

一种纹理图象分类方法的研究

张妙兰 付新文

(中国科学技术大学研究生院, 北京 100039)

摘要 提出了一种基于矢量量化的纹理分类方法。通过矢量量化的方法生成原始图象的符号图象,并生成这个符号图象的共生矩阵,选用共生矩阵的4个数字特征构成原始图象的纹理特征向量。使用2个特征向量之间的距离作为匹配的标准,可以实现对纹理图象进行快速匹配分类。

关键词 矢量量化 共生矩阵 符号图象 纹理分类

0 引言

当人们讨论图象的纹理时,指的是图象像素灰度或颜色的某种变化,这种变化是统计相关的,虽然至今尚无关于纹理的定义描述,但是图象或物体的纹理或纹理特征是客观存在的,它反映了图象或物体本身的属性。纹理基元是构成纹理的基本单位,它是一种或多种图象基元的组合。纹理基元的适当排列组合就形成了纹理。图象纹理是图象的重要特征,特别是对灰度呈梯度变化的图象。纹理分析中的纹理分类就是通过图象处理技术提取纹理特征,研究这些纹理在图象中反复出现的局部模式和它们的排列规则,获得对纹理的定量描述,进而对图象或物体进行正确分类。

图象纹理分析在场景分析、医学图象分析、遥感图象分析以及其它领域中有着重要应用。因此近年来一直是人们研究的热门课题。已有的纹理分析方法大致可以分为统计方法和结构方法:统计方法是根据象素灰度的统计特性确定纹理特征,如直方图统计特征法、自相关函数法等。这种方法被用于分析象木纹,沙地及草坪等纹理细而又不规则物体;结构方法是将复杂的纹理图象通过特征提取和分割得到局部基元和它们的属性及其相互关系,对纹理基元及其排列规则进行描述、分析和解释。这种方法适用于分析布料图案或砖的花样等一类由规则基元组成的纹理。除统计方法和结构方法外,还有谱分析方法等。大多数方法有一共同点,就是提取了那些在特定纹理描述中最重要的特征,突出纹理的不同方面。有

的分析方法精度高,但是运算量大;有的方法速度快但又不够精细。

本文提出的纹理分类方法源于这样的考虑:在很多场合,纹理图象的尺寸是较大的,而对于纹理分类,最重要的是提取整幅图象纹理基元排列的结构信息,因此消除次要信息,减少运算复杂度,保留结构信息,可使分类过程加快。本文正是基于这种想法利用矢量量化来减少共生矩阵的维数,以减少运算复杂度来正确实现纹理图象分类的。实现过程是:首先,对图象先进行矢量量化压缩,然后产生压缩图象的共生矩阵,再利用共生矩阵的数字特征构成特征向量,用特征向量做为对纹理图象特征的描述。利用马氏距离作为两个特征向量的判别准则,可对两幅图象进行匹配分类。实验结果表明,本文采用基于矢量量化的压缩图象进行纹理分类是纹理分析的有效(减少了运算复杂度,便于特征提取和匹配分类)方法之一。

1 原理描述

(1) 矢量量化

矢量量化方法经常用于图象压缩。近年来的研究也把矢量量化用于简化图象处理,如增强、分类、边缘提取等。矢量量化方法中最关键的是码书的生成。在实验中我们所用的码书是这样生成的:我们挑选了40幅大小为 256×256 的纹理图象,从每一幅中各自截取 128×128 的一块,这样就得到了40幅 128×128 的纹理图象,用这新的40幅图象做为训练样本。对于 128×128 的纹理图象,以 2×2 象素块

构成一个向量,那么由每幅图象可得到 $(128 \times 128) / (2 \times 2) = 2^{12}$ 个向量。由这 40 幅图象就生成了有 40×2^{12} 个向量的向量组 V ,我们假定这个向量组 V 是研究对象的灰度向量空间的闭包。如此,采用 LBG 算法,以马氏距离为度量函数,对向量组 V 进行训练就获取了码书:

$$\text{马氏距: } Dist_{v_1, v_2} = (v_1 - v_2)^T H^{-1} (v_1 - v_2) \quad (1)$$

$$H = E \{ (v_1 - v_2)(v_1 - v_2)^T \}$$

根据生成的码书对这 40 幅新获取的纹理图象进行编码,于是就生成了 40 幅符号图象,每个符号只需 2 比特存储位,大小为 $64 \times 64 \times 2\text{bit}$ (压缩比为 $(128 \times 128 \times 8) : (64 \times 64 \times 2) = 16 : 1$)。由于这些符号在一定的纹理区域中是随机排列的,而且纹理图象又具有马尔柯夫随机特性,所以我们把这个二维符号图象称为马尔柯夫特征符号随机场,为便于处理,我们给每一个符号一个字节大小的存储位。这是我们对原始图象进行的预处理。

以上是我们对原始图象进行的预处理,以后的分析都是基于这些符号图象的。如此可见,经过矢量量化,我们可以简化对图象的处理。

(2) 灰度共生矩阵

$$P_\delta(i, j) = \# \left\{ (x, y) \mid f(x, y) = i \text{ 且 } \begin{cases} f(x + \Delta x, y + \Delta y) = j \\ \text{或} \\ f(x - \Delta x, y - \Delta y) = j \end{cases} \right. \\ \left. i, j = 0, 1, 2, \dots, L - 1, x, y = 0, 1, 2, \dots, N - 1 \right\} \quad (3)$$

并且 δ 只取 4 个值: $(d, 0)$ 、 (d, d) 、 $(0, d)$ 、 $(d, -d)$ 。

这里实际上只取了东西、东北—西南、南北,东南—西北 4 个方向。这样做了以后,所要处理的数据量大大减少了,当时 $d=1$, 4 个方向的共生矩阵分别记做 $M^{(0,1)}, M^{(1,0)}, M^{(1,1)}, M^{(1,-1)}$ 。在以下的描述中,我们就使用(3)式定义的灰度共生矩阵。

(3) 特征向量的生成

一幅图象的灰度共生矩阵纹理反映了图象灰度在方向、相邻间隔、幅度变化的综合信息,是分析图象的基元模式和它们排列规则的基础。由此可以进一步提取图象纹理的一系列特征。我们对(3)式定义的共生矩阵进行正规化处理,即

$$\hat{P}_\delta(i, j) = \frac{P_\delta(i, j)}{R}, \quad (4)$$

$R = \sum_{i,j} P_\delta(i, j), i, j = 0, 1, \dots, L - 1$ —正规化常数
我们选用了典型的 4 个数字特征:

在上面,我们已经获得了原始纹理图象的符号图象。在这个符号图象上生成图象的共生矩阵,就可以减少运算的复杂度。

灰度共生矩阵方法是一种常用的纹理分析方法,它是图象中两个象素灰度级联合分布的统计形式,能较好的反映灰度级相关性的规律。灰度共生矩阵被定义为灰度为 i 的象素离开某个固定位置 $\delta = (\Delta x, \Delta y)$ 的灰度为 j 的象素的概率,即

$$P_\delta(i, j) = \# \{ (x, y) \mid f(x, y) = i \text{ 且}$$

$$f(x + \Delta x, y + \Delta y) = j, i, j = 0, 1, 2, \dots, L - 1, \\ x, y = 0, 1, 2, \dots, N - 1 \} \quad (2)$$

$\# \{ \Omega \}$ —集合 Ω 的元素个数

(x, y) —象素坐标

L —灰度线

N —行列宽(象素个数)

从这个定义我们看出 δ 的取值范围是 $[-N + 1, N + 1]$,因此有 $(2N + 1) \times (2N + 1)$ 个共生矩阵。每个共生矩阵的维数是 $L \times L$ 。对于一幅 256 灰度级的图象来说,信息量过大。为了去除冗余信息,将矩阵简化为:

$$\text{角相关矩: } Q_1 = \sum_{l_1} \sum_{l_2} \hat{P}_\delta(l_1, l_2)^2$$

$$\text{对比度: } Q_2 = \sum_{l_1} \sum_{l_2} (l_1 - l_2)^2 \hat{P}_\delta(l_1, l_2)$$

$$\text{相关: } Q_3 = \frac{\sum_{l_1} \sum_{l_2} \hat{P}_\delta(l_1, l_2)^2 - \mu_1 \mu_2}{\sigma_1 \sigma_2}$$

$$\text{熵: } Q_4 = \sum_{l_1} \sum_{l_2} \hat{P}_\delta(l_1, l_2) \log_2 \hat{P}_\delta(l_1, l_2)$$

其中:

$$\mu_1 = \sum_{l_1} l_1 \sum_{l_2} \hat{P}_\delta(l_1, l_2)$$

$$\mu_2 = \sum_{l_2} l_2 \sum_{l_1} \hat{P}_\delta(l_1, l_2)$$

$$\sigma_1 = \sum_{l_1} (l_1 - \mu_1)^2 \sum_{l_2} \hat{P}_\delta(l_1, l_2)$$

$$\sigma_2 = \sum_{l_2} (l_2 - \mu_2)^2 \sum_{l_1} \hat{P}_\delta(l_1, l_2)$$

对于每一幅图象,都可以计算出 Q_1, Q_2, Q_3, Q_4 , 这 4

个数字特征构成一个特征向量 V_f

$$V_f = (Q_1, Q_2, Q_3, Q_4) \quad (5)$$

在实验中我们选取 4 个方向上的共生矩阵 $M^{(0,1)}$, $M^{(1,0)}$, $M^{(1,1)}$, $M^{(1,-1)}$, 对于每一个方向的共生矩阵均可以计算出一个其特征向量 V_f , 我们将这 4 个方向的纹理特征向量平均, 用这个平均的特征向量来表征原始图象的具有旋转不变特性的特征纹理特征。

有了以上概念, 现在我们就可以详细的描述在我们实现的这个纹理图象分类方法。

2 分类方法的实现

(1) 码书的生成

① 选择 40 幅 256×256 的纹理图象。从每一幅中各自截取 128×128 的一块, 这样就生成了新的 40 幅纹理图象;

② 对每一幅纹理图象生成其向量组。以 2×2 象素块构成一个向量, 这样就将一幅原始图象转化为一组向量, 这样就可从 40 幅纹理图象生成 40 组向量。将这 40 组向量组合成一个大向量组 V ;

③ 采用标准的 LBG 算法, 以马氏距做为判别准则, 对这一个大向量组 V 进行训练。在实验中我们没有做加速处理。这样就获取了码书 (Codebook)。马氏距的定义如(1)式。

(2) 纹理特征表的生成

① 根据生成的码书对 40 幅新获取的纹理编码, 于是就生成了 40 幅大小为 64×64 的符号图象 (即特征符号随机场);

② 对这 40 幅符号图象的特征符号随机场进行纹理分析, 每幅图象生成 4 个方向上的共生矩阵, 并生成其相应的能量正规化 (为了消除照明不均对纹理特征的影响) 特征向量 $V_{f1}, V_{f2}, V_{f3}, V_{f4}$, 取其平均值 $\bar{V}_f = (V_{f1} + V_{f2} + V_{f3} + V_{f4}) / 4$, 这样每幅图象就对应一个 \bar{V}_f 作为它的训练特征 (标准特征)。

(3) 分类

① 在原始的 256×256 的图象中任意截取 128×128 的一块作为校验样本;

② 依上所述方法获取欲匹配纹理的符号图象, 并获取它的纹理特征向量;

$$V_{f_{exercise}} = (0.12710803671125, 1.6104083994709, 2.4518537488424, 0.402225220231737),$$

$$V_{f_{check}} = (0.12995558144903, 1.6543816137566, 2.4389556215852, 0.40642149718442),$$

$$Dist_{V_{f1}, V_{f2}} = 0.0046263825630634$$

③ 我们以距离: $Dist_{V_{f1}, V_{f2}} = (V_{f1} - V_{f2})^T (V_{f1} - V_{f2})$ 作为判别标准;

距离最小的两个特征向量所对应的图象纹理是匹配的, 应该归属于同一类, 这样就可以将该校验样本归于已得到的 40 类中的某一类。

3 实验结果分析及结论

依据以上的分析, 我们做了 4 组实验, 每一组的码书容量分别取为 4、8、16 和 32, 所的结果列于表 1 中。

表 1 基于矢量量化的纹理分类实验结果

码书容量	4	8	16	32
分类准确率 (%)	75	80	85	87.5

从表 1 中列出的结果可见, 随着码书容量的增大, 分类的准确率也在增大。依据这一结果, 我们可以根据实际需要调节码书容量来改变分类准确率, 进而可以调节分类的速度。

与常用分类方法比较还可以看到, 通过矢量量化对原图象生成其对应的符号图象 (特征符号随机场), 有效地降低了原图象的灰度级数目, 从而降低了共生矩阵的维数, 减少了运算量, 提高了分类速度。同时, 由于由原始图象生成的符号图象很好地保留了原始图象的纹理结构信息, 分类的准确度也得到了较好的保证。见表 2 和图 1 所示的比较结果。

表 2 新分类算法与常用分类算法的比较

	正确分类 样本数	误分类 样本数	正确率 (%)
标量量化算法	29	11	72.5
Gabor 单层分类算法	32	8	80.0
矢量量化纹理分类 (码书容量=4)	30	10	75.0

由图 1 可见, 特征符号随机场很好的反映了原始图象纹理结构方面的信息; 而且训练样本特征符号随机场和校验样本特征符号随机场之间是可以比拟的。该训练样本的特征向量、校验样本的特征向量及二者之间的距离分别为:

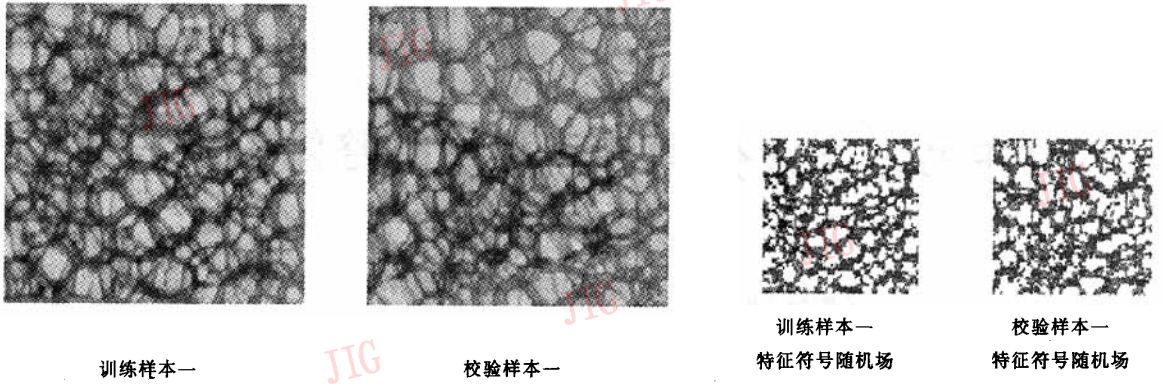


图 1 特征符号随机场(均衡化后)

综上所述,本文提出的一种基于矢量化压缩图象进行纹理分类的方法是一种切实可行的有效的纹理分类算法,特别是在纹理图象尺寸较大,信息冗余度也大的情况下。

参 考 文 献

1 Chang T, Kuo C-C J. Texture analysis and classification with tree-structure wavelet transform. IEE Trans Image Processing,

1993,2(4):429~441.

2 Unser M. Texture classification and segmentation using wavelet frames. IEEE Trans Image Processing, 1995, 4 (11): 1549 ~ 1560.

3 Ma Xiaochuan, Fu Xinwen, Hou Chaohuan. Texture classification based on feature symbol random field. In: 1998 Fourth International Conference on Signal Processing. October 12-16, 1998, Beijing, China, 901~903.

4 徐建华. 数字图象处理. 北京: 科学出版社, 1992.



张妙兰 中国科学技术大学研究生院(北京)副教授。主要从事数字信号处理的教学与科研。主要研究方向为信号处理,数字图象处理和计算机视觉。



付新文 1995 年于西安交通大学电子与信息工程系获学士学位,1998 年于中国科学技术大学研究生院(北京)获硕士学位。主要研究方向为纹理分析,特别是纹理分类的研究。

A Method of Texture Classification Based on Vector Quantization

Zhang Miaolan, Fu Xinwen

(School of Graduate USTC, Beijing 100039)

Abstract This paper gives a method of texture classification based on vector quantization. By using vector quatization to create the symbol images of original images, the cooccurences matrix of these symbol images can be gotten. Four digital features of cooccurences matrix are selected to obtain texture feature vectors of original images. Using the distance between two texture feature vectors as a matching standar, guick match and classification of texture images can be realized.

Keywords Vector quatization, Cooccurence matrix, Symbol image, Texture classification