

文章编号: 1007-4619 (2001) 02-0100-04

# 利用基于小波的尺度共生矩阵进行纹理分析

吴 均, 赵忠明

(中国科学院 遥感应用研究所, 国家遥感工程技术研究中心, 北京 100101)

**摘 要:** 提出了一个在尺度空间提取特征的新方法, 它的特点是提取尺度之间的依存关系, 而非尺度间的独立特征, 和传统方法相比, 它更全面、更准确地刻画了纹理的尺度特性。具体做法是, 首先构造一个反映尺度依存关系的矩阵(本文称之为尺度共生矩阵), 然后在此基础上进行特征提取分类。实验结果表明: 用基于尺度共生矩阵的分类方法可以得到较好的分类结果。

**关键词:** 共生矩阵; 尺度共生矩阵; 框架小波变换; 纹理分类

**中图分类号:** TP751.1      **文献标识码:** A

## 1 引 言

纹理可以看成是表示灰度空间分布的属性<sup>[1]</sup>, 纹理分析在诸如遥感、景物分析、医学影像分析等领域都有着重要的应用价值, 然而由于无法从灰度图像中直接得出纹理的完整信息, 故纹理分析一直都被认为是一个极富挑战性的课题。

传统的纹理分析方法可分为两大类, 即统计法和结构法<sup>[2,3]</sup>, 统计法利用像素间的局部相关性来刻画纹理, 而结构法则使用纹理基元和合成规则描述纹理。有关纹理分析方法的详细综述请参阅文献<sup>[4,5]</sup>, 这些纹理分析方法有一个共同的特点, 即它们都是从单一尺度上提取纹理特征, 显然这是不充分的。事实上纹理特性的一个主要方面就是尺度特性, 已有实验结果表明, 人类视觉系统在进行纹理处理时是以多尺度方式进行的<sup>[6]</sup>。根据这一观点, 基于多尺度的纹理分析方法已引起人们的极大兴趣, 其中以基于小波的多尺度分析法最引人注目<sup>[7,8]</sup>。

基于小波的纹理分析法, 主要是利用小波对图像进行多尺度分解, 然后在每个尺度上独立地提取特征, 进而对其进行组合, 形成一个特征向量, 最后对纹理图像进行分类, 这些方法的区别仅在于提取特征时, 所提取的方式和数量不同。

本文提出了一个在尺度空间提取特征的新方法, 它的特点是提取尺度之间的依存关系, 而非尺度

间的独立特征。它基于以下的事实: 不同纹理其信息从一个尺度到另一个尺度间的变化是不同的, 很显然该特征更具一般性。具体做法是, 首先构造了一个反映尺度依存关系的矩阵(本文称之为尺度共生矩阵), 然后在此基础上进行特征提取分类。实验结果表明, 基于尺度共生矩阵的纹理特征, 是非常有意义的特征, 利用该特征可获得较好的纹理分类结果。

## 2 离散框架小波变换

离散框架小波变换(Discrete Wavelet Frame)是一个有冗余的小波表示, 它和小波变换非常类似, 所不同的就是在分解时没有子采样这一步, 图1给出了一维情况下的离散框架小波变换。

一维离散框架小波变换具有以下简单的分解方法:

$$d_i(k) = [g_i^T * x], (i = 1, 2, \dots, N) \quad (1)$$

$$x_N(k) = [h_N^T * x] \quad (2)$$

相邻尺度之间的关系可表示如下:

$$x_{i+1}(k) = [h \uparrow 2^i * x_i(k)], (i = 0, 1, \dots, N) \quad (3)$$

此处  $x_0 = x$  为原始图像,  $h$  和  $g$  是对应小波的低通和高通滤波器,  $\uparrow m$  表示由相邻元素间插入  $m$  个 0 后得到的序列。对于二维离散框架小波, 亦有相似的结论。




图 1 框架小波分解

Fig. 1 Frame wavelet decomposition

由图 1 看出,利用框架小波分解,可以得到一系列的子图像,  $x = x_0, x_1, \dots, x_N$ , 它们是在不同尺度下的低频部分,由于没有进行子采样,所有子图像的尺寸都是相同的。

在我们的纹理分析方法中,我们利用了小波包 Wavelab<sup>[9]</sup>,小波选用的是 Coiflet 小波。

### 3 尺度共生矩阵

设  $x$  是一个正方形离散纹理,包含有限数目的灰度级。 $x$  的定义如下:

$$x = \{((i, j); g) \mid (i, j) \in D, g = x(i, j) \in [0, G], g \in I\} \quad (4)$$

这里  $D = \{i, j \mid i \in [0, M], j \in [0, M], i, j \in I\}$ ,  $I$  是整数的集合,  $M$  是  $x$  定义域的边长,  $G$  是  $X$  中的灰度级的数目。

我们定义尺度共生矩阵,  $\Phi_k(i, j)$ , 为尺寸是  $G$  的方阵。它是相邻两尺度  $x_k$  和  $x_{k+1}$  的函数。

$$\Phi_k(i, j) = \{ \phi_{ij}(x_k, x_{k+1}) \} \quad (5)$$

它的元素中  $\phi_{ij}$  是相邻尺度的共现灰度的频率, 其定义为

$$\phi_{ij}(x_k, x_{k+1}) = \# \{ (m, n) \mid (m, n) \in D, x_k(m, n) = i, x_{k+1}(m, n) = j \} \quad (6)$$

这里  $\#$  表示集合中元数的数目。

很显然这里矩阵  $\Phi_k$  并没有归一化, 一个简单的归一化方法是:

$$\begin{aligned} \Phi_k &= \Phi_k / N \\ N &= \sum_i \sum_j \phi_{ij} \end{aligned} \quad (7)$$

### 4 基于尺度共生矩阵的特征抽取

虽然尺度共生矩阵在许多方面包含了纹理的统计特性,但它并不是直接作为纹理分割或分类的特征,一般来讲,是由尺度共生矩阵构造一些统计量,并以此作为纹理特征。本文中利用常用的由 Haralick 导出的统计量<sup>[10]</sup>,它们是:

$$f_1 = \sum_{i,j} \Phi_k(i, j)^2 \quad (8)$$

$$f_2 = - \sum_{i,j} \Phi_k(i, j) \log \Phi_k(i, j) \quad (9)$$

$$f_3 = \sum_{i,j} \frac{(1 - \mu_i)(1 - \mu_j)}{\sigma_i \sigma_j} \Phi_k(i, j) \quad (10)$$

$$f_4 = \sum_{i,j} \frac{1}{1 + (i - j)^2} \Phi_k(i, j) \quad (11)$$

$$f_5 = \sum_{i,j} (i - j)^2 \Phi_k(i, j) \quad (12)$$

$$f_6 = \sum_{i,j} ((i - \mu_i) + (j - \mu_j))^3 \Phi_k(i, j) \quad (13)$$

$$f_7 = \sum_{i,j} ((i - \mu_i) + (j - \mu_j))^4 \Phi_k(i, j) \quad (14)$$

$$f_8 = \frac{\sum_{i,j} ij \Phi_k(i, j) - \mu_i \mu_j}{\sigma_i \sigma_j} \quad (15)$$

其中:

$$\mu_i = \sum_j \Phi_k(i, j)$$

$$\mu_j = \sum_i \Phi_k(i, j)$$

$$\sigma_i = \sum_j (i - \mu_i)^2 \Phi_k(i, j)$$

$$\sigma_j = \sum_i (j - \mu_j)^2 \Phi_k(i, j)$$

$\mu_i, \mu_j, \sigma_i$  和  $\sigma_j$  分别是行与列的均值及方差。

这样得到了由尺度共生矩阵提取特征的一般过




图 2 特征提取过程

Fig. 2 Feature extraction

程,对于每个尺度  $k$ ,可构造一个共生矩阵  $\Phi_k$ ,它描述了由尺度  $k$  到尺度  $k-1$  的特性,所有的  $\Phi_k$  ( $k=1,2,\dots$ )便描述了纹理在尺度空间的特性。这一过程见图 2。

## 5 实验结果

我们使用了 16 个 Brodatz 纹理(图 3),对所提算法进行了验证。在实验中,选用了  $k$  均值最近邻域算法( $k$ -NN)。该算法的原理非常简单,若设已知纹理的类别数为  $m$ ,经过训练得到每种类别所对应的特征向量,当要把一未知样本(纹理) $x$  分类的时候,首先选出  $x$  的  $k$  个最近邻,设这  $k$  个最近邻中来自每一类样本数目分别为  $k_1, k_2, \dots, k_m$ , ( $k_1 + k_2 + \dots + k_m = k$ ),则按照 Bayes 检验,判决规则为

$$k_i = \max \{k_1, k_2, \dots, k_m\} \rightarrow x \in c$$

$x$  的  $k$  个最近邻是由  $x$  提取的特征向量与训练集中的特征向量的距离决定的。换句话说,在  $x$  的  $k$  个邻域中,若属于  $c$  类的最多,则将  $x$  也归为  $c$  类。




图 3 原始纹理图像

Fig. 3 Original texture images

每个纹理图像的尺寸是  $128 \times 128$ 。它们被分成 16 个  $32 \times 32$  的子图像,其中前 8 个用作训练集,后 8 个作为待分集(图 4)。

对每个子图像进行框架小波分解,在实验中,为兼顾计算量和特征量的大小,分解深度选为 2;为了减少共生矩阵的尺寸,将原始图像的灰度级重新量化为 32 级。




图 4 测试图像的选定

Fig. 4 Selection of test images

将实验结果分别与灰度共生矩阵法(GLCM),高斯马尔可夫模型法(GMRF),Gabor 能量法(GE)和分形法(FD)进行了比较,结果见表 1,表 1 的数据表示正识率。实验的类别数分别是 2 类、4 类、8 类和 16 类。

表 1 实验结果

Table 1 Test results

实验方法	2 类	4 类	8 类	16 类
GLCM	0.9212	0.8543	0.7055	0.5880
GMRF	0.8725	0.7458	0.5764	0.4359
GE	0.9304	0.8590	0.7225	0.6118
FD	0.9134	0.8419	0.7147	0.6097
SCM	0.9389	0.8655	0.7567	0.6532

从表 1 可以看出,利用尺度共生矩阵提取的特征,进行纹理分类可得到更好的分类结果,不管是类别少还是多,都如此,这进一步表明尺度共生矩阵含有更充分的纹理信息。

## 6 结论与讨论

由理论分析到实验结果都表明,反映尺度间变化的尺度共生矩阵含有充分的纹理信息,所以基于尺度共生矩阵的分类方法可以得到更好的分类结果,同时从某种意义上讲,描述纹理的尺度间的相互关系与描述纹理的空间关系同等重要,所以从多尺度这一特性入手,可得到更加有效的特征。

当然,如果能将反映纹理空间尺度变化信息的尺度共生矩阵(动态信息)和反映纹理信息的灰度共生矩阵法(静态信息)相结合,可以进一步提高纹理分类的精度,这将是下一步的工作方向。

## 参 考 文 献 (References)

- [1] Duda R. O. Pattern classification and scene analysis [M]. Wiley & Sons, Inc., 1973.
- [2] Haralick R M, Shanmugam K, Dinstein I. Texture features for image

- classification [J]. *IEEE Trans. SMC*, 1973, **3**: 610—621.
- [3] Fu K S. Syntactic methods in pattern recognition [M]. Academic Press, New York, 1974.
- [4] Ojala T, Pietkainen M, Harwood D. A comparative study of texture measures with classification based on feature distributions [J]. *Pattern Recognition*, 1996, **29**(1): 51—59.
- [5] Reed T R, DuBuf J M H. A review of recent texture segmentation and feature extraction techniques. [J]. *CVGIP: Image Understanding*, 1993, **57**(3): 359—372.
- [6] Daugman J G. An information-theoretic view of analog representation in striate cortex [J]. *Comp. Neurosc*, 1990, 403—424.
- [7] Laine A, Fan J. Frame representation for texture segmentation [J]. *IEEE Trans. Image Processing*, 1996, **5**: 771—779.
- [8] Unser M. Texture classification and segmentation using wavelet frames [J]. *IEEE Trans. Image Processing*, 1995, 4(11): 1549—1560.
- [9] Wavelab. <ftp://playfair.stanford.edu/pub/wavelab>.
- [10] Haralick R M. Statistical and structural approaches to texture [J]. *Proc. IEEE*, 1979, **67**: 786—804.

## Scale Co-occurrence Matrix for Texture Analysis Using Wavelet Transform

WU Jun, ZHAO Zhong-ming

( Institute of Remote Sensing Applications, CAS, National Engineering Research Center for Geoinformatics, Beijing 100101, China)

**Abstract:** In this paper, we proposed a new method for image feature extraction within scale space. The new method captures the relation of features between different scales, but not the features within a single scale space. Compared with the traditional methods, the proposed method can represent the scale property of texture better. In practice, we first construct a scale-based concurrent matrix (SCM) which reflects the relation between different scales; and then using the matrix calculate some useful measurements as the features for texture classification. Experiments also show that the proposed method can get more accurate results for texture classification than the traditional texture classification methods.

**Key words:** concurrent matrix; scale-based concurrent matrix; frame wavelet; texture classification