

基于分维特征和反向传播神经网络的 自然纹理识别*

刘 泓 莫玉龙

(上海大学嘉定校区通信与信息工程学院, 上海 201800)

摘 要 提出一种利用分维特征, 即自然纹理的自相似性进行纹理识别的研究。利用原始图像、高灰度图像、低灰度图像、四个方向(0° , 45° , 90° , 135°)的梯度图像及二阶多分维共八个分维数作为特征值; 分维的计算采用改进的盒子计数法(MBCM); 最后利用反向传播(BP)神经网络进行纹理的分类识别。实验结果与其它技术进行了比较, 并提出利用维纳滤波进一步改进分类性能。

关键词 分维, 盒子计数法, 纹理分析, 分类。

自然界中许多事物不同程度地具有自相似性。自然纹理图像也是如此。自相似性在描述自然界中起着重要的作用。Mandelbrot^[1]提出了分维几何来描述这些复杂的自相似形态。分维的概念也可以用来测量、分析纹理图像。Pentland^[2]认识到三维图像表面的粗糙或光滑程度与分维模型的结论很接近, 可以用分维数对这些区域加以区分。Field^[3]指出许多自然纹理图像具有线性对数功率谱, 而线性对数功率谱又可以对应于分维数, 这样分维的估计就可以用谱的估计代替。Wen^[4]就是利用傅里叶域的功率谱的最大似然估计来分析自相似的纹理, 并用这种方法进行核磁共振图像(MRI)的分析。但是一般图像都是空间域的。如果要用傅里叶域的功率谱来估计分维, 显然要增加大量的傅里叶变换计算量。因此许多学者提出了空间域的分维计算方法。如 Sarker 和 Chaudhuri^[5-7]提出了差分盒子计数法使图像的纹理的分维计算简洁方便。Buczowski^[8]等提出了改进的计算方法, 使分维数的估计更为精确。我们采用改进的盒子计数法(MBCM)估计分维。但是仅一个分维特征是无法对纹理分类的。文献[6]中给出了 Brodatz 一些纹理的分维数, 它们都很接近。为了正确地对纹理进行分类, 必须提取足够的特征。我们采用了八个分维数作为特征值, 利用反向传播神经网络进行纹理的分类识别。实验结果与小波多分辨能量分析的结果进行了比较。

1 图像分维数估计方法

一个集合 $A \in R^n$ 的分维或 Hausdorff-Besicovitch 维数通常大于它的拓扑维数, Pentland^[2]定义如下:

* 国家自然科学基金(69875009)和上海高教局青年基金资助。

收稿日期: 1998-12-29; 收到修改稿日期: 1999-05-04

$$D_f = \lim_{r \rightarrow 0} \frac{\log N_r}{\log (1/r)} \quad (1)$$

这里 N_r 是以 r 为直径的集合覆盖目标物体所需的最小集合数。Sarker 和 Chaudhuri^[5, 6] 提出的差分盒子计数法计算分维具有很大的动态范围, 已经被很多学者所采用。其方法如下: 假设图像具有 $M \times M$ 的像素, 把它的尺度缩小为 $S \times S (M/2 \geq S > 1, S$ 为整数)。这样比例因子为 $r = S/M$ 。如果一个三维图像它的 (x, y) 表示二维图像的像素位置, 第三维表示灰度值。 (x, y) 空间分割为 $S \times S$ 的小块, 灰度值也作相应比例的缩小分割。这样一来每个盒子的体积为 $S \times S \times S'$ 。其中 S' 满足下式:

$$[G/S'] = [M/S] \quad (2)$$

G 为总的灰度级数。 $[x]$ 表示大于 x 的最小整数。设第 (i, j) 区域中最小与最大灰度级分别落在第 k 和第 l 个盒子, 这样覆盖第 (i, j) 区域所需的盒子数为:

$$n_r(i, j) = l - k + 1 \quad (3)$$

覆盖整个目标物体所需的盒子数为:

$$N_r = \sum_{i,j} n_r(i, j) \quad (4)$$

由此可以利用 (1) 式估计图像的分维数。

Buczowski^[8] 等研究了 r 的各种取法对分维数估计的影响, 提出用 $\log N_r$ 和 $\log (1/r)$ 的均方斜率来计算分维数。在本文中尺度 S 的选择为 $S = 2^i, i$ 为整数 ($2 \leq S \leq M/2$)。分维数计算过程如下:

- 1) 把输入图像分别存入寄存器 I^{\max} 和 I^{\min} (I 表示图像的灰度值);
- 2) 令 $S = 2, r = S/M$;
- 3) 利用 (2) 式计算 S' ;
- 4) 把图像映射缩小 $1/4, I_{i/2, j/2}^{\max} = \max (I_{i, j}^{\max}, I_{i+1, j}^{\max}, I_{i, j+1}^{\max}, I_{i+1, j+1}^{\max}), I_{i/2, j/2}^{\min} = \min (I_{i, j}^{\min}, I_{i+1, j}^{\min}, I_{i, j+1}^{\min}, I_{i+1, j+1}^{\min})$, 利用 (3)、(4) 式分别计算 n_r 和 N_r ;
- 5) S 增加一倍, 转第 3 步直到 $S = M$;
- 6) 利用 (1) 式计算分维数或用 $\log N_r$ 和 $\log (1/r)$ 的均方斜率来计算分维数。

2 纹理图像的分维特征提取

为了识别纹理图像, 选择了八个分维数特征。

第一个特征选择原始图像的分维数, 也就是利用第一部分叙述的计算方法求出图像的分维数 D_{f1} ($2 \leq D_{f1} \leq 3.0$)。

特征 2 和特征 3 分别选取高灰度值图像 I_2 和低灰度值图像 I_3 。这是因为很多纹理图像的分维数是很接近或相等的, 但它们的灰度直方图分布是不一样的。为此构造高灰度值图像 I_2 和低灰度值图像 I_3 ,

$$I_2(i, j) = \begin{cases} I(i, j) - L_1, & I(i, j) > L_1 \\ 0, & \text{otherwise} \end{cases} \quad (5)$$

$$I_3(i, j) = \begin{cases} 255 - L_2, & I(i, j) > 255 - L_2 \\ I(i, j), & \text{otherwise} \end{cases} \quad (6)$$

其中 $L_1 = g_{\min} + av/2, L_2 = g_{\max} - av/2, g_{\max}, g_{\min}$ 和 av 分别为图像 I 的最大、最小和平均

灰度值。

特征 4~ 7 分别取自纹理图像的四个方向的梯度图像(0°, 45°, 90°, 135°)的分维数。因为纹理图像具有一定的方向性,取方向梯度有助于分辨不同方向的纹理。本文选用 Kirsch 边缘算子计算方向梯度。Kirsch 边缘算子如图 1 所示。卷积运算后形成相应的梯度图像,并计算各自的分维数。




Fig. 1 Kirsch edge detector

特征 8 选用原始图像的二阶多分维数^[7]。其定义如下:如果函数

$$\chi(q, r) = \sum_{i,j} \left[\frac{n_r(i, j)}{N_r} \right]^q \tag{7}$$

那末

$$(q - 1)D_f(q) = \lim_{r \rightarrow 0} \frac{\ln \chi(q, r)}{\ln r}, \quad q \neq 1 \tag{8}$$

二阶多分维数反映了盒子数的二阶分布情况,也就是体现了覆盖各个区域所需盒子数二阶矩的特征。

3 自然纹理图像分类实验

选用取自 <http://sipi.usc.edu/services/database/Database.html> 中的 Brodatz 自然纹理图像 D9、D15、D19、D29、D68、D84 作为实验用图像。参见图 2。因为这些图像是南加州大学信号处理组提供给各研究单位测评算法性能的通用图像数据库,而且都是自然纹理图像。D9 是草地, D15 是稻草, D19 是羊毛布, D29 是沙子, D68 是木纹, D84 是酒椰叶的纤维。原始纹理图 D9 的分维计算结果见图 3。其它图像的分维计算结果见表 1。



Fig. 2 Texture images D9, D15, D19, D29, D68, D84 (from left to right)

Table 1. Fractal dimension of texture images

texture	D9	D15	D19	D29	D68	D84
D_f	2.7174	2.6628	2.5663	2.5747	2.5152	2.5503

为了对纹理进行分类识别实验,在 512×512 图像中随机地选取 256×256 的样本图像,并形成所需的高灰度值图像 I_2 和低灰度值图像 I_3 及四个方向的梯度图像(0°, 45°, 90°, 135°),并把样本组分为教师训练组和测试组。训练组用来训练反向传播神经网络。每个纹理都随机选取 256×256 的 16 个训练图像和 16 个测试图像。形成的八个分维特征在输入神经网络前统一减去一个常数,使其落在 0 附近。在实验中该常数为 2.487。反向传播神经网络的

输入层有 8 个节点, 隐层为 12 个节点, 输出层有 6 个节点, 对应于 6 个纹理的分类结果。隐层非线性函数采用 MATLAB 中的 `tansig`, 输出层采用 `purelin` 函数。神经网络的训练结果见图 4。测试图像的分类结果全部正确。




Fig. 3 Fractal dimension calculation for texture D9




Fig. 4 Training of the BP neural network

4 比较与讨论

为了比较利用分维特征和小波多分辨能量分析进行纹理分类^[9]的性能, 对各个纹理图像加入零均白高斯噪声, 在不同的信噪比条件下计算它们的特征分维数。由于噪声的加入, 纹理表面的粗糙度增加了, 所以分维数也增加了。从实验结果看(参见图 5 虚线), 在信噪比为 25 dB, 分维法识别纹理的能力还和小波多分辨能量分析法相当。但是随着信噪比的降低, 分类能力急剧下降。为此我们提出利用维纳滤波的方法来改进性能。对所有要识别的图像首先进行 3×3 邻域的维纳滤波, 然后再提取分维特征。此时的分类性能有较大改进(图 5 中实线)。在信噪比为 15 dB 处也有 92% 的分类正确率。

利用组合的八个分维数特征, 可以较好地分类纹理图像。但是在多纹理分割实验中, 不规则边界处的纹理分维特征的计算方法及特征平滑算法都需要进一步研究。




Fig. 5 Classification rate under different signal to noise ratio (dot-dashed line: wavelet method, dashed line: fractal dimension method, solid line: fractal dimension and Weiner filter method)

参 考 文 献

- [1] Mandelbort B B. *Fractal Geometry of Nature*, San Francisco: Freeman Press, 1982.
- [2] Pentland A P. Fractal based description of natural scenes. *IEEE Trans. Pattern Anal. & Machine Intell.* 1984, **6**(6): 661~ 674
- [3] Field D J. Relations between the statistics of natural images and the response properties of cortical cells. *J. Opt. Soc. Am. (A)*, 1987, **4**(12): 2379~ 2394
- [4] Wen C Y, Acharya R *et al.*. Self-similar texture characterization using a Fourier-domain maximum likelihood estimation method. *Pattern Recognition Letters*, 1998, **19**(8): 735~ 739
- [5] Sarker N, Chaudhuri B B. An efficient approach to estimate fractal dimension of texture image. *Pattern Recognition*, 1992, **25**(9): 1035~ 1041

- [6] Sarker N, Chaudhuri B B. An efficient differential box-counting approach to compute fractal dimension of image. *IEEE Trans. on System Man and Cybernetics*, 1994, **24**(1) : 115~ 120
- [7] Chaudhuri B B, Sarker N. Texture segmentation using fractal dimension. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1995, **17**(1) : 72~ 77
- [8] Buczkowski S, Kyriacos S, Nekka F *et al.*. The modified box-counting method: Analysis of some characteristic parameters. *Pattern Recognition*, 1998, **31**(4) : 411~ 418
- [9] Liu Hong, Mo Yulong. Texture analysis and classification based on tree-structured wavelet transform and neural network. *Proceedings of IEEE International Conference on Neural Networks and Signal Processing*, 1995, **2** : 1022~ 1025

Texture Classification Based on Fractal Dimension and BP Neural Network

Liu Hong Mo Yulong

(School of Communication and Information Engineering, Shanghai University, Shanghai 201800)

(Received 29 December 1998; revised 4 May 1999)

Abstract A nature texture classification method based on fractal dimension using self-similar texture characterization is presented. For this purpose, eight fractal dimension (FD) features are used based on the original image, the high gray level image, the low gray level image, four directional (0° , 45° , 90° , 135°) gradient image and the multi-fractal dimension of order two. The fractal dimension is estimated with the modified box-counting method. The texture classification is completed with back propagation (BP) neural network. The results are compared with other techniques. The Wiener filter is used to improve the performance of this method.

Key words fractal dimension, box-counting method, texture analysis, classification.