

图模型在彩色纹理分类中的应用

杨 关^{1,2} 张向东³ 冯国灿² 邹小林² 刘志勇²

(中原工学院计算机学院 郑州 450007)¹

(中山大学数学与计算科学学院广东省计算科学重点实验室 广州 510275)²

(河南省理工学校 郑州 450000)³

摘 要 纹理分析中往往将彩色图像转换为灰度图以降低计算复杂度,这样就忽略了颜色信息。而利用主成分分析的方法来降维彩色纹理,则可以尽可能地保留颜色和纹理信息。高斯图模型(Gaussian Graphical Models, 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。根据局部马尔可夫性和高斯变量的条件回归之间的关系,可将复杂的模型选择转变为较简单的变量选择。通过惩罚正则化方法,其邻域选择和参数估计可同步进行,然后提取纹理特征进行彩色纹理分类,实验显示其具有很好的效果。因此,结合主成分分析和高斯图模型来构建彩色纹理模型有很好的发展前景。

关键词 高斯图模型,变量选择, L_1 -惩罚正则化,彩色纹理分类

中图法分类号 TP391.41 **文献标识码** A

Applications of Graphical Models in Color Texture Classification

YANG Guan^{1,2} ZHANG Xiang-dong³ FENG Guo-can² ZOU Xiao-lin² LIU Zhi-yong²

(School of Computer Science, Zhongyuan University of Technology, Zhengzhou 450007, China)¹

(School of Mathematical and Computational Science, Sun Yat-sen University, Guangdong Province Key Laboratory of Computational Science, Guangzhou 510275, China)²

(Henan Province Polytechnic School, Zhengzhou 450000, China)³

Abstract Texture is one of the important visual features in image analysis. For convenience, color texture images are often converted to gray images. It is a pity that color information is ignored. In order to keep texture and color information, principle component analysis (PCA) was utilized to reduce the dimension of color textures. Gaussian graphical models (GGM) have good prospect due to themselves advantages, and are applied to construct texture model. The structure of GGM is explored by the connection between the local Markov property and conditional regression of Gaussian random variables. Thus, the model selection can be converted to select variables in GGM. The development of technique of penalty regularization provides many methods for variable selection and parameter estimation. And, the methods of penalty regularization conduct neighborhood selection and parameter estimation simultaneously. Then, the texture feature is extracted and applied in color texture classification. The experiments show the good results. Therefore, the texture models based connection of GGM and PCA have an attractive prospect.

Keywords Gaussian graphical models, Variables selection, L_1 -penalty regularization, Color texture classification

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之一,纹理分类与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,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,提取过程计算量小。纹理的特征主要包括粗糙度、方向性、对比度和规律性^[1]。在过去的30多年间,发展了很多纹理特征

提取的方法^[2]。

图模型(Graphical Models)理论^[3-5]为描述具有相互作用和上下文约束关系的实体集合提供了一种简洁一致的建模方法,如图像像素和相关特征。高斯图模型(Gaussian Graphical Models, GGM)^[3,5]是建立在图上的一种特殊的概率模型,即模型中随机变量的联合概率分布服从高斯分布,它既可以描述随机变量之间的条件依赖性,又具有很好的计算性质,很适合描述有交互作用的高维数据。高斯图模型的马尔可夫结构表明一个随机变量的概率分布仅仅依赖它的邻域。

彩色纹理的处理通常是通过对3个单色图像分别处理而

到稿日期:2010-11-12 返修日期:2011-03-13 本文受国家自然科学基金项目(60975083, U0835005)资助。

杨 关(1974—),男,博士,主要研究方向为图像处理、模式识别和机器视觉, E-mail: guanyang. sysu@yahoo. com; 冯国灿(1962—),男,博士,教授,博士生导师,主要研究方向为计算机视觉、模式识别和图像处理。

得到的。其基本原理是把颜色的红(R)、绿(G)、蓝(B)都设成原来 RGB 的平均值。好处是降低了处理的难度,但是这种固定各分量比例的简单均值使得图像数据的颜色信息损失较大。

主成分分析(Principal Component Analysis, PCA)^[6]是一种经典的数据降维方法,它将数据中方差最大的几个方向作为主要方向,以使得数据信息损失最小。这样图像数据主方向中各颜色分量的比例就是动态的和自适应的,因而颜色信息在降低分析难度的基础上也尽可能地保留。

本文将高斯图模型引入彩色纹理分析中,利用主成分分析,将多通道彩色纹理降为低维空间,这样可以尽可能地保留纹理和颜色信息。再利用高斯图模型可分解为一个自回归过程的思想,提出了利用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,并可将其应用于彩色图像纹理分析。

1 颜色空间

RGB 三维颜色空间是最常见的彩色图像表示方法。彩色图像可以用每一像素点上 R, G, B 三基色值加以定量描述,它容易用硬件实现,但它与人类的感官差别较大。RGB 颜色空间中相同欧氏距离的颜色人眼看起来差别不一样^[7],因此也可选用其它彩色空间。不同颜色空间只是同一物理量的不同表示法。

YCbCr 颜色空间广泛应用于数字视频。在这种格式中,亮度信息用单个分量 Y 来表示,颜色信息用两个色差分量 Cb 和 Cr 来存储。分量 Cb 是蓝色分量和一个参考值的差,分量 Cr 是红色分量和一个参考值的差。

颜色空间也可以采用亮度(I)、色度(H)和饱和度(S)加以描述。在 HSI 色彩空间中, I 表示亮度,它确定了像素的整体光照强度。色度 H 由角度表示,取值为 $0^\circ \sim 360^\circ$,其中从 0° 到 240° 覆盖了所有可见光谱的彩色,色度表示该彩色最接近什么样的光谱波长。饱和度 S 表示彩色的纯度,其值为 $0 \sim 1$ 。

为了分析彩色纹理,首先选用合适的颜色空间。本文分别在 RGB、YcCbCr 和 HSI 空间中进行纹理分析。

2 高斯图模型

定义标记图 $G=(S, E)$, S 是节点集合, E 是图中边的集合。设随机向量 $X=\{x_m | m \in S\}$, 服从均值 μ 、协方差矩阵 Σ 的高斯分布。且在节点 m 和 n 之间没有边存在, 当且仅当 $x_m \perp x_n | x_{S \setminus \{m, n\}}$, 则称随机向量 $X=\{x_m | m \in S\}$ 关于图 G 是高斯图模型。其联合分布如下:

$$P(x) = \frac{1}{(2\pi)^{M/2} |\Sigma|^{1/2}} \exp\left\{-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu)\right\} \quad (1)$$

式中, $|\Sigma|$ 表示 Σ 的行列式。高斯图模型的马尔可夫结构可以从逆协方差矩阵 $P=\Sigma^{-1}$ 得到, P 称为精度矩阵(Precision Matrix)或信息矩阵(Information Matrix)。 P 是一个正定矩阵。实际上, P 的稀疏性可以很好地满足马尔可夫条件: 如果 $\{m, n\} \notin E$ 或 $x_m \perp x_n | x_{S \setminus \{m, n\}}$, 则有 $P_{mn}=0$ 。这就给高斯图模型的统计推断(或参数估计)带来很大方便。

要构建高斯图模型, 需确定哪些节点之间有边相连, 即选择节点的邻域。一个节点仅与它的邻域点有边相连, 这就是马尔可夫性。然后就要考虑在一些观察值已知的情况下, 如何确定变量的边缘概率, 即统计推断。其均值和方差可通过精度矩阵 P 和 $\mu=P^{-1}b$ 来获得。建立高斯图模型就是确定其逆协方差矩阵中的非零元素。检验逆协方差矩阵的元素是否为零, 等价于检验相对应的两个随机变量在给定其它剩余变量条件下的独立性。这种独立性反映在图上, 就是节点之间没有边相连。因而, 变量选择也可通过检验独立性来完成, 即所对应的部分相关系数为零。因此, 逆协方差矩阵的稀疏结构反映了高斯图模型的模型结构。

3 纹理模型的建立

若在一个规则图像网格上利用高斯图模型构建纹理模型, 就需要找到某个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。

一般来说, 高斯图模型的模型选择和参数估计, 是为了选择合适变量和估计高斯分布的均值和协方差矩阵。

但是在纹理图像分析中, 如果以纹理图像为基础构建高斯图模型, 其随机变量的数目就会非常庞大。例如一幅 256×256 像素的纹理图像, 其随机变量数是 $65536(256 \times 256)$ 个, 这样其协方差矩阵的维数就是 65536×65536 , 这将是灾难性的。此外, 邻域结构随变量的变化而变化, 也使得计算更加复杂。

因此, 直接将未知结构的高斯图模型应用于纹理分析很难处理。为了在纹理分析中应用高斯图模型, 需要对高斯图模型做一些处理。

设图 $G=(S, E)$, E 是图中边的集合, 节点集合 $S=\{m | m=(i, j), 0 \leq i \leq M-1, 0 \leq j \leq N-1\}$ 定义在图 1 所示的有循环边界的二维网格上。设纹理图像为 $X=\{x_m | m \in S\}$, $x_m, m \in S$, 表示图像中像素 m 的灰度值是一个离散的零均值高斯观察值。




图 1 有循环边界的二维网格^[8]

这样, 精度矩阵 P 就是块循环矩阵, 而块循环矩阵和离散傅立叶变换(Discrete Fourier Transform, DFT)之间的关系使得计算复杂度大大降低且不依赖于邻域点的个数。

根据标准的高斯性质^[4], 条件分布 $p(x_m | x_{S \setminus m})$ 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。因此, 可分解 x_m 为一个自回归过程(Auto-Regressive, 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:

$$x_m = \sum_{n \in S \setminus m} \theta_{mn}^m x_n + e_m \quad (2)$$

式中, $\theta^n = (\theta_{mn}^n, n \in S \setminus m)$ 是一个向量, 参数 θ_{mn}^n 由 X 的精度矩阵 P 所决定^[6,8]。更准确地说, 对于任意的 $m \neq n$,

$$\theta_{mn}^m = -P_{mn} / P_{mm} \quad (3)$$

$$\text{Var}(x_m | x_{S \setminus m}) = 1 / P_{mm} \quad (4)$$

因此,非零系数向量 θ^m 对应矩阵 P 的第 m 行的非零元素。即,如果 P_{mm} 不等于零,则节点 m 和 n 之间有边相连接。这样高斯图模型的模型选择问题就转换为自回归方程的变量选择问题。这里, e_m 是一个与 $x_{S \setminus m}$ 相独立的零均值高斯随机变量^[9],其方差为 x_m 的条件方差 $\text{Var}(x_m | x_{S \setminus m})$ 。

高斯图模型的平稳性约束使得邻域结构和节点变化无关,且某个节点的邻域点对应的参数是一致的,即参数不随节点位置的变化而变化。这样,邻域结构的选择和参数估计的计算复杂度大大降低。因此,对高斯图模型做如下限制:

$$\text{Var}(x_m | x_{S \setminus m}) = 1/P_{mm} = \sigma^2 > 0 \quad (5)$$

由于高斯图模型包含一个非因果的二维自回归过程,因此考虑了从自回归过程中选择协变量(邻域)和估计参数的方法。

4 彩色纹理分类

4.1 PCA 降维

以 RGB 颜色空间的图像为例,若要将彩色图像转换为灰度图像,只需取图像中的每个像素的 R、G、B 颜色分量计算灰度值,且每种分量的比例是固定的。

PCA 方法可使信息损失最小,并且各个主成分是不相关的。此外,降维后图像的各个彩色分量之间的比例根据图像的不同而动态变化,因而是自适应的。因此,与转换为灰度图相比,PCA 降维方法使图像颜色信息损失最小。

将彩色纹理图像每个像素的灰度值作为一个三维向量,则一幅图像就可构造为一个由三维向量组成的样本空间,即对一幅图像 X ,有:

$$X(m, n) = \begin{bmatrix} X_1(m, n) \\ X_2(m, n) \\ X_3(m, n) \end{bmatrix} \quad (6)$$

有了这个图像的样本空间,就可以利用 PCA 对这个样本空间进行降维。首先去均值,即 $E(X(m, n)) = 0$;接下来就需要构建相关矩阵 C ,这里 $C = E(XX^T)$;然后求解它的特征向量。于是得到 $X(m, n)$ 的第 i 个主成分:

$$Y_i(m, n) = \omega_i^T X(m, n) \quad (7)$$

这样就将一幅三维彩色纹理图像投影到一个低维空间。由于在 $Y_j(m, n)$ 与 $Y_i(m, n)$ 不相关的条件下, ω_i 最大化了 $Y_i(m, n)$ 的方差,这里只保留一个主成分,因而经过 PCA 降维后可以将原图像投影到一个一维空间。这样在一维空间就产生了一个新的图像,并保留了原图像最多的信息。

从 Vistex 彩色纹理库^[10]中选取两幅纹理,通过 PCA 方法对其降维,将它们变成一维空间的图像,结果见图 2。




图 2 彩色纹理图像的 PCA 降维结果

4.2 特征提取

图像进行 PCA 降维后,再以此为基础建立高斯图模型,并进一步构建纹理模型。由于原图像通过 PCA 降维后,从多通道图像转换为单通道图像,因此可应用自回归过程(2)来构建纹理模型, x_m 被称为响应变量。通过方程(2),高斯图模型的结构选择和参数估计就转换为选择和响应变量最相关的协

变量并估计相应的变量系数。即从 $x_{S \setminus m}$ 中选择集合 $\{x_n, \theta_n^m \neq 0\}$,并估计参数 θ^m , $\{n | \theta_n^m \neq 0\}$ 就是选择后的邻域。这将更加有利于分析纹理图像。理论上,解出方程(2)就能估计出未知参数向量 θ^m 的值。最小二乘法(Least Squares Estimation, LSE)常常被用来估计求解。但是,最小二乘法的解不稳定。此外,最小二乘法给出了所有参数的非零估计,无法完成变量选择,即找到每个节点的邻域。

L_1 类型的回归是目前处理多重共线性的主要方法之一,相对于其它方法,更容易产生稀疏解,在参数估计的同时,实现变量选择,因而可用来解决检验中的多重共线性问题,以提高检验效率。故,本文利用 L_1 类型的算法来提取纹理特征。

Lasso 算法^[11]是一种 L_1 惩罚正则化方法,即将残差平方和与回归系数的 L_1 惩罚项之和最小化:

$$\theta^* = \arg \min_{\theta} \|X_n \theta - X\|_2^2 + \lambda \|\theta\|_1 \quad (8)$$

式中, $X = (x_m, m \in S)^T$ 是一个长度为 MN 的列向量, X_n 是 $MN \times (MN-1)$ 维的矩阵,它的列由 $(x_n, n \in S \setminus m)^T$ 给出。 λ 是调谐参数(Tuning Parameter),邻域选择(由参数 λ 所控制)通过 L_1 惩罚回归的非零系数所定义。 λ 越大,则非零系数的个数越少; λ 越小,则非零系数的个数越多,即邻域点的数目更多;当 $\lambda = 0$,就是普通的最小二乘估计。

然而,调谐参数(Tuning Parameter) λ 的值要求在减少非零系数的同时要保持变量选择的一致性,这往往会导致非零系数估计的渐进偏差。因而,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,这里的权值由一个初始估计所决定^[12],初始估计可使用 LSE 的估计值。假设初始估计 $\tilde{\theta} = (\tilde{\theta}_n, n \in S \setminus m)$,则定义 $|\tilde{\theta}_n|^{-1}$ 作为权值。下式:

$$\tilde{\theta}_i^* = \arg \min_{\theta} \|X_n \theta - X\|_2^2 + \lambda_i \|\theta \cdot \tilde{\theta}\|_1 \quad (9)$$

被称作自适应 Lasso(Adaptive Lasso, aLasso)估计^[12]。“ $\cdot$ ”表示两个矩阵中位置相同的元素相乘。值得强调的是,方程(9)仍然是一个凸优化问题,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。如果有一个合理的初始估计可利用,则在合适的条件下,自适应 Lasso 可以解决 Lasso 估计不一致的问题,并正确选择有非零系数的变量。

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,比如图像。Lasso 类型的估计可同时选择变量和估计参数。

最小角度回归(Least Angle Regression, LARS)算法^[13]可用来求解 Lasso 估计。对于自适应 Lasso 估计,则可重新定义 $X_n^* = (x_{n_1}/\tilde{\theta}_{n_1}, x_{n_2}/\tilde{\theta}_{n_2}, \dots, x_{n_p}/\tilde{\theta}_{n_p})_{MN \times p}$,方程(9)改写为

$$\tilde{\theta}^{**} = \arg \min_{\theta} \|X_n^* \theta - X\|_2^2 + \lambda_i \|\theta\|_1 \quad (10)$$

再利用 LARS 算法,可求出自适应 Lasso 估计。

然而,利用 LARS 算法及变形分别求解 Lasso 和自适应 Lasso 估计,得到的是所有 λ 对应的解。每一个调谐参数 λ 对应一个邻域和一组参数。因此,要得到合适的邻域和相应的参数,就必须选择一个适当的调谐参数 λ 。

对于 Lasso 和自适应 Lasso 估计,本文使用贝叶斯信息准则(Bayesian Information Criterion, BIC)的变形^[14]来选择合适的 λ 。

$$BIC_{\lambda} = \log(\hat{\sigma}_{\lambda}^2) + |\eta_{\lambda}| \times \frac{\log(MN)}{MN} \times K_n \quad (11)$$

式中, $\hat{\sigma}_{\lambda}^2 = \|X - X_r \theta\|_2^2 / MN$ 。设 $\eta_{\lambda} = \{r: \hat{\theta}_{\lambda,r} \neq 0\}$ 由 $\hat{\theta}_{\lambda}$ 所决定, $|\eta_{\lambda}|$ 表示 η_{λ} 的势。 K_n 是一个正常数。则优化的调谐参数将通过 $\hat{\lambda} = \arg \min_{\lambda} BIC_{\lambda}$ 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。

当邻域选定后, 还要强调的是高斯随机变量的局部马尔可夫性和条件回归性之间的联系。根据条件独立性, 选择后的图模型应该满足马尔可夫条件:

$$p(x_m | x_{S_m}) = p(x_m | x_n, n \in \eta_m) \quad (12)$$

称 x_m 关于对称邻域 η_m 具有严格马尔可夫性质。 $\eta_m = \{n | n \in S, \{m, n\} \in E\}$ 。

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。也就是说, 如果两个像素点距离太远, 则一般不能互为邻域点。因此, 在本文的实验中, 为了提高运算效率, 从一个 11×11 的窗口中选择邻域, 即可能的邻域点和中心像素点的欧式距离小于等于 $5\sqrt{2}$ 。

以 Vistex 纹理库中的纹理图像 Bark. 0001 为例。表 1 给出了基于 Lasso 和自适应 Lasso 估计的高斯图模型的邻域和参数。可以看出, Lasso 和自适应 lasso 估计对纹理给出了不同的邻域选择和参数估计。其邻域结构与传统的高斯马尔可夫随机场模型 (Gaussian Markov Random Field, GMRF)^[9] 也不同。并且, 这种基于高斯图模型的纹理模型是自适应的。

表 1 纹理 Bark. 0001 的 GGM 邻域及对应参数

Bark. 0001			
Lasso 估计		aLasso 估计	
$\theta_{0,1}=0.518$	$\theta_{3,-4}=0.004$	$\theta_{0,1}=0.520$	$\theta_{3,0}=-0.014$
$\theta_{0,3}=-0.025$	$\theta_{3,-3}=-0.013$	$\theta_{0,3}=-0.027$	$\theta_{3,1}=0.007$
$\theta_{0,4}=0.014$	$\theta_{3,-2}=0.009$	$\theta_{0,4}=0.012$	$\theta_{3,2}=0.007$
$\theta_{0,5}=-0.014$	$\theta_{3,0}=-0.019$	$\theta_{0,5}=-0.012$	$\theta_{3,3}=-0.004$
$\theta_{1,-4}=0.016$	$\theta_{3,1}=0.013$	$\theta_{1,-4}=0.021$	$\theta_{4,-4}=0.007$
$\theta_{1,-3}=0.002$	$\theta_{3,2}=0.008$	$\theta_{1,-2}=-0.062$	$\theta_{4,-3}=-0.011$
$\theta_{1,-2}=-0.064$	$\theta_{3,3}=-0.011$	$\theta_{1,-1}=-0.211$	$\theta_{4,-2}=-0.012$
$\theta_{1,-1}=-0.208$	$\theta_{3,4}=0.001$	$\theta_{1,0}=0.511$	$\theta_{4,-1}=0.018$
$\theta_{1,0}=0.51$	$\theta_{3,5}=0.001$	$\theta_{1,1}=-0.211$	$\theta_{4,1}=-0.013$
$\theta_{1,1}=-0.207$	$\theta_{4,-5}=0.001$	$\theta_{1,2}=-0.065$	$\theta_{4,2}=-0.015$
$\theta_{1,2}=-0.066$	$\theta_{4,-2}=-0.013$	$\theta_{1,3}=0.022$	$\theta_{5,-4}=-0.003$
$\theta_{1,3}=0.02$	$\theta_{4,-1}=0.01$	$\theta_{1,4}=0.003$	$\theta_{5,-3}=0.006$
$\theta_{1,5}=0.004$	$\theta_{4,0}=0.008$	$\theta_{2,-5}=0.006$	$\theta_{5,0}=-0.008$
$\theta_{2,-5}=0.006$	$\theta_{4,1}=0.003$	$\theta_{2,-4}=-0.028$	$\theta_{5,2}=0.004$
$\theta_{2,-4}=-0.026$	$\theta_{4,2}=-0.009$	$\theta_{2,-3}=0.017$	
$\theta_{2,-3}=0.018$	$\theta_{5,-5}=-0.001$	$\theta_{2,-2}=0.068$	
$\theta_{2,-2}=0.06$	$\theta_{5,-4}=0.002$	$\theta_{2,-1}=-0.062$	
$\theta_{2,-1}=-0.064$	$\theta_{5,-2}=0.001$	$\theta_{2,1}=-0.059$	
$\theta_{2,1}=-0.06$	$\theta_{5,-1}=0.001$	$\theta_{2,2}=0.063$	
$\theta_{2,2}=0.06$	$\theta_{5,0}=-0.009$	$\theta_{2,4}=-0.011$	
$\theta_{2,3}=0.007$	$\theta_{5,1}=0.003$	$\theta_{2,5}=0.005$	
$\theta_{2,4}=-0.011$	$\theta_{5,3}=0.002$	$\theta_{3,-3}=-0.003$	
$\theta_{2,5}=0.002$		$\theta_{3,-2}=0.007$	
$\hat{\sigma}^2=6.57$		$\hat{\sigma}^2=6.56$	

4.3 纹理分类

纹理分类研究中, 分类器一般是根据测试样本的参数和训练样本参数间的距离设计的。但是, 由于每一类基于高斯图模型的邻域不一样, 因此, 其参数长度各异。为消除邻域点和参数长度不一致的影响, 利用高斯图模型的边缘分布, 本文提出了一种基于最大后验概率的有监督的纹理分类算法。

假设这些纹理特征是独立的, 则训练纹理图像的特征向量由 $\theta = (\theta_r, \sigma_r \in \eta)$ 表示。对每一类训练纹理样本, 计算它的样本参数均值 $\bar{\theta}_k = (\bar{\theta}_{k,r}, \bar{\sigma}_k: r \in \eta_k)$, 下标 k 表示第 k 类的样


本训练特征。对图像中的每一个像素, 设定一个以测试图像中某个像素 s 为中心的窗口 W 。按照贝叶斯规则, 使用下面的最大后验概率的算法形式来进行纹理分类。

$$g_k(X) = \arg \min_k \sum_{s \in W} \left[2 \ln \bar{\sigma}_k + \frac{(x_s - \sum_{r \in S_{1s}} \bar{\theta}_{k,r} x_r)^2}{\bar{\sigma}_k^2} \right] \quad (13)$$

式中, x_s 是 s 点的灰度值, x_r 是点 s 的邻域点的灰度值。采用最大后验概率分类测试纹理图像, 即哪一类纹理的后验概率最大, 则测试纹理图像就属于哪一类。

5 实验结果

Vistex 纹理库是彩色纹理图像分析领域的标准测试库。为了验证 3 种颜色空间中基于高斯图模型的纹理特征的可靠性, 首先从 Vistex 纹理库中选择 12 幅纹理图像合成 2 幅 Mosaics 图像, 用于图像分割实验。Mosaics1 由 4 幅图像组成。对 Mosaics1 的分割实验, 主要是比较基于高斯图模型的纹理特征分别在 RGB、YCbCr 和 HSI 空间中的有效性。3 种空间的图像分割结果见图 3。




(a) Mosaics1 图像 (b) RGB 空间的分割结果 (c) YCbCr 空间的分割结果 (d) HSI 空间的分割结果

图 3 在不同彩色空间下利用 PCA 降维和高斯图模型纹理特征得到的分割结果

从图 3 可以看出, 在 RGB 和 YCbCr 空间的分割效果很好, 准确分割率分别为 91.08% 和 90.91%。而在 HSI 空间中的分割效果较差, 分割准确率为 84.34%。造成这种情况的主要原因是: 经过 PCA 降维后在 RGB 和 YCbCr 空间中保留的主成分贡献率较高, 因而更多保留了原图像的信息, 而 HSI 空间降维后的分量保留原图像的信息相对较少。

Mosaics2 由 8 幅图像组成。对 Mosaics2 的分割实验主要验证用 PCA 方法降维后提取基于高斯图模型的纹理特征是否比直接转化为灰度图后提取的特征更有效, 这里采用自适应 Lasso 估计。作为比较, 首先将彩色图直接转换为灰度图进行分割实验。此外, 由图 3 知道, 在 HSI 空间中分割效果较差, 因此本次实验中本文的分割实验仅在 RGB 和 YCbCr 空间中进行。结果见图 4。



(a) 原图像; (b) 真实的分割结果; (c) 转换为灰度图后的分割结果; (d) RGB 空间中高斯图模型的 aLasso 估计的参数和邻域得到的分割结果; (e) YCbCr 空间中高斯图模型的 aLasso 估计的参数和邻域得到的分割结果

图 4 利用高斯图模型参数得到的分割结果

从图 4(c)看出,将彩色图转换为灰度图后的分割结果较差。与标准分割图 4(b)相比较,图 4(c)中的分割准确率仅为 51.87%。图 4(d)和图 4(e)显示在 RGB 和 YCbCr 空间中由本文算法所得到的分割准确率分别达到 80.51%和 79.77%。

因此,根据图 3 和图 4 显示的效果。本文提出的结合颜色空间的 PCA 降维和高斯图模型的模型选择的结果对纹理图像分类取得了较好的结果,这反映了本文算法对高斯图模型的结构学习的准确性,同时证明了本文算法在彩色纹理分析中是有效的。

为了更进一步分析纹理,从 Vistex 纹理库中随机选取 512×512 像素的 60 幅自然纹理图像作为测试数据,将每一个 512×512 像素的 Vistex 纹理看作是一类,将该类纹理用 PCA 降维后再提取基于高斯图模型的纹理特征。每幅图像被分成 128×128 像素的 49 幅子图像,共得到 $49 \times 60 = 2940$ 幅图像。将其中 $9 \times 60 = 540$ 幅子图作为训练图像数据库,将另外 $29 \times 60 = 1740$ 幅图像作为测试样本库,并统计其准确分类率。降维实验分别在 RGB 和 YCbCr 彩色空间中进行。

由于 RGB 和 YCbCr 空间中 PCA 降维后的分类准确率差别不大,因此仅在 RGB 空间和灰度图中利用小波纹理特征^[15]、Gabor 滤波器纹理特征^[15]和基于 4 阶高斯马尔可夫随机场模型的纹理特征进行分类,并以此结果进行比较。这里,使用 Haar 小波的 3 层分解。由于高频分量往往包含噪声,因此仅选用剩下的 7 个分量,并计算其均值,以此提取小波特征。Gabor 滤波器有 4 个方向: $\pi/4, \pi/2, 3\pi/4, \pi$; 5 个尺度:1, $\sqrt{2}, 2, 2\sqrt{2}$ 和 4,共有 20 个滤波器,Gabor 纹理特征包括图像 Gabor 小波变化幅度的均值和标准差。然后,分别在 RGB 空间、YCbCr 空间和灰度图中利用高斯图模型的 Lasso 估计和自适应 Lasso 估计来提取纹理特征并进行分类实验。表 2 显示各种方法的分类结果比较。

表 2 不同方法的纹理分类准确率(%)比较

纹理特征	最低准确率	最高准确率	平均准确率
灰度图中小波特征	6.69	100	58.62
RGB 中小波特征	3.45	100	63.79
灰度图中 Gabor 特征	10.34	100	59.20
RGB 中 Gabor 特征	10.34	100	59.77
灰度图中 GMRF 特征	0	100	80.63
RGB 中 GMRF 特征	3.45	100	84.54
灰度图中 GGM 的 Lasso 特征	0	100	74.17
灰度图中 GGM 的 aLasso 特征	0	100	84.43
YCbCr 中 GGM 的 Lasso 特征	10.34	100	88.51
RGB 中 GGM 的 Lasso 特征	6.69	100	88.10
YCbCr 中 GGM 的 aLasso 特征	41.38	100	90.75
RGB 中 GGM 的 aLasso 特征	37.93	100	91.80

首先验证 PCA 降维后提取的各种纹理特征是否比直接将彩色图转换为灰度图后提取的纹理特征更有效。通过表 2 中比较显示,PCA 降维后各种方法的纹理分类结果明显要好于将其转换为灰度图后分类的结果。使用 PCA 降维后,又在 RGB 空间中比较了基于高斯图模型、GMRF 和小波特征的纹理分类结果。结果显示,基于高斯图模型的纹理分类结果比其它几种方法都好。在 RGB 空间、YCbCr 空间中利用高斯图模型的 Lasso 估计和自适应 Lasso 估计提取的纹理特征对每种纹理都进行了有效识别,并取得了较高的分类准确率,基

于 Lasso 估计的分类结果为 88.1%和 88.51%,基于自适应 Lasso 估计的分类结果则达到 90.75%和 91.80%。因此,本文算法有很好的稳定性和很高的分类准确率。

结束语 纹理分析是图像理解和计算机视觉等领域研究的重点和难点。高斯图模型具有完备的数学理论,其包容性很强,内涵很广,可以充分利用建模对象的先验知识,有非常广阔的应用前景。为了使彩色纹理中颜色信息损失最小,且降低纹理分类的复杂度,本文以主成分分析理论和高斯图模型理论为基础,提出彩色纹理图像的分类方法。利用 PCA 方法先将彩色纹理图像降维,然后利用惩罚正则化技术估计参数和选择邻域,以此构建纹理模型。实验结果显示,本文提出的算法在彩色纹理图像分析中有很好的应用前景。

参考文献

- [1] Kardan M, Buf Jmh Du, Span M. Texture feature performance for images segmentation [J]. Pattern Recognition, 1990, 23(3/4): 291-309
- [2] 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] Lauritzen S. Graphical Models [M]. Oxford Statistical Science Series. London, Oxford University Press, 1996
- [4] Jordan M I. Graphical models [J]. Statistical Science(Special Issue on Bayesian Statistics), 2004, 19: 140-155
- [5] Edwards D M. Introduction to Graphical Modelling (2nd Ed) [M]. New York: Springer, 2000
- [6] Jonathon S. A Tutorial on Principal Component Analysis [EB/OL]. <http://www.snl.salk.edu/~shlens/pca.pdf>, 2009
- [7] 安志勇,赵珊,周利华. 基于形状和纹理的图像检索[J]. 计算机科学, 2006, 33(11): 225-228
- [8] Rue H, Held L. Gaussian Markov random fields: theory and applications [M]. Boca Raton, Chapman & Hall/CRC, 2005
- [9] Bader D A, Já 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
- [10] MIT VisTex, texture database [EB/OL]. <http://vismod.media.mit.edu/vismod/imagery/VisionTextur%e/vistex.html>, 1995
- [11] Tibshirani R. Regression shrinkage and selection via the lasso [J]. Journal of the Royal Statistical Society, Series B, 1996, 58: 267-288
- [12] Zou H. The adaptive Lasso and its oracle properties [J]. Journal of the American Statistical Association, 2006, 101(476): 1418-1429
- [13] Efron B, Hastie T, Johnstone I, et al. Least angle regression [J]. Annals of statistics, 2004, 32(2): 407-451
- [14] 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
- [15] 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