

中图分类号: TP391.41 文献标志码: A 文章编号: 1006-8961(2011)10-1818-08

论文索引信息: 杨关, 冯国灿, 陈伟福, 邹小林. 纹理分析中的图模型 [J]. 中国图象图形学报, 2011, 16(10): 1818-1825

## 纹理分析中的图模型

杨关, 冯国灿, 陈伟福, 邹小林

(中山大学数学与计算科学学院, 广州 510275)

**摘要:** 纹理作为一种重要的视觉特征, 广泛应用于图像分析。高斯图模型(GGM)可以很好地描述有交互作用的高维数据, 因此可用来建立图像纹理模型。根据纹理特征的局部马尔可夫性和高斯变量的条件回归之间的关系, 将复杂的模型选择转变为较简单的变量选择, 应用惩罚正则化技巧同步选择邻域和估计参数。提取基于图模型的纹理特征分析纹理, 实验显示了很好的效果。因此, 利用高斯图模型来构建纹理模型有很好的发展前景。

**关键词:** 高斯图模型; 模型选择; 纹理合成; 纹理分类; 纹理分割

## Graphical models in texture analysis

Yang Guan, Feng Guocan, Chen Weifu, Zou Xiaolin

(School of Mathematical and Computational Science, Sun Yat-sen University, Guangzhou 510275 China)

**Abstract:** Texture is one of the important visual features in image analysis. Gaussian graphical models (GGM) have good prospective, and are applied to construct the texture model. The structure of the GGM is explored by the connection between the local Markov property of texture features and the conditional regression of Gaussian random variables. Thus, the model selection can be converted to select variables. The technique of penalty regularization provides many methods for variable selection and parameter estimation. Furthermore, the methods of penalty regularization conduct neighborhood selection and parameter estimation simultaneously. The texture feature is extracted and applied in texture analysis.

**Keywords:** Gaussian graphical models; model selection; texture synthesis; texture classification; texture segmentation

## 0 引言

纹理是图像的一种非常重要的属性。它是图像中特征值强度的某种局部重复模式的宏观表现。因此, 纹理是一种重要的视觉信息, 是图像中普遍存在而又难以描述的特征。

作为纹理研究的主要内容, 纹理分类和分割问题一直是人们关注的焦点, 涉及模式识别、应用数学、统计学、神经生理学、神经网络等多个研究领域。

纹理特征提取是成功进行图像纹理描述、分类与分割的关键环节, 纹理特征的提取直接影响后续处理的质量。提取的纹理特征维数不大、鉴别能力强、稳健性好, 且提取过程计算量小。纹理特征主要包括粗糙度、方向性、对比度和规律性<sup>[1]</sup>。在过去的三十多年间, 很多纹理特征提取的方法被发展<sup>[2]</sup>。这些纹理特征可以被大致分为基于统计特征、基于模板卷积特征、基于频域特征和基于模型特征这4类<sup>[3]</sup>。

本文将图模型(GM)<sup>[4-5]</sup>引入纹理分析中, 利用高斯图模型(GGM)<sup>[4-5]</sup>可分解为一个自回归过程的

收稿日期: 2010-11-03; 修回日期: 2010-12-26

基金项目: 国家自然科学基金项目(60975083; U0835005)。

第一作者简介: 杨关(1974—), 男, 中山大学数学与计算科学学院信息计算科学专业博士研究生, 主要研究方向为模式识别、图像处理和计算机视觉。E-mail: guanyang\_sysu@yahoo.com。

思想,提出利用不同惩罚正则化的变量选择方法去学习以纹理图像为基础的高斯图模型的结构,获得高斯图模型的邻域结构并估计参数。将协方差的估计转变为一组参数的估计,这就大大降低了计算复杂度,使之应用于图像纹理合成、分类和分割。

## 1 高斯图模型

图模型定义在图上,节点表示随机变量,边表示随机变量之间的依赖性,模型选择就是确定哪些节点之间有边相连,两个相连的节点互为邻域点,图结构也表明了节点的邻域结构,即马尔可夫性。为了方便分析,本文采用高斯图模型,即随机变量服从高斯分布。

统计推断(或参数估计)也是一个重要问题。这里的均值和方差可通过逆协方差矩阵  $\Sigma^{-1}$  和  $\mu = \Sigma b$  来获得,称  $P = \Sigma^{-1}$  为精度矩阵(precision matrix)。建立高斯图模型就是确定其精度矩阵中的非零元素,且求出所对应部分的相关系数。检验精度矩阵的元素是否为零就等价于检验相对应的两个随机变量在给定其他剩余变量条件下的独立性,即节点之间无边。因而,检验独立性就可以完成变量选择,即所对应的部分相关系数为零。因此,精度矩阵的稀疏结构反映了高斯图模型的模型结构。

## 2 纹理模型的建立

确定高斯图模型就是选择合适变量和估计高斯分布的均值和协方差矩阵。

因此,在规则图像网格上利用高斯图模型构建纹理模型就是要找到像素点的灰度级与其邻域点的灰度级之间的联系。这就带来两个问题,一是如何选择合适的邻域,另一个就是如何在大量的图像数据中估计参数。

以纹理图像为基础的高斯图模型中的随机变量的数目庞大,例如,一幅  $256 \times 256$  像素的纹理图像,其随机变量数是  $65\ 536 (256 \times 256)$  个,这样其协方差矩阵的维数就是  $65\ 536 \times 65\ 536$ ,这将是灾难性的,此外,邻域结构的变化也使得计算更加复杂。这就使得高斯图模型很难直接应用于纹理分析。因此,需要对高斯图模型做一些处理。

设图  $G = (S, E)$ ,  $E$  是边的集合,节点集合  $S = \{m \mid m = (i, j), 0 \leq i \leq M - 1, 0 \leq j \leq N - 1\}$ ,

定义在有循环边界的 2 维网格上。设纹理图像为  $X = \{x_m \mid m \in S\}$ ,  $x_m$  表示图像中像素  $m$  的灰度值,且是一个离散的零均值高斯观察值。

根据标准的高斯性质<sup>[4]</sup>,条件分布  $p(x_m \mid x_{S \setminus m})$  服从一个以  $x_{S \setminus m}$  的线性权值和为均值且方差不依赖  $x_{S \setminus m}$  的高斯分布, $S \setminus m$  表示  $S$  中不包含  $m$  的点集。因此,可分解  $x_m$  为一个自回归过程(AR),其协方差矩阵正定,邻域系统对称,对称的邻域参数相等。即

$$x_m = \sum_{n \in S \setminus m} \theta_n^m x_n + e_m \quad (1)$$

式中,参数  $\theta_n^m$  由  $X$  的精度矩阵  $P$  决定<sup>[5-6]</sup>。更准确的说,对于任意的  $m \neq n$ ,

$$\theta_n^m = -P_{mn}/P_{mm}, \quad \text{Var}(x_m \mid x_{S \setminus m}) = 1/P_{mm} \quad (2)$$

因此,非零系数向量  $\theta^m$  对应矩阵  $P$  的第  $m$  行的非零元素。即就是,如果  $P_{mn} \neq 0$ ,则节点  $m$  和  $n$  之间有边相连接。

平稳性约束使得邻域结构及所对应的参数和节点的变化无关。这样,精度矩阵  $P$  就是块循环矩阵,块循环矩阵和离散傅里叶变换(DFT)之间的关系就可用来降低计算复杂度。

邻域结构的选择和参数估计的计算复杂度也大大降低。因此有

$$\text{Var}(x_m \mid x_{S \setminus m}) = 1/P_{mm} = \sigma^2 > 0 \quad (3)$$

方程式(1)就是一个平稳自回归过程,其精度矩阵也大大简化。

$e_m$  是一个与  $x_{S \setminus m}$  相独立的零均值高斯随机变量<sup>[7]</sup>,方差为  $x_m$  的条件方差  $\text{Var}(x_m \mid x_{S \setminus m})$ ,且有以下自相关结构

$$E(e_m e_n) = \begin{cases} -\theta_n \sigma^2 & n \in S \setminus m \\ \sigma^2 & m = n \end{cases} \quad (4)$$

## 3 纹理特征的提取

通过方程(1),高斯图模型的模型选择和统计推断就转换为变量选择及估计相应的变量系数,也就是从  $x_{S \setminus m}$  中选择变量  $\{x_n, \theta_n^m \neq 0\}$ ,并估计参数  $\theta^m = \{\theta_n^m\}$ ,  $\{n \mid n \in S \setminus m, \theta_n^m \neq 0\}$  就是选择后的邻域。

高斯图模型包含了一个非因果的 2 维自回归过程,因此,从理论上讲,解出方程式(1)就能估计出未知参数向量  $\theta^m$  的值。最小二乘法(LSE)常常被用来估计求解。但是,最小二乘法的解不稳定,此外,它也无法完成变量选择。

$L_1$  类型的回归在参数估计的同时实现变量选择。因此,  $L_1$  惩罚正则化方法可用来提取纹理特征。本文使用最小收缩和选择算子(Lasso)<sup>[8]</sup>算法选择邻域和估计参数,其形式为

$$\theta^* = \arg \min_{\theta} \| X_n \theta - X \|_2^2 + \lambda \| \theta \|_1 \quad (5)$$

$X = (x_m, m \in S)^T$  是一个长度为  $MN$  的列向量, 矩阵  $X_n$  是  $MN \times (MN - 1)$  维的矩阵, 它的列由  $(x_n, n \in S \setminus s)^T$  给出,  $\theta$  表示所有可能的参数。 $\lambda$  是调谐参数, 邻域的选择(由参数  $\lambda$  控制)通过  $L_1$  惩罚回归的非零系数定义。 $\lambda$  越大, 非零系数的个数越少,  $\lambda$  越小, 否则非零系数的个数越多, 即邻域点的数目越多, 当  $\lambda = 0$  时, 就是普通的最小二乘估计。然而, Lasso 只是在一定的条件下才有变量选择一致性。

通过加权的  $L_1$  惩罚项来获得一个凸性目标函数以建立一个变量选择一致的方法, 这里的权值是由一个初始估计  $\tilde{\theta} = (\tilde{\theta}_n, n \in S \setminus m)$  所决定<sup>[9]</sup>, 则定义  $|\tilde{\theta}_n|^{-1}$  作为权值, 即

$$\tilde{\theta}_i^* = \arg \min_{\theta} \| X_n \theta - X \|_2^2 + \lambda_i \| \theta ./ \tilde{\theta} \|_1 \quad (6)$$

被称为自适应 Lasso (aLasso) 估计<sup>[9]</sup>。“./”表示两个矩阵中位置相同的元素相除。值得强调的是方程式(6)仍是一个凸优化问题, 因此, 不会出现多个局部最小值, 且全局最小值可被有效解出。aLasso 可以解决 Lasso 估计不一致的问题。

Lasso 类型的算法有两个优点: 1) 选择过程是连续的, 因而是稳定的; 2) 这个优化问题仍然是凸性的, 因而更利于计算高维数据, 如图像。且选择变

量和估计参数同步进行。

最小角度回归(LARS)算法<sup>[10]</sup>可用来求解 Lasso 类型的估计。

然而, 利用 LARS 算法求解 Lasso 类型的估计, 得到的是所有  $\lambda$  对应的解, 即每一个调谐参数  $\lambda$  都确定一个邻域和一组参数。因此, 要得到合适的邻域和参数就必须选择一个适当的调谐参数  $\lambda$ 。

本文使用贝叶斯信息准则(BIC)的变形<sup>[11]</sup>来选择合适的  $\lambda$ 。

$$BIC_{\lambda} = \lg(\hat{\sigma}_{\lambda}^2) + |\eta_{\lambda}| \times \frac{\lg(MN)}{MN} \times K_n \quad (7)$$

式中,  $\hat{\sigma}_{\lambda}^2 = \| X - X\theta \|_2^2 / (MN)$ 。设  $\eta_{\lambda} = \{r: \hat{\theta}_{\lambda, r} \neq 0\}$  由  $\hat{\theta}_{\lambda}$  决定,  $|\eta_{\lambda}|$  表示  $\eta_{\lambda}$  的势。 $K_n > 0$  是正的常数。则优化的调谐参数将通过  $\hat{\lambda} = \operatorname{argmin}_{\lambda} BIC_{\lambda}$  获得, 其对应的参数解和邻域也就可以解出, 这样就可提取出一组纹理特征。

通过实验发现, 纹理图像中的某个像素和其邻域点的距离不会太远。因此, 本文实验中为了提高运算效率, 仅从一个  $11 \times 11$  的窗口中选择邻域。

通过准则式(7), 可以确定  $\lambda$  并得到 Lasso 和 aLasso 估计的邻域和对应的参数值。因为邻域  $\eta$  和参数  $\hat{\theta}$  具有对称性, 因此只需解出一半的邻域点和参数。以 Brodatz 纹理库<sup>[12]</sup>中的 D68 和 D84 纹理为例, 表 1 分别给出基于高斯图模型的 Lasso 和 aLasso 估计的邻域和参数。

表 1 纹理 D68 和 D84 的 GGM 邻域及对应参数

Tab. 1 Neighborhoods and parameters of GGM for textures D68 and D84

D68Lasso 估计	D68aLasso 估计	D84Lasso 估计	D84aLasso 估计
$\theta_{0,1} = 0.250$	$\theta_{0,1} = 0.260$	$\theta_{0,1} = 0.517$	$\theta_{0,1} = 0.531$
$\theta_{0,4} = -0.013$	$\theta_{0,4} = -0.016$	$\theta_{0,2} = -0.04$	$\theta_{0,2} = -0.053$
$\theta_{1,-4} = 0.008$	$\theta_{1,-4} = 0.009$	$\theta_{0,4} = -0.002$	$\theta_{0,4} = -0.005$
$\theta_{1,-1} = -0.123$	$\theta_{1,-1} = -0.126$	$\theta_{1,-4} = 0.001$	$\theta_{1,-4} = 0.003$
$\theta_{1,0} = 0.542$	$\theta_{1,0} = 0.551$	$\theta_{1,-2} = -0.014$	$\theta_{1,-1} = -0.222$
$\theta_{1,1} = -0.129$	$\theta_{1,1} = -0.133$	$\theta_{1,-1} = -0.202$	$\theta_{1,0} = 0.528$
$\theta_{1,4} = 0.006$	$\theta_{1,4} = 0.007$	$\theta_{1,0} = 0.513$	$\theta_{1,1} = -0.322$
$\theta_{2,-1} = -0.008$	$\theta_{2,0} = -0.097$	$\theta_{1,1} = -0.309$	$\theta_{1,2} = 0.051$
$\theta_{2,0} = -0.087$	$\theta_{3,0} = 0.072$	$\theta_{1,2} = 0.047$	$\theta_{1,4} = 0.002$
$\theta_{2,1} = 0.006$	$\theta_{4,0} = -0.031$	$\theta_{2,-2} = 0.013$	$\theta_{2,-2} = 0.007$
$\theta_{3,-1} = -0.009$	$\theta_{5,0} = 0.005$	$\theta_{2,-1} = 0.004$	$\theta_{2,-1} = 0.012$
$\theta_{3,0} = 0.063$		$\theta_{2,0} = -0.077$	$\theta_{2,0} = -0.091$
$\theta_{3,1} = 0.003$		$\theta_{2,1} = 0.066$	$\theta_{2,1} = 0.074$
$\theta_{4,-1} = 0.004$		$\theta_{2,2} = -0.025$	$\theta_{2,2} = -0.024$

续表 1  
To be continued Tab. 1

D68Lasso 估计	D68aLasso 估计	D84Lasso 估计	D84aLasso 估计
$\theta_{4,0} = -0.025$		$\theta_{3,0} = 0.006$	$\theta_{3,0} = 0.012$
$\theta_{4,1} = -0.001$		$\theta_{4,0} = -0.001$	$\theta_{3,1} = -0.005$
$\theta_{5,0} = 0.003$			$\theta_{4,-1} = -0.001$
$\hat{\sigma}^2 = 12.56$	$\hat{\sigma}^2 = 12.55$	$\hat{\sigma}^2 = 32.57$	$\hat{\sigma}^2 = 32.48$

由表 1 可以看出,Lasso 和 aLasso 估计对两种纹理给出了不同的邻域选择和参数估计。对同一种纹理,Lasso 估计和 aLasso 估计的结果较为接近。对不同的纹理,选择的邻域结构也不同,这与传统的高斯马尔可夫随机场(GMRF)模型<sup>[7]</sup>有很大不同。同时也反映了基于高斯图模型的纹理模型是自适应的。值得强调的是像素点  $m$  的邻域包含的并不一定是与它距离最近的邻域点,而是最相关的邻域点。

## 4 纹理分析

### 4.1 纹理合成

在高斯马尔可夫随机场模型中,如果图像大小是  $M \times N$ ,则块循环矩阵  $\mathbf{A}$  就是  $MN \times MN$ ,要合成纹理图像就要对  $\mathbf{A}$  的逆矩阵求傅里叶变换<sup>[7]</sup>,这样运算量太大。为了快速合成纹理图像,就需要提出一种新的算法以得到纹理的合成图像。根据块循环矩阵的性质<sup>[6]</sup>,本文提出一种快速的纹理合成算法,只需对  $M \times N$  维矩阵求傅里叶变换,且不需要求逆矩阵,这就大大简化了计算复杂度,加快了纹理合成的速度。

这种合成结果是基于统计模型的一种对原纹理的模拟。平稳性的约束在这里仍然被考虑。

将方程(1)用矩阵形式  $\mathbf{A}(\boldsymbol{\theta})\mathbf{X} = \mathbf{e}$  表示,则根据式(4), $\mathbf{e}$  有如下相关矩阵

$$E(\mathbf{e}\mathbf{e}^T) = \sigma^2\mathbf{A}(\boldsymbol{\theta}) \quad (8)$$

由于平稳性约束,其方差就是条件方差  $Var(x_m | x_{S \setminus m}) = \sigma^2$ ,且

$$\sigma^2 = \frac{1}{MN} \|\mathbf{X} - \mathbf{X}\boldsymbol{\theta}\|_2^2 \quad (9)$$

由于高斯图模型的协方差矩阵是正定的,因此, $\mathbf{A}(\boldsymbol{\theta})$  的特征值必须为正,且  $\mathbf{A}(\boldsymbol{\theta})$  是一个高度稀疏的块循环矩阵,它的对角元素为 1,其他的非零元素对应相关邻域点的参数。需要说明的是  $\frac{1}{\sigma^2}\mathbf{A}(\boldsymbol{\theta})$  就是高斯图模型的精度矩阵,因此, $\mathbf{A}(\boldsymbol{\theta})$  反映了高斯图模型的稀疏性结构。 $\theta_r = \theta_{-r}$  确保相关矩阵  $\mathbf{A}(\boldsymbol{\theta})$

的对称性,则  $\sigma^2\mathbf{A}(\boldsymbol{\theta})$  能够被对角化

$$\mathbf{V}^T[\sigma^2\mathbf{A}(\boldsymbol{\theta})]\mathbf{V} = \boldsymbol{\Lambda} \quad (10)$$

式中, $\mathbf{V}$  是一个由  $\sigma^2\mathbf{A}(\boldsymbol{\theta})$  的特征向量(正交的)组成的矩阵, $\boldsymbol{\Lambda}$  是对角矩阵,其对角线上的元素对应  $\sigma^2\mathbf{A}(\boldsymbol{\theta})$  的特征值。因此,可以将  $\mathbf{e}$  变换成为另一个不相关的随机变量,即

$$\boldsymbol{\varepsilon}_1 = \mathbf{V}^T\mathbf{e} \quad (11)$$

此外, $\boldsymbol{\Lambda}^{1/2}$  是一个对角矩阵,其元素是  $\sigma^2\mathbf{A}(\boldsymbol{\theta})$  的特征值的平方根,则  $\mathbf{e}$  可由下述方程所确定

$$\mathbf{e} = \mathbf{V}\boldsymbol{\Lambda}^{1/2}\boldsymbol{\varepsilon} \quad (12)$$

式中, $\boldsymbol{\varepsilon} \sim N(0, \mathbf{I})$ ,  $\mathbf{I}$  是一个  $M \times N$  维的单位矩阵。

块循环矩阵的特征值和特征向量与傅里叶变换的关系<sup>[6]</sup>可以被利用,合成方程

$$\mathbf{X} = \frac{1}{\sqrt{MN}}\text{DFT2}(\text{IDFT2}(\mathbf{e}) ./ \text{DFT2}(\boldsymbol{\theta})) \quad (13)$$

这里, $\boldsymbol{\theta}$  是块循环矩阵  $\mathbf{A}(\boldsymbol{\theta})$  的基,DFT2 表示 2 维离散傅里叶变换,IDFT2 表示 2 维逆离散傅里叶变换。从方程式(13)可以看出,由于  $\mathbf{e}$  和  $\mathbf{A}(\boldsymbol{\theta})$  的基都是  $M \times N$  维矩阵,且方程中的除法是二个矩阵中位置相对应元素的商,这样运算就变得简单起来。

### 4.2 纹理分析

本文提出的基于高斯图模型纹理特征的图像分类算法采用有监督的方式,如前所述,找出每类纹理样本的参数和邻域。样本图像的纹理特征集合就可用于纹理分析,则训练纹理图像的特征向量由  $\boldsymbol{\theta} = (\theta_r, \sigma; r \in \boldsymbol{\eta})$  所表示。对每类训练纹理样本计算它的样本参数均值  $\bar{\theta}_k = (\bar{\theta}_{k,r}, \bar{\sigma}_k; r \in \boldsymbol{\eta}_k)$ ,下标  $k$  表示第  $k$  类的样本训练特征。对图像中的每个像素,设定一个窗口  $\mathbf{W}$ , $\mathbf{W}$  是一个以测试图像中某个像素点  $m$  为中心的窗口,然后计算下式

$$g_k(\mathbf{X}) = \arg \min_k \sum_{m \in \mathbf{W}} \left[ 2 \ln \bar{\sigma}_k + \frac{(x_m - \sum_{r \in S \setminus m} \bar{\theta}_{k,r} x_r)^2}{\bar{\sigma}_k^2} \right] \quad (14)$$

采用最大后验概率分类测试纹理图像,哪一类纹理的后验概率最大,则该像素就属于哪一类。

由于一个纹理图像既包含随机性元素,又包含结构性元素,因此,在纹理分割中考虑将纹理图像的小波特征<sup>[13]</sup>也加进来,以期获得更好的分割结果。我们利用 db4 小波将图像分解成 3 个尺度,则一共获得 10 个频率块,由于高频部分往往反映噪声信息,我们将其去掉,这样就剩下 7 个,计算每一块小波系数的均值,将其作为纹理特征,则分割准则为

$$k = \arg \min_w [\alpha g_k(\mathbf{X}) + (1 - \alpha) |w_w - \bar{w}_k|] \quad (15)$$

式中,  $w_w$  是窗口内的小波特征,系数  $0 < \alpha < 1$ , 哪一类参数使方程式(15)最小,则该像素就属于哪一类。

### 5 实验结果

为了检验提出算法的有效性,这里设计了 3 组实验,即纹理合成、分类和分割实验。实验中的纹理样本均来自 Brodatz 纹理库<sup>[12]</sup>。

#### 5.1 纹理合成

选取 3 种 Brodatz 纹理,分别是 D49、D68 和 D84。根据高斯图模型的模型选择方法提取纹理特征,并随机生成一个高斯随机白噪声  $\epsilon \sim N(0, \mathbf{I})$ , 然后通过方程式(13)获得合成的纹理图像,并且用高斯马尔可夫随机场纹理特征<sup>[7]</sup>和高斯图模型的纹理特征相比较。图 1—3 显示了利用 3 类纹理特征合成纹理图像的结果。

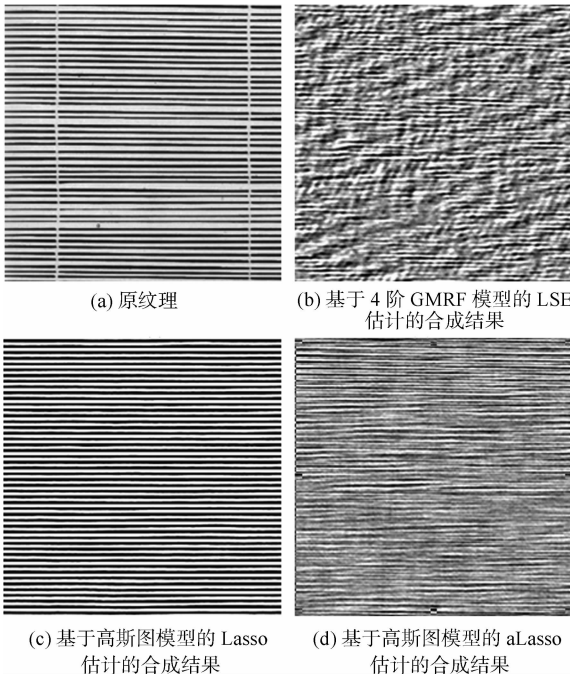


图 1 D49 纹理合成的实验结果  
Fig. 1 Synthetic results of D49




图 2 D68 纹理合成的实验结果  
Fig. 2 Synthetic results of D68




图 3 D84 纹理合成的实验结果  
Fig. 3 Synthetic results of D84

从图 1—3 中可以看出,使用基于高斯图模型的纹理特征合成的纹理在视觉效果上比基于高斯马尔可夫随机场纹理特征合成的纹理更接近真实纹理。

尤其是图 1 中基于 Lasso 估计的纹理特征合成的 D49 纹理图像和原图像非常接近。实验表明,利用高斯图模型的 Lasso 和 aLasso 估计得到的纹理特征合成的纹理在视觉上更接近真实纹理。同时,实验也显示,本文的纹理合成算法在速度上大大快于文献[7]中的纹理合成算法。这也证明了基于高斯图模型的纹理特征可以很好地描述纹理。

### 5.2 纹理分析

将每一个  $640 \times 640$  像素的 Brodatz 纹理看做一类,并计算该类基于高斯图模型的纹理参数。

将 Brodatz 纹理中的 69 幅均质性纹理组成样本库,每种纹理看做一类,将每类纹理分为 49 个,  $128 \times 128$  个子块,这样就得到了包含  $69 \times 49 = 3\ 381$  幅图像的纹理库。从每类中挑出 9 幅作为该类纹理的训练样本,选择另外与之不相重叠的 29 幅图像作为测试样本。这样,训练集包含了  $69 \times 9 = 621$  幅纹理图像,测试集包含了  $69 \times 29 = 2\ 001$  幅图像。

由实验结果发现,基于高斯图模型的 aLasso 估计的纹理分类效果最好,因此,本组实验中仅利用基于 aLasso 估计的高斯图模型纹理特征。同时和基于高斯马尔可夫随机场模型的纹理特征和基于小波的纹理特征的分类结果加以比较。表 2 展示了基于 3 种纹理特征的纹理分类比较结果。

表 2 不同方法的纹理分类准确率比较

Tab.2 Comparison of classification accuracy

/%

纹理	小波特征	GMRF	GGM
D1	20.69	100	100
D3	37.93	89.66	79.31
D4	79.31	96.55	100
D6	96.55	0	100
D8	82.76	100	100
D10	72.41	86.21	96.55
D11	75.86	100	100
D12	6.9	100	100
D14	41.38	93.1	100
D15	79.31	79.31	79.31
D16	100	0	100
D17	100	0	55.17
D18	6.9	86.21	96.55
D19	55.17	58.62	62.07
D22	10.34	93.10	89.66
D24	31.03	41.38	58.62
D26	62.07	20.69	48.28
D28	41.38	96.55	100
D29	24.14	0	68.97
D30	13.79	51.72	68.97

续表 2

To be continued Tab. 2

纹理	小波特征	GMRF	GGM
D32	44.83	82.76	75.86
D33	100	0	75.86
D36	10.34	75.86	55.17
D40	55.17	89.66	89.66
D43	10.34	100.00	100
D44	100	34.48	96.55
D45	13.97	100	100
D46	44.83	100	100
D47	58.62	65.52	100
D49	100	93.1	86.21
D50	44.83	68.97	79.31
D51	51.72	65.52	65.52
D53	75.86	96.55	100
D55	86.21	100	100
D56	24.14	100	100
D57	100	31.03	100
D58	24.14	100	100
D59	10.34	100	100
D60	27.59	72.41	68.97
D62	3.45	68.97	96.55
D64	44.83	86.21	89.66
D65	62.07	100	100
D67	96.55	100	100
D68	34.48	100	100
D69	89.66	93.1	89.66
D70	0	89.66	86.21
D71	62.07	89.66	93.1
D75	17.24	96.55	96.55
D76	75.86	79.31	58.62
D79	34.48	100	100
D80	79.31	79.31	89.66
D81	6.9	82.76	79.31
D82	3.45	93.1	100
D83	100	93.1	100
D84	93.1	89.66	100
D85	100	100	100
D93	27.59	89.66	89.66
D94	89.66	37.93	65.52
D95	68.97	100	100
D96	17.24	100	100
D97	75.86	100	100
D98	27.59	96.55	93.1
D99	65.52	100	100
D101	96.55	82.76	96.55
D102	100	93.1	93.1
D104	100	100	100
D105	79.31	86.21	75.86
D106	65.52	58.62	82.76
D107	44.83	96.55	96.55
平均值	54.82	79.01	89.46

实验结果显示,基于高斯图模型的纹理分类率最高,达到 89.46%,而且对所有纹理都有较好的分类准确率。在基于高斯马尔可夫随机场纹理特征的分类结果中,有 6 种纹理分类准确率为 0,平均准确率为 79.01%。而在这组实验中,基于小波纹理特征的分类准确率都不高,平均准确率只有 54.82%。

基于此,本文算法在实验中结果明显好于另外两种方法,取得了较高的分类准确率,而且在整体上表现很稳定。因此,实验可以说明基于高斯图模型的纹理特征可以很好地刻画纹理。

再选择 10 个纹理合成两幅 Mosaics 图像用于图像分割实验。

Mosaics 1 由 8 幅图像组成。为了做一个比较,本文在实验中也利用 4 阶高斯马尔可夫随机场的最小二乘估计的纹理特征分割两种图像。两种方法对 Mosaics 1 图像的分割结果见图 4。

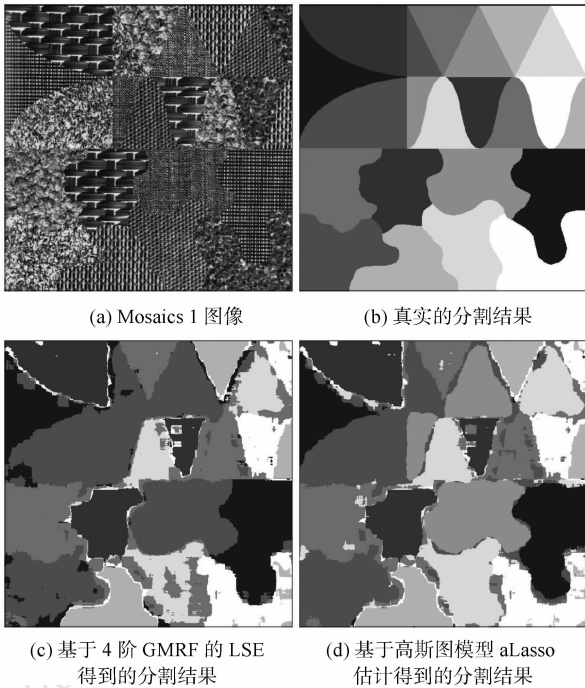


图 4 Mosaics 1 的分割结果  
Fig.4 Segmentation results of Mosaics 1

图 4(b)是 Mosaics 1 图的真实分割结果,与之相比,从视觉效果上看,利用高斯图模型的模型选择结果来分割图像比用 4 阶高斯马尔可夫随机场的最小二乘估计得到的分割结果明显要好。图 4 中基于高斯马尔可夫随机场的纹理特征将 Mosaics 1 中的不同纹理也分为同一类,而基于高斯图模型纹理特征则将所有纹理的主要区域都分

开了。通过同图 4(b)相比较,还得到一个更加客观的评价结果,基于高斯图模型的分割准确率为 82.11%,而基于高斯马尔可夫随机场的准确率为 67.05%。实验结果反映了本文算法对高斯图模型的结构学习的准确性,基于高斯图模型的纹理特征也是有效的。此外,由于我们的算法是基于区域的纹理属性分割,因此,在不同纹理的边界对分割产生了一定影响。

为使分割更加准确,对合成纹理 Mosaics 2 结合高斯图模型参数和小波参数特征<sup>[13]</sup>进行分割实验,并与基于高斯图模型纹理特征的分割结果加以对比,结果如图 5 所示。

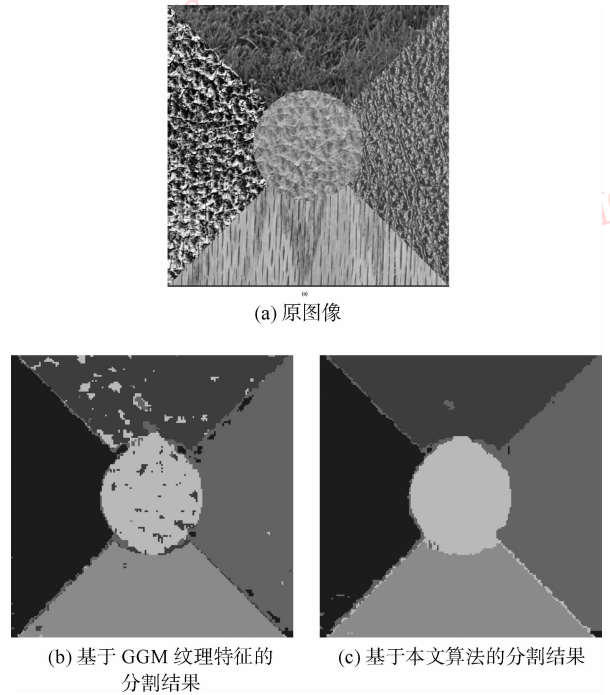


图 5 Mosaics 2 的分割结果  
Fig.5 Segmentation results of Mosaics 2

实验显示了较好的分割效果,可以看出,加上小波特征后,分割结果变得更好,小波特征捕捉了一些细节性信息,说明了本算法结合小波纹理特征的合理性。

选择两幅自然图片进行实验,进一步检验结合高斯图模型参数和小波参数的分割算法的效果。结果显示,本文算法取得了很好的实验结果,如图 6(c)所示,一些细节也很好地分割出来。

本文又选择了两幅 IKONOS 卫星图片,分割结果见图 7。可以很直观地看出,对于卫星遥感图片,本文算法依然得到了很好的结果。




图 6 自然图像的分割结果

Fig. 6 Segmentation results of natural images




图 7 IKONOS 卫星图片的分割结果

Fig. 7 Segmentation results of IKONOS images

## 6 结 论

高斯图模型具有完备的数学理论,包容性很强,内涵很广,可以充分利用建模对象的先验知识。但是,由于其协方差矩阵维数往往很大,计算复杂度很

高,因此很难将其直接应用于图像分析应用。本文将高斯图模型引入纹理分析中,将高斯图模型分解为一个自回归过程,并加以平稳性约束,计算复杂度显著降低。这就使得高斯图模型可直接应用于纹理分析,且模型选择是一个动态的适应性过程,可根据模型的不同自动调整。实验显示基于高斯图模型的纹理特征对纹理分析的有效性。这证明了利用高斯图模型来构建纹理模型是有意义的,因而有非常广阔的应用前景。

## 参考文献 (References)

- [ 1 ] Kardan M, Du Buf J M H, Span M. Texture feature performance for images segmentation [J]. Pattern Recognition, 1990, 23 (3-4): 291-309.
- [ 2 ] Liu Li, Kuang Gangyao. Overview of image textural feature extraction methods [J]. Journal of Image and Graphics, 2009, 14 (4): 622-635. [刘丽,匡纲要. 图像纹理特征提取方法综述[J]. 中国图象图形学报, 2009, 14 (4): 622-635.]
- [ 3 ] Reed T R, Buf J M H. A review of recent texture segmentation and feature extraction techniques [J]. Computer Vision, Graphics, and Image Processing, 1993, 57 (3): 359-372.
- [ 4 ] Lauritzen S. Graphical Models [M]. Oxford Statistical Science Series. London: Oxford University Press, 1996:123-157.
- [ 5 ] Edwards D M. Introduction to Graphical Modelling [M]. 2nd ed. New York: Springer, 2000: 35-58.
- [ 6 ] Rue H, Held L. Gaussian Markov Random Fields: Theory and Applications [M]. Boca Raton, FL: Chapman & Hall/CRC, 2005: 14-81.
- [ 7 ] Bader D A, J J, Chellappa R. Scalable data parallel algorithms for texture synthesis using Gibbs random fields [J]. IEEE Transactions on Image Processing, 1996, 4 (10): 1456-1460.
- [ 8 ] Tibshirani R. Regression shrinkage and selection via the Lasso [J]. Journal of the Royal Statistical Society: Series B, 1996, 58 (1):267-288.
- [ 9 ] Zou H. The adaptive Lasso and its oracle properties [J]. Journal of the American Statistical Association, 2006, 101 (476): 1418-1429.
- [ 10 ] Efron B, Hastie T, Johnstone I, et al. Least angle regression [J]. Annals of statistics, 2004, 32 (2): 407-451.
- [ 11 ] Wang H, Li B, Leng C. Shrinkage tuning parameter selection with a diverging number of parameters [J]. Journal of the Royal Statistical Society: Series B, 2009, 71 (3): 671-683.
- [ 12 ] Brodatz P. Texture: A Photographic Album for Artists and Designers [M]. New York: Dover, 1966.
- [ 13 ] Porter R, Canagarajah N. Robust rotation-invariant texture classification; wavelet, Gabor filter and GMRF based schemes [J]. IEE Proceedings in Vision, Image and Signal Processing, 1997, 144 (3): 180-188.