 512×512 大小的数据。

5.1 最粗尺度的初分割实验及分析

本节的实验目的是测试并比较 EHMM-HMT 模型和 HMM-HMT 模型在最粗尺度上的初分割性能。我们对微纹理、宏纹理及其混合纹理都做了仿真,如图 4 所示,有:

mosaic 1(D9/D68/D16/D21), mosaic 2(D42/D63/D91/D71), mosaic 3(D95/D9/D68/D91),
mosaic 4(D9/D68/D16/D21/D4), mosaic 5(D75/D95/D35/D56/D5), mosaic 6(D75/D9/D68/D95/D42)

显然,mosaic 1 和 mosaic 4 由微纹理合成,mosaic 2 和 mosaic 5 由宏纹理合成,mosaic 3 和 mosaic 6 由微纹理和宏纹理混合合成。由图 4 我们可以看出,微纹理的纹理特征比较“精细”,宏纹理的纹理基元比较大,结构特征比较显著。

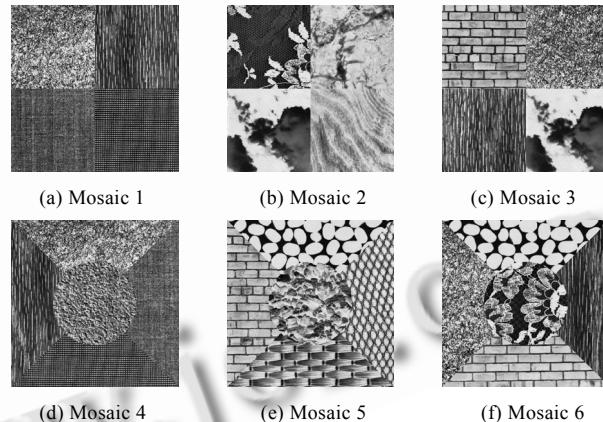


Fig.4 4-class and 5-class test texture images synthesized by micro-texture,
macro-texture and the hybrid texture images

图 4 由微纹理、宏纹理及其混合纹理图像人工合成的 4 类和 5 类测试纹理图像

表 3 给出了 EHMM-HMT 与 HMM-HMT 在最粗尺度上的初分割精度(正确率:%)。由表 3 可见,对于大多数测试纹理,EHMM-HMT 在最粗尺度的初分割性能比 HMM-HMT 要优。通过分析可知,由于 EHMM-HMT 对中心块与 8 邻域内的所有块建立直接联系,增强了模型对纹理图像的宏观统计关系的描述能力,进而提高了粗尺度上的初分割性能。

Table 3 Comparison of the segmentation results between EHMM-HMT and HMM-HMT on the coarsest scale
表 3 EHMM-HMT 与 HMM-HMT 在最粗尺度上初分割性能比较

Models	Micro-Mosaics		Macro-Mosaics		Hybrid mosaics	
	Mosaic 1	Mosaic 4	Mosaic 2	Mosaic 5	Mosaic 3	Mosaic 6
HMM-HMT	99.04	95.67	90.72	87.98	93.16	84.37
EHMM-HMT	99.24	95.29	91.41	89.16	92.29	84.48

5.2 各细尺度上边界检测实验及分析

本节将着重关注 EHMM-HMT,HMT,MSWHMT 和文献[9]中的方法在细尺度上初分割的边界检测性能.以第 5.1 节的测试图像为例,分别运用 EHMM-HMT,HMT,MSWHMT 和文献[9]中的方法计算各细尺度上的初分割,然后给出了它们的边界检测精度和所耗时间.由于基于小波域的 EHMM-HMT 在最细尺度上剖分得到的图像块大小为 2×2 ,此时,基于块的 HMT 模型退化为 IM 模型^[10](independent mixture model),故本文在表 4 中未给出其结果,并将其边界检测精度和耗时分别标记为“ \times ”和“/”.本部分实验的硬件测试平台是: Pentium 4 CPU, 主频 2.9GHz, 内存 1.0GB; 软件平台为: Windows XP 操作系统和 Matlab 7.3.0.

Table 4 Comparison of the boundary detection precision and the time cost on each scale

表 4 对微纹理、宏纹理及其混合纹理在各尺度上的边界检测精度及耗时

Mosaics		Block size	EHMM-HMT		Ref.[9]		HMT	MSWHMT	
			Boundary detection precision (%)	Time cost (s)	Boundary detection precision (%)	Time cost (s)	Boundary detection precision (%)	Boundary detection precision (%)	Time cost (s)
Micro-mosaics	Mosaic 1	16×16	82.51	464.25	82.51	435.92	100	100.00	464.25
		8×8	86.13	453.88	73.60	30.51	91.80	92.00	3.43
		4×4	65.61	1 524.00	60.74	30.51	71.81	72.46	3.43
		2×2	\times	/	50.55	30.51	49.70	50.47	3.43
	Mosaic 4	16×16	82.24	591.94	82.24	516.09	80.93	83.55	591.94
		8×8	83.19	543.18	68.31	38.08	72.79	72.43	5.48
		4×4	63.76	1 964.03	51.67	38.08	57.01	57.02	5.48
		2×2	\times	/	39.49	38.08	37.32	37.62	5.48
Macro-mosaics	Mosaic 2	16×16	69.95	228.05	69.95	276.50	84.15	81.97	228.05
		8×8	61.60	472.54	61.07	26.54	69.33	72.27	3.06
		4×4	51.52	1 074.40	54.81	26.54	52.15	53.10	3.06
		2×2	\times	/	47.28	26.54	45.97	46.17	3.06
	Mosaic 5	16×16	68.15	462.33	68.15	459.29	70.71	70.76	362.33
		8×8	57.18	523.81	56.95	13.90	63.35	61.54	4.64
		4×4	50.06	1 912.22	50.20	13.90	47.78	48.09	4.64
		2×2	\times	/	39.71	13.90	38.53	38.65	4.64
Hybrid mosaics	Mosaic 3	16×16	63.39	369.05	63.39	363.86	96.90	98.36	369.05
		8×8	79.20	508.25	52.27	27.76	83.53	85.87	4.07
		4×4	70.62	1 179.20	58.37	27.76	78.78	77.74	4.07
		2×2	\times	/	57.63	27.76	59.26	59.40	4.07
	Mosaic 6	16×16	63.71	491.79	63.71	484.65	73.89	74.06	491.79
		8×8	49.21	630.49	49.82	34.72	63.84	62.39	4.92
		4×4	43.75	1 502.10	43.51	34.72	55.25	57.55	4.92
		2×2	\times	/	44.94	34.72	45.08	47.51	4.92

从表 4 可以看出,在算法时间开销方面,MSWHMT 模型比 EHMM-HMT 模型降低不少,前者所耗时间仅是后者的 $1/6\sim1/4$,比文献[9]中的方法也有所降低;在边界检测精度方面,MSWHMT 模型对边界区分割的正确率比 EHMM-HMT 模型有显著提高,尤其是对 mosaic 1 和 mosaic 3 MSWHMT 模型的边界检测精度在最粗尺度上达到了 98%以上,比 EHMM-HMT 模型的边界检测精度提高了 20%以上.另外,与 HMT 模型相比,MSWHMT 模型也有一定优势.同时,我们也注意到,无论是对微纹理、宏纹理还是对二者混合的测试纹理,文献[9]中方法的边界检测精度远不如 MSWHMT 模型高,而且在多数尺度上也不如 EHMM-HMT 模型高.

实验结果表明,EHMM-HMT 模型在更精细的尺度(比如 $8\times 8, 4\times 4$ 和 2×2)上重新估计 EHMM-HMT 参数不

仅增加了算法的运行时间,而且得到的边界检测精度不尽如人意,在绝大多数尺度上,该模型对边界检测的效果明显比MSWHMT模型的效果差.该实验结果与我们在第3.1和第3.2节的分析是一致的.在边界检测效果方面,MSWHMT模型远比文献[9]中的方法和EHMM-HMT模型要好,该实验结果与我们在第3.2节的分析也是一致的.由于MSWHMT通过对多个状态的HMT统计加权来计算细尺度的似然,保留了描述平滑图像块和奇异图像块的全局统计信息,实现了对该两类图像块的宏观估计与局部描述的有机结合,在各细尺度上达到了减少区域边界误分的目的,因而在细尺度上对边界检测精度方面比HMT性能更优.

综合边界检测性能和时间复杂度两方面因素可见,本文提出的MSWHMT模型比EHMM-HMT模型、HMT模型和文献[9]中的方法性能要好.

5.3 纹理分割实验及分析

本节针对HMTseg方法和本文方法EHMM-HMT(boundary based+MAP)设计了两种方法,以便对比分析本文提出的初分割模型和融合策略的性能,我们给出了各方法的具体结构(见表5).

Table 5 Structure of each algorithm

表 5 各方法的具体结构

Models	Raw segmentation model	Fusion strategy
HMTseg ^[7]	HMT ^[6,10]	MAP ^[6,10,17]
HMT (boundary based+MAP)	HMT ^[6,10]	Boundary based+MAP
EHMM-HMT (MAP)	EHMM-HMT and MSHWT	MAP ^[6,10,17]
EHMM-HMT (boundary based+MAP)	EHMM-HMT and MSHWT	Boundary based+MAP

5.3.1 微纹理分割实验及分析

我们选择了5幅由2~6类不同的纹理样图合成的测试纹理,如图5所示.有mosaic 7(D16/D24), mosaic 8(D16/D24/D68), mosaic 9(D9/D19/D16/D32/D68/D21),其中,mosaic 1和mosaic 4详见第5.1节.

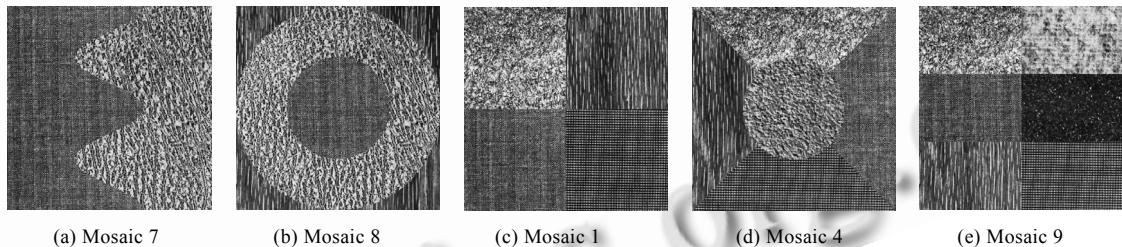


Fig.5 2-class to 6-class test texture images synthesized by the micro-texture images

图5 由微纹理图像人工合成的2~6类测试纹理图像

从微纹理的分割结果(表6(正确率: %))中我们可以看出,对于mosaic 7和mosaic 1,本文方法的分割正确率相比HMTseg方法要低,比HMT(boundary based+MAP)和EHMM-HMT(MAP)略高;对于mosaic 8,mosaic 4和mosaic 9,本文方法的分割正确率比HMTseg方法提高1.5%~5.0%,比HMT(boundary based+MAP)提高1.0%~4.0%,比EHMM-HMT(MAP)提高幅度较大.

Table 6 Comparison of the performances of four algorithms

表 6 各分割方法性能比较

Methods/Mosaic	Mosaic 7	Mosaic 8	Mosaic 1	Mosaic 4	Mosaic 9
HMTseg ^[6]	99.16	96.31	99.69	92.80	94.91
HMT (boundary based+MAP)	98.95	96.57	99.48	95.75	95.78
EHMM-HMT (MAP)	99.03	97.08	98.45	92.31	88.71
EHMM-HMT (boundary based+MAP)	99.18	98.05	99.32	98.07	97.09

从视觉效果上看,如图6所示,在区域一致性方面,本文方法和HMT (boundary based+MAP)方法的区域一致

性比其余方法要好。原因有两点:一是这两种方法在融合过程中都采用了本文提出的结合边界信息的贝叶斯融合策略;二是微纹理的纹理基元比较“精细”,适合用 HMT 模型来描述微纹理的特征。在边界保持方面,HMTseg 方法比本文方法稍有优势。综合区域一致性和边界保持两方面因素,本文方法相比其他 3 种方法效果要好,特别是对于多类如 5 类和 6 类合成纹理的分割优势明显。

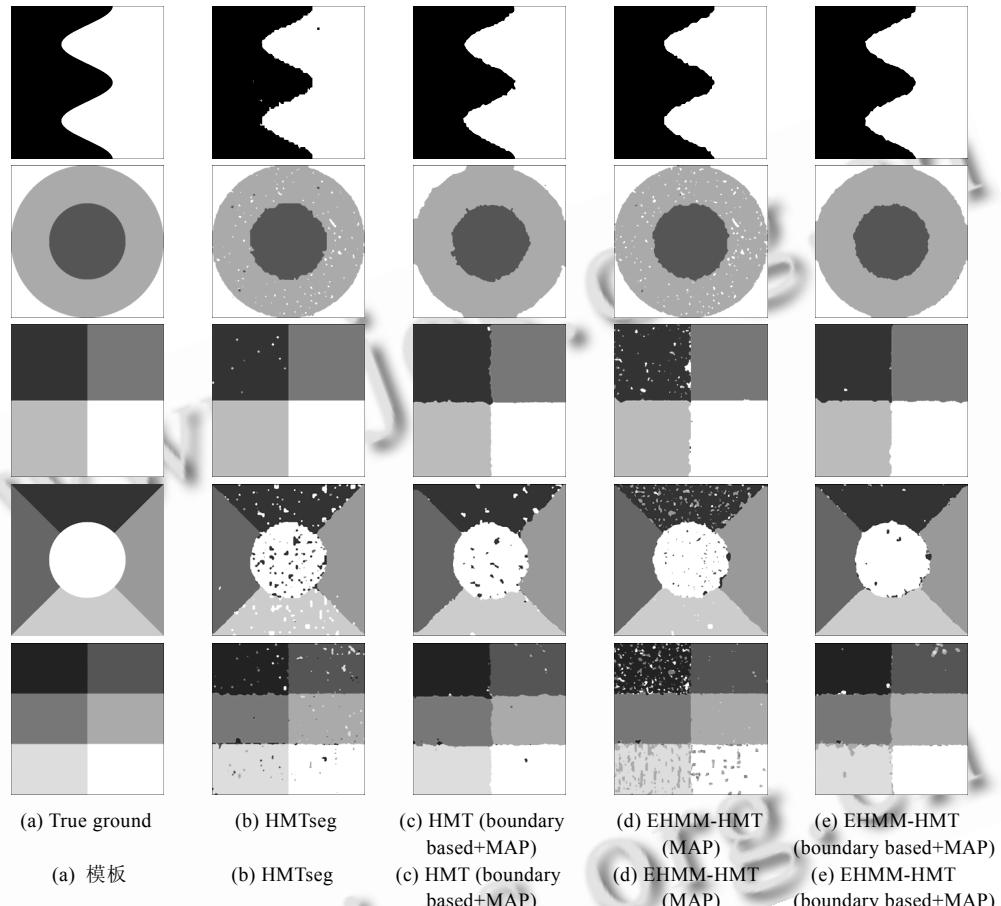


Fig.6 Comparison of the segmentation results of each algorithm for micro-mosaics

图 6 不同方法对微纹理的分割结果比较

5.3.2 微纹理分割实验及分析

我们选择了由 2~6 类不同的宏纹理样图合成的测试纹理,如图 7 所示。有 mosaic 10(D42/D91),mosaic 11(D56/D75/D95),mosaic 12(D76/D75/D95/D35/D56/D5),其中,mosaic 2 和 mosaic 5 详见第 5.1 节。从图 7 中我们注意到,纹理 D42 和 D91 与纹理 D75,D35 不同,纹理在不同区域表现出迥然不同的纹理特征,图像中的灰度在空间上分布很不均匀,因此对含有此类特征的测试图像设计分割算法是一项极具挑战性的研究工作。

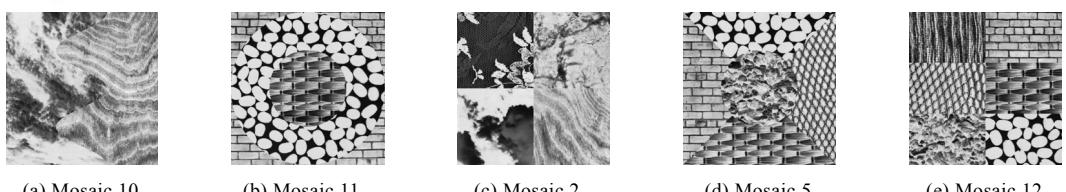


Fig.7 2-Class to 6-class test texture images synthesized by the macro-texture images

图 7 由宏纹理图像人工合成的 2~6 类测试纹理图像

由表 7(正确率:%)可以看出,对宏纹理的分割,本文方法的分割正确率比 HMTseg 方法和 HMT (boundary based+MAP)方法提高了 7%~30%,比 EHMM-HMT(MAP)方法提高了 2%~20%.同时也注意到,随着测试纹理类别数的增加,本文方法优势更显著,比如对 6 类测试纹理 mosaic 12 的分割,本文方法分割正确率比 HMTseg 方法提高了 39 个百分点.另外从图 8 中可以看出,在区域一致性方面和边界保持方面,本文方法比其余方法都要好.这除了本文方法采用了结合边界信息的贝叶斯融合策略以外,更重要的是它采用了 EHMM-HMT 模型和 MSWHMT 模型.EHMM-HMT 模型比 HMT 能够更好地捕捉图像的宏观(全局)和微观(局部)的纹理特征,进而提高了初分割的可靠性;而 MSWHMT 模型实现了对复杂纹理图像中平滑图像块和奇异图像块的宏观估计与局部描述的有机结合.与 HMT 相比,该模型增强了对不同类别纹理的判别能力,在各细尺度上最终达到了减少区域边界误分的目的.

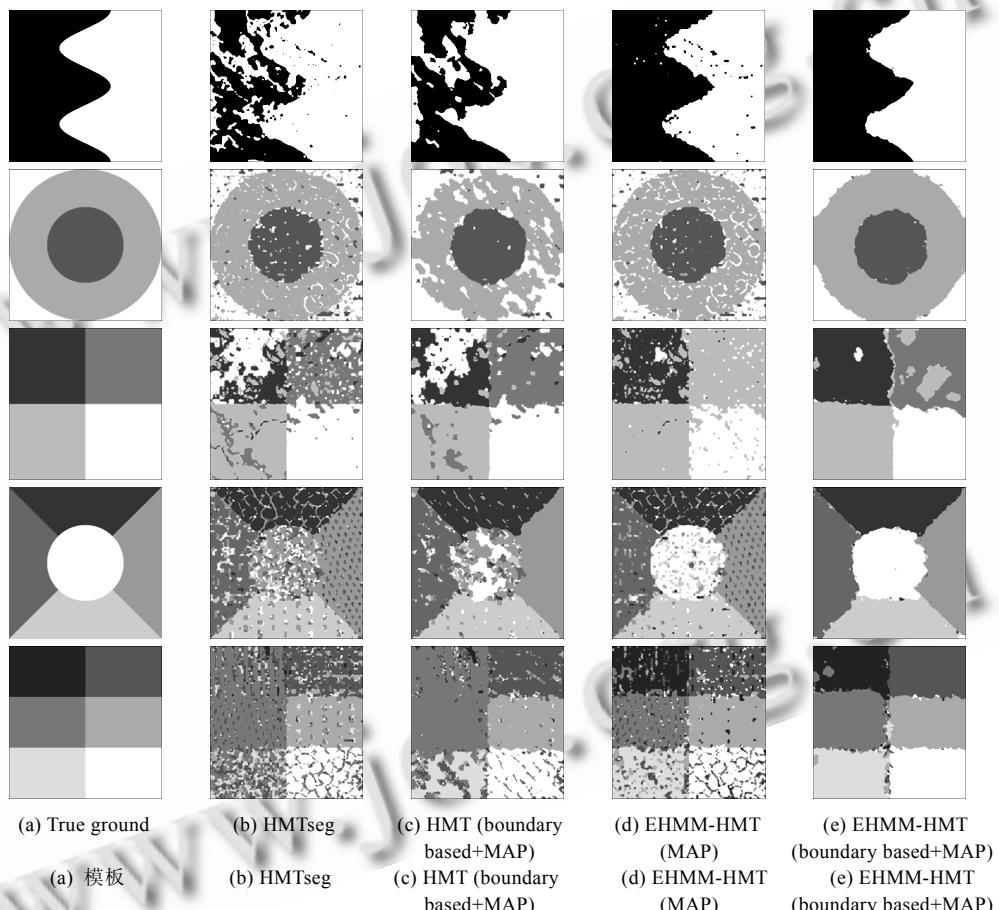


Fig.8 Comparison of the segmentation results of four algorithms on the macro-texture images

图 8 4 种方法对宏纹理图像的分割结果比较

Table 7 Comparison of the performances of four algorithms

表 7 4 种分割方法性能比较

Methods/Mosaic	Mosaic 10	Mosaic 11	Mosaic 2	Mosaic 5	Mosaic 12
HMTseg ^[6]	84.10	88.72	73.15	65.35	54.78
HMT (boundary based+MAP)	85.34	84.66	79.42	79.11	68.06
EHMM-HMT (MAP)	96.96	88.07	66.15	79.46	75.23
EHMM-HMT (boundary based+MAP)	98.10	95.24	89.63	95.48	93.55

5.3.3 混合纹理的分割实验及分析

混合纹理分割测试中每个测试纹理包含了微纹理和宏纹理,如图 9 所示.有 mosaic 13(D19/D91), mosaic 14(D75/D42/D56),mosaic 15(D42/D76/D9/D108/D95/D16),其中,mosaic 3 和 mosaic 6 详见第 5.1 节.

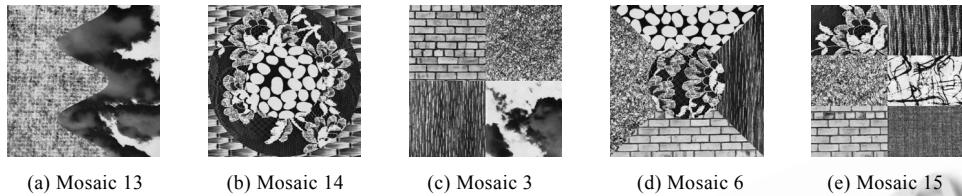


Fig.9 2-Class to 6-class the hybrid test texture images synthesized by the micro-texture and the macro-texture images

图 9 由微纹理和宏纹理图像人工合成的 2~6 类混合测试纹理图像

由图 10 和表 8(正确率:%)可看出,本文方法分割混合测试纹理时,在纹理类别数比较少的情况下分割正确率能达到 95%以上,但对纹理类别数较多(如 5 类和 6 类)的测试纹理,分割正确率只能达到 80%左右,但相比 HMTseg 方法亦有较大幅度的提高.对于 mosaic 14 和 mosaic 6,本文方法分割结果不如 HMT(boundary based+MAP)方法好,而两者的融合策略是一致的.分析原因后发现:一方面,这些宏纹理的纹理基元表现形式多样,且分布无明显的规律,比如纹理 D42 中部分纹理区域与 D75 纹理很相似;另一方面,对于此类宏纹理,模型训练阶段选取的训练数据往往与测试阶段选取的测试数据有较大差异,导致模型训练失败.但是,综合本节的测试结果可以看出,对混合纹理的分割本文方法仍具有一定的优势.

Table 8 Comparison of the performances of each algorithm

表 8 各分割方法性能比较

Methods/Mosaic	Mosaic 13	Mosaic 14	Mosaic 3	Mosaic 6	Mosaic 15
HMTseg ^[10]	96.70	85.76	92.85	80.94	70.76
HMT (boundary based +MAP)	96.86	89.43	94.72	89.63	75.76
EHMM-HMT (MAP)	97.37	84.65	92.91	59.52	70.38
EHMM-HMT (boundary based +MAP)	98.08	85.47	95.27	87.92	79.70

6 结 论

本文在充分考虑纹理图像的宏观和微观特性的基础上,提出了基于 EHMM-HMT 和 MSWHMT 的多尺度贝叶斯纹理图像分割方法.EHMM-HMT 模型从宏观和微观两个角度对纹理特征建模:在宏观上,通过 EHMM 的邻域结构加强了对图像块间联系的描述,更好地实现了对纹理图像呈现出的统计规律性建模;在微观上,通过小波域的 HMT 对图像块内的纹理特征建模.在计算各细尺度的初分割过程中,本文在不增加计算复杂度的情况下将最粗尺度上的 EHMM 参数和与块隐状态相联系的 HMT 参数有机结合,提出了 MSWHMT 模型.与其他方法相比,该模型在各细尺度上得到了更优的边界检测精度.最后,采用结合边界信息的多尺度贝叶斯融合策略得到了像素级的最终分割结果.本文针对 HMTseg 方法和 EHMM-HMT(boundary based+MAP)设计了 2 种对比方法,并测试了各方法对微纹理、宏纹理及其混合纹理的分割性能.实验表明,与 HMTseg,HMT(boundary based+MAP)和 EHMM-HMT(MAP)方法相比,本文的方法不仅对微纹理图像有好的分割效果,对宏纹理图像也达到了较优的分割性能.

尽管本文方法对各类型的纹理均取得了较好的分割效果,但是该方法还存在不足和需要改进的地方.比如,本文方法采用了基于小波域的 HMT,而二维离散小波变换对图像分解的方向有限.为进一步提高对图像块内(微观)特征的建模准确度,可采用其他方向信息表示更丰富的变换域 HMT 模型等.此外,还需研究如何在保证分割精度的前提下降低 EHMM-HMT 模型训练的时间复杂度,进一步提高算法运行速度.

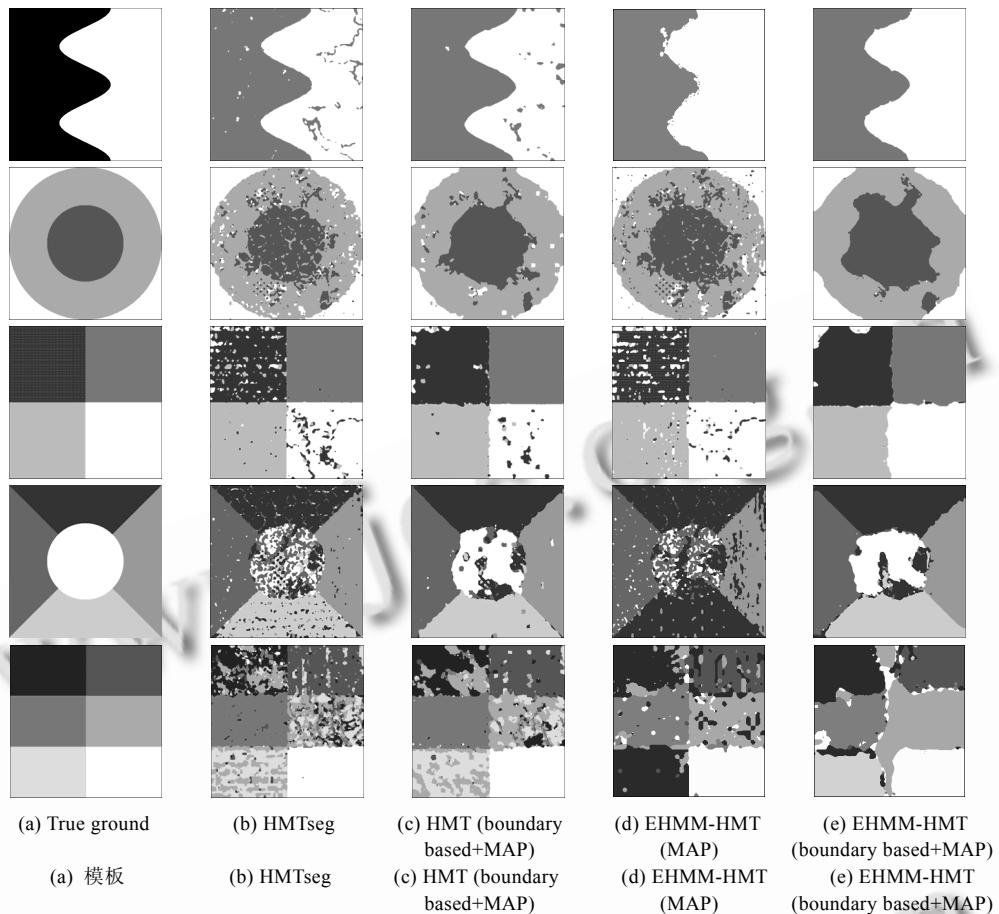


Fig.10 Comparison of the segmentation results of four algorithms on the hybrid texture images

图 10 4 种方法对混合纹理的分割结果比较

References:

- [1] Tuceryan M, Jain AK. Texture Analysis-Handbook of Pattern Recognition and Computer Vision. 2nd ed., Singapore: World Scientific Publishing Company, 1998. 207–248.
- [2] He Y, Luo YP, Hu DC. Unsupervised texture segmentation based on geodesic active regions. Journal of Software, 2007,18(3): 592–599 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/18/592.htm> [doi: 10.1360/jos180592]
- [3] Yhann SR, Young TY. Boundary localization in texture segmentation. IEEE Trans. on Image Processing, 1995,4(6):849–856. [doi: 10.1109/83.388089]
- [4] Bouman CA, Shapiro M. A multiscale random field model for Bayesian image segmentation. IEEE Trans. on Image Processing, 1994,3(2):162–177. [doi: 10.1109/83.277898]
- [5] Unser M, Eden M. Multiresolution feature extraction and selection for texture segmentation. IEEE Trans. on Pattern Analysis and Machine Intelligence, 1989,11(7):717–728. [doi: 10.1109/34.192466]
- [6] Choi H, Baraniuk RG. Multiscale image segmentation using wavelet domain hidden Markov models. IEEE Trans. on Image Processing, 2001,10(9):1309–1321. [doi: 10.1109/83.941855]
- [7] Fan GL, Xia XG. A joint multi-context and multi-scale approach to Bayesian image segmentation. IEEE Trans. on Geosciences and Remote Sensing, 2001,39(12):2680–2688. [doi: 10.1109/36.975002]
- [8] Liang KH, Tjahjadi T. Adapitve scale fixing for multiscale texture segmentation. IEEE Trans. on Image Processing, 2006,15(1): 249–256. [doi: 10.1109/TIP.2005.860340]

- [9] Joong HW, Pyun K, Robert MG. Hidden Markov multi-resolution texture segmentation using complex wavelets. In: Proc. of the 10th Int'l Conf. on Telecommunications, Vol.2. 2003. 1624–1630. <http://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=8474>
- [10] Crouse MS, Nowak RD, Baraniuk RG. Wavelet-Based statistical signal processing using hidden Markov models. IEEE Trans. on Signal Processing, 1998,46(4):886–902. [doi: 10.1109/78.668544]
- [11] Hou YH, Song JP, Zhou FN. A new document segmentation based on subbands by wavelet-domain hidden Markov tree models. Chinese Journal of Electronics, 2002,30(8):1180–1183 (in Chinese with English abstract).
- [12] Li J, Najimi A, Gray RM. Image classification by a two-dimensional hidden Markov model. IEEE Trans. on Signal Processing, 2000,48(2):517–533. [doi: 10.1109/78.823977]
- [13] Lu JL, Carin L. HMM-Based multiresolution image segmentation. In: Proc. of the IEEE Int'l Conf. on Acoustics, Speech, and Signal Processing. 2002. 3357–3360. <http://ieeexplore.ieee.org/xpl/tocresult.jsp?isnumber=21686>
- [14] Shannon CE. A mathematical theory of communication. Bell System Technical Journal, 1948,27:379–423.
- [15] Thomas MC, Joy AT. Elements of Information Theory. 2nd ed., New York: John Wiley & Sons, Inc., 1991. 30–35.
- [16] Ma WY, Manjunath BS. EdgeFlow: A technique for boundary detection and image segmentation. IEEE Trans. on Image Processing, 2000,9(8):1375–1388. [doi: 10.1109/83.855433]
- [17] Jiao LC, Zhang XR, Hou B, Wang S, Liu F. Intelligent SAR Image Processing and Interpretation. Beijing: Science Press, 2008. 505–536 (in Chinese).
- [18] Canny J. A computational approach to edge detection. IEEE Trans. on Pattern Analysis and Machine Intelligence, 1986,18(8):679–698. [doi: 10.1109/TPAMI.1986.4767851]

附中文参考文献:

- [2] 何源,罗予频,胡东成.基于测地线活动区域模型的非监督式纹理分割.软件学报,2007,18(3):592–599. <http://www.jos.org.cn/1000-9825/18/592.htm> [doi: 10.1360/jos180592]
- [11] 侯玉华,宋锦萍,周福娜.基于小波域隐马尔科夫模型的文本图像子带分割方法.电子学报,2002,30(8):1180–1183.
- [17] 焦李成,张向荣,侯彪,王爽,刘芳.智能 SAR 图像处理与解译.北京:科学出版社,2008.505–536.



陈蓉伟(1982—),男,重庆忠县人,硕士,主要研究领域为图像理解,智能信息处理.



刘芳(1963—),女,教授,博士生导师,CCF高级会员,主要研究领域为网络智能信息处理,智能图像处理,模式识别.



郝红侠(1980—),女,博士,主要研究领域为多尺度几何分析,智能图像处理.