

基于模糊灰度共生矩阵与隐马尔可夫模型的 断口图像识别

李 凌¹⁾, 黎 明²⁾, 鲁宇明²⁾

¹⁾(南京航空航天大学自动化学院, 南京 210016) ²⁾(南昌航空大学无损检测技术教育部重点实验室, 南昌 330063)

摘 要: 纹理通常由空间分布和灰度分布共同描述, 灰度共生矩阵(GLCM)能兼顾二者, 故广泛应用于纹理分析中。在计算GLCM时, 为降低其维数, 需对纹理图像进行灰度量化, 这必然丢失部分图像信息。灰度量化时, 由灰度值与量化区间中心值的不同距离, 构造出相应的模糊隶属度函数, 并定义了模糊灰度共生矩阵(FGLCM)。通过对断口图像FGLCM的14个特征统计量进行相关性分析, 选择角二阶矩和熵等7个统计量作为特征参数, 并验证了其有效性。最后, 在4类典型断口图像的特征空间上, 采用隐马尔可夫模型(HMM)进行分类识别。实践表明, FGLCM比已有的GLCM能更好地表征断口特性, 且在HMM状态数为3时, 断口分类的平均识别率可达98%。

关键词: 灰度共生矩阵; 模糊灰度共生矩阵; 断口图像; 隐马尔可夫模型

中图法分类号: TN957 文献标志码: A 文章编号: 1006-8961(2010)09-1370-06

Recognition of fracture surface images based on fuzzy gray level co-occurrence matrix and hidden Markov model

LI Ling¹⁾, LI Ming²⁾, LU Yuming²⁾

¹⁾(College of Automation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016)

²⁾(Key Laboratory of Nondestructive Testing (Ministry of Education), Nanchang Hangkong University, Nanchang 330063)

Abstract: Texture is usually depicted by a gray-level distribution along with a certain spatial interaction. Gray level co-occurrence matrix(GLCM) is an appropriate candidate to depicted texture because of its capability of blending spatial interaction with gray-level distribution, thus, it can be widely applied in texture analysis. When calculating GLCM, the gray-level quantization would be needed in order to decrease matrix dimension, and certain information would be lose. A membership function matrix is established whereby the distance which between the real gray-level and the mean of quantization gray-levels area, and then, a newly co-occurrence matrix, namely fuzzy gray level co-occurrence matrix(FGLCM) is proposed. After appropriate features are selected based on FGLCM statistics properties analysis, the hidden markov model(HMM) classification is applied to divide the classical fracture surface image to four kinds. It is proved practically that FGLCM in this paper is better than the GLCM in depicting textures and the FGLCM combined with HMM is efficient performance in fracture surface images classification, and the recognition rate is 98%.

Keywords: gray level co-occurrence matrix; fuzzy gray level co-occurrence matrix; fracture surface image; hidden Markov model

基金项目: 国家自然科学基金项目(60475002); 航空基金项目(2008ZD56003); 江西省自然科学基金项目(2009GZS0090); 江西省教育厅科技项目(GJJ09483, GJJ08209)。

收稿日期: 2008-11-07; 改回日期: 2009-05-16

第一作者简介: 李 凌(1981—), 女, 南京航空航天大学自动化学院测试计量技术与仪器专业博士研究生。主要从事图像处理、模式识别相关研究。E-mail: tina@nuaa.edu.cn, liling35@163.com。

通讯作者: 黎 明, E-mail: limingniat@hotmail.com。

0 引言

断口是断裂失效最主要的残骸,是断裂失效分析的物证。通过对断口进行分析可以找到断裂的原因及影响因素,这在断裂失效分析中起着重要的作用。把图像分析和模式识别技术应用到断口分析中,从断口的 SEM 图像中提取有用的特征信息,并对断口进行模式识别与分类是断裂故障智能化分析的关键。图 1 为 4 类典型的金属断口图像^[1-2]:疲劳




图 1 典型金属断口图像

Fig. 1 Classical metal fracture surface images

灰度共生矩阵 (GLCM) 是分析图像纹理特征的经典二阶统计法^[6]。灰度共生矩阵是空间分布和灰度分布的共同描述,广泛应用于纹理分析^[7],遥感图像^[8]和医学图像分割^[9]中。生成方向 θ 、生成步长 d 和灰度级 L 是 GLCM 的三要素,文献[10]从理论和实践上证明了当 d 足够大时,GLCM 的计算结果趋于一致;文献[11]提出的类别共生矩阵用灰度类别代替灰度级,避免了灰度量化,可有效地监测纹理斑点;Rishi 提出的加权共生矩阵可以有效地进行遥感图像分割^[12]。

为了降低 GLCM 的维数,减少运算量,在计算 GLCM 时要对图像进行灰度压缩,文中称为灰度量化。图像灰度级量化时,必然丢失大量信息,目前,还没有文献涉及灰度量化对 GLCM 的影响。量化时,由灰度值与量化区间中心值的不同距离,本文构造相应的模糊隶属度矩阵,定义了模糊灰度共生矩阵 (FGLCM),并分析了 FGLCM 特征统计量的相关性,选择出断口图像的特征参数。最后,在 4 类典型断口疲劳 (fatigue)、解理 (cleavage)、沿晶 (intergranular)、韧窝 (dimple) 的特征空间上,采用隐马尔可夫模型 (HMM) 对其进行分类识别。

断口呈现出平衡而略带弯曲的密排条纹;解理断口的主要特征是“河流花样”;沿晶断裂的断口形貌呈粒状;韧窝的形貌大部分以空穴为主。可见,断口形貌复杂,具有一定的纹理特征,但不规则,因此,对断口图像分类具有一定的难度。对断口的识别和分类有多种方法,文献[3]基于小波变换的分类方法,识别率较高,但计算复杂;文献[4]应用金属断口表面定量计算的改进算法和加权回归法,其识别率还有待提高;文献[5]中的分类方法依赖于边缘形态分布,且分类识别率不高。

1 模糊灰度共生矩阵

1.1 灰度共生矩阵

GLCM 是图像空间上具有某种位置关系的一对像元灰度对出现的概率,描述在图像中,从灰度为 i 的像素 (其位置为 (x, y)) 出发,统计在 θ 方向上,与之距离为 d 的另一个像素点 $(x + d\cos \theta, y + d\sin \theta)$ 的灰度为 j 同时出现的概率。设灰度图像 $I = [f(x, y)]_{M \times N}$ 有 L 灰度级,则灰度共生矩阵 $G = [g_{\text{GLCM}}(m, n)]_{L \times L}$ 可定义为一个概率分布:

$$g_{\text{GLCM}}(m, n) = P(f(x, y) = m, f(x + d\cos \theta, y + d\sin \theta) = n) \quad (1)$$

式中, $g_{\text{GLCM}}(m, n)$ 表示灰度 m 和 n 在空间上相距 $(d\cos \theta, d\sin \theta)$ 同时出现的概率。GLCM 不仅反映了图像灰度的分布,而且还描述了灰度在空间上的依赖关系,通过选取不同的 θ 和 d ,GLCM 还能够灵活地描述纹理更为细微的特征。

1.2 模糊灰度共生矩阵

一幅图像的灰度通常有 256 级,而级数太多会导致 GLCM 维数较大,计算量也就越大。因此,在

计算 GLCM 之前,常把图像的灰度级压缩到 2^n 级,量化间隔为 $(256/2^n)$,量化区间为 $[(k-1)(256/2^n), k(256/2^n) - 1]$,其中 k 的取值是 $\{1, 2, \dots, 2^n\}$ 。

在 GCLM 计算中,灰度图像 $I = [f(x, y)]_{M \times N}$,当满足 $f(x, y) \in [(k-1)(256/2^n), k(256/2^n))$ 时, $f(x, y)$ 均被量化为 k ,即 $f(x, y)$ 的量化值 $f_0(x, y)$ 等于 k 的概率为 1,量化为其他值的概率为 0。结合模糊集合的概念,根据量化值 $f_0(x, y)$ 取不同值的概率来定义隶属度 $u_0(x, y)$,则有:

$$\forall f(x, y) \in [(k-1)(256/2^n), k(256/2^n))$$

$$u_0(x, y) = \begin{cases} 1 & f_0(x, y) = k \\ 0 & f_0(x, y) \neq k \end{cases} \quad (2)$$

显然,在同一个量化区间内 $f(x, y)$ 与量化区间的中心值 $mn = ((k-1)(256/2^n) + k(256/2^n))/2$ 的距离是不同的,因此,在文中假设 $f(x, y)$ 的量化值并不唯一,而以 mn 为界,把区间分成 $d_1 = [(k-1)(256/2^n), mn)$, $d_2 = [mn, k(256/2^n))$ 两部分,当 $f(x, y)$ 属于不同的区间时,其量化值以不同的概率取相邻的两个值 $\{k-1, k\}$ 或 $\{k, k+1\}$ 。当 $f(x, y) \in d_1$ 时,量化值 $f_1(x, y) = k$ 的概率为 $\mu_1(x, y)$,量化值 $f_2(x, y) = k-1$ 的概率为 $\mu_2(x, y)$;当 $f(x, y) \in d_2$

时,量化值 $f_1(x, y) = k$ 的概率为 $\mu_1(x, y)$,量化值 $f_2(x, y) = k+1$ 的概率为 $\mu_2(x, y)$ 。这样得到灰度量化的矩阵 $F_1 = [f_1(x, y)]_{M \times N}$ 和 $F_2 = [f_2(x, y)]_{M \times N}$ 以及相应的模糊隶属度矩阵 $U_1 = [\mu_1(x, y)]_{M \times N}$, $U_2 = [\mu_2(x, y)]_{M \times N}$,图 2 所示 ($2^n = 32$) 是以 $f(x, y)$ 与量化区间中心值 mn 的不同距离来构造的隶属度函数分别服从线性分布和高斯分布的情况,图中横坐标表示灰度,纵坐标表示的是模糊隶属度。其中由线性隶属度函数得到的矩阵 U_1 和 U_2 分别为


$$\mu_1(x, y) = \begin{cases} 0.5 + 0.5 \frac{|f(x, y) - (k-1)(256/2^n)|}{|mn - (k-1)(256/2^n)|} & f(x, y) \in ((k-1)(256/2^n), mn) \\ 0.5 + 0.5 \frac{|f(x, y) - k(256/2^n)|}{|mn - k(256/2^n)|} & f(x, y) \in (mn, k(256/2^n)) \end{cases} \quad (3)$$

$$\mu_2(x, y) = 1 - \mu_1(x, y) \quad (4)$$


由高斯隶属度函数得到的矩阵 U_1 和 U_2 分别为

$$\mu_1(x, y) = \exp\left(\frac{-(f(x, y) - mn)^2}{2\sigma^2}\right) \quad (5)$$

$$\mu_2(x, y) = 1 - \mu_1(x, y) \quad (6)$$



(a) 线性隶属度



(b) 高斯隶属度

图 2 隶属度函数(实线表示 μ_1 , 点线表示 μ_2)

Fig. 2 Membership Functions(real line represented μ_1 , dot line represented μ_2)

根据上述的隶属度矩阵,定义模糊灰度共生矩阵

$$FG = [fg_{FGLCM}(m, n)]_{L \times L}: \forall f_i(x, y) = m,$$

$$f_j(x + d \cos \theta, y + d \sin \theta) = n, i = 1, 2; j = 1, 2.$$

$$fg_{FGLCM}(m, n) = \sum_{i=1}^2 \sum_{j=1}^2 \mu_i(x, y) \mu_j(x, y) \quad (7)$$

由于模糊隶属度函数是依据灰度值与量化区间中心值的不同距离来构造的,降低了灰度量化的误差,减少了信息丢失量。对比 GLCM,计算 FGLCM 时,当量化灰度级确定后,其线性、高斯隶属度函数矩阵均可提前计算出,而定义式(7)为乘积求和运算,因此,FGLCM 时间复杂度的数量级与 GLCM 的一致。

2 特征提取

2.1 相关性分析

基于共生矩阵,Haralick 定义了熵、对比度、能量、相关、方差逆、差矩、均值和、方差和、和熵、差的方差、差熵、相关信息测度和最大相关系数 14 个描述纹理的特征统计量^[6]。类似地,也用 FGLCM 的 14 个统计量来描述纹理。14 种纹理描述符中,对同一图像纹理从不同方面表现,相互之间具有一定的相关性。对图像采用非重叠窗口求取某一纹理描述

符的系列特征值,构成该纹理描述符的数据序 $x_{k1}, x_{k2}, \dots, x_{k14}$, 则相关系数矩阵 $\mathbf{R} = [r(i, j)]_{14 \times 14}$

$$r_{ij} = \frac{\sum_{k=1}^m |x_{ik} - \bar{x}_i| |x_{jk} - \bar{x}_j|}{\sqrt{\sum_{k=1}^m (x_{ik} - \bar{x}_i)^2} \sqrt{\sum_{k=1}^m (x_{jk} - \bar{x}_j)^2}} \quad (8)$$

$$\bar{x}_j = \frac{1}{m} \sum_{k=1}^m x_{jk}, \bar{x}_j = \frac{1}{m} \sum_{k=1}^m x_{jk} \quad (9)$$

对铝合金断口图像进行特征参数的相关性分析,得到 FGLCM 的 14 个特征统计量的相关系数矩阵如表 1 所示,表中 W_1 — W_{14} 依次为角二阶矩、反差、相关性、差分矩、逆差分矩、和平均、和方差、和熵、

熵、差方、差熵、相关信息度 1、相关信息度 2 和最大相关系数。当两统计量的相关系数大于 0.9 时,认为其是相关的(如表 1 中黑体所示)。

由表 1 可知,有 4 组参数是相关的,它们是 (W_1, W_4, W_9) , $(W_2, W_3, W_{10}, W_{11})$, (W_6, W_7) 和 (W_{12}, W_{13}) ,为减少参数间的冗余,在每个相关的参数组中只选一个参数。针对断口图像,选择 FGLCM 的角二阶矩、相关性、逆差分矩、和方差、和熵、相关信息度 1 和最大相关系数等 7 个参数构成特征空间,为了描述方便记为参数系统 I。类似地,通过对 GLCM 的相关系数矩阵进行分析,同样选取了上述 7 个参数作特征,记为参数系统 II。

表 1 断口图像的 FGLCM 相关系数

Tab. 1 The FGLCM correlation coefficient of fracture surface image

	W_1	W_2	W_3	W_4	W_5	W_6	W_7	W_8	W_9	W_{10}	W_{11}	W_{12}	W_{12}	W_{14}
W_1	1.00	0.62	0.42	0.94	0.73	0.35	0.37	0.64	0.90	0.28	0.51	0.05	0.33	0.33
W_2	0.62	1.00	0.94	0.70	0.74	0.01	0.03	0.20	0.41	0.87	0.98	0.68	0.46	0.40
W_3	0.42	0.94	1.00	0.53	0.69	0.13	0.10	0.09	0.23	0.97	0.97	0.70	0.57	0.47
W_4	0.94	0.70	0.53	1.00	0.87	0.13	0.17	0.77	0.94	0.41	0.60	0.02	0.29	0.26
W_5	0.73	0.74	0.69	0.87	1.00	0.04	0.03	0.68	0.77	0.67	0.73	0.13	0.08	0.08
W_6	0.35	0.01	0.13	0.13	0.04	1.00	0.99	0.08	0.15	0.22	0.07	0.07	0.15	0.31
W_7	0.37	0.03	0.10	0.17	0.03	0.99	1.00	0.03	0.18	0.18	0.04	0.08	0.16	0.32
W_8	0.64	0.20	0.09	0.77	0.68	0.08	0.03	1.00	0.88	0.06	0.16	0.49	0.68	0.49
W_9	0.90	0.41	0.23	0.94	0.77	0.15	0.18	0.88	1.00	0.13	0.31	0.35	0.60	0.52
W_{10}	0.28	0.87	0.97	0.41	0.67	0.22	0.18	0.06	0.13	1.00	0.94	0.71	0.59	0.50
W_{11}	0.51	0.98	0.97	0.60	0.73	0.07	0.04	0.16	0.31	0.94	1.00	0.73	0.52	0.46
W_{12}	0.05	0.68	0.70	0.02	0.13	0.07	0.08	0.49	0.35	0.71	0.73	1.00	0.93	0.83
W_{13}	0.33	0.46	0.57	0.29	0.08	0.15	0.16	0.68	0.60	0.59	0.52	0.93	1.00	0.88
W_{14}	0.33	0.40	0.47	0.26	0.08	0.31	0.32	0.49	0.52	0.50	0.46	0.83	0.88	1.00

2.2 标准纹理图像分类

为验证 FGLCM 在纹理描述上的有效性,取标准 Brodatz^[13] 纹理库中的 21 类纹理($D_1, D_5, D_9, D_{16}, D_{19}, D_{20}, D_{21}, D_{32}, D_{34}, D_{47}, D_{49}, D_{55}, D_{57}, D_{74}, D_{92}, D_{96}, D_{101}, D_{102}, D_{107}, D_{109}, D_{110}$)进行纹理分类识别。每类纹理包含 25 幅图像,选取每类 10 幅共 210 幅纹理进行训练,其余的 315 幅纹理进行识别。对参数系统 I 和参数系统 II 应用最近邻准则进行识别,其分类识别的准确率分别为 95.56%和 95.24%。比较实验结果可得出结论:本文定义的 FGLCM 不仅能有效地表征纹理特征,而且在对标准纹理的分类识别上要优于传统的 GLCM。

3 隐马尔可夫模型与分类器设计

HMM 是双重随机过程有限状态自动机^[14-16],其中的双重随机过程是指满足 Markov 分布的状态转换 Markov 链以及每一个状态的观察输出概率密度函数。HMM 可以用 3 元组来表示: $\lambda = (\mathbf{A}, \mathbf{B}, \pi)$,其中 \mathbf{A} 是状态 S_i 到 S_j 的转移概率矩阵, \mathbf{B} 是状态的观察输出概率密度, π 是状态的初始分布概率。HMM 需要研究的 3 个基本问题是:1) 已知模型 λ 的各参数,求某一观察序列 \mathbf{O} 在该模型下的极大似然率,即 $P(\mathbf{O} | \lambda)$, $\mathbf{O} = O_1, \dots, O_T, T$ 为观察序列长

度;2) 在给定模型 λ 的条件下,求观察序列 O 最有可能历经的状态序列 S ;3) 在已知样本集合的条件下,如何根据样本集合训练模型并获得模型参数。问题 1) 可以由前向 (forward) 或后向 (backward) 算法解决,问题 2) 是典型的状态空间搜索问题,经典的算法是基于动态规划的 Viterbi 算法,问题 3) 是统计学习过程,其学习算法有 Baum-Welch 算法、梯度算法等。

对疲劳、解理、沿晶、韧窝共 4 类断口图像分别训练它们各自的 left-right DHMM (discrete HMM), 记为 $\lambda_1, \lambda_2, \lambda_3$ 和 λ_4 。在实验中,模型的参数 A, B 和 π 的初值随机生成,观察序列是上文提取的图像特征参数,训练时采用 Baum-Welch 算法,实验中分别建立了 4 种断口的 HMM,训练流程如图 3 所示。识别时采用 Viterbi 算法,在已知模型参数 A, B, π 的情况下,对观察序列 O ,分别计算 $P(O | \lambda_i) (i = 1, 2, 3, 4)$,比较各个模型的输出概率,似然率最大的模型所对应的类别即为观察序列 O 的类别。

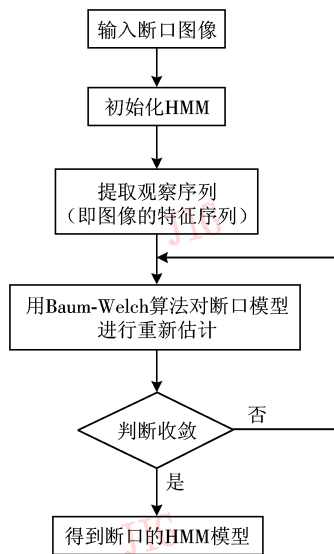


图 3 断口图像的 HMM 训练流程

Fig. 3 The HMM training procedure of fracture surface image

4 实验结果与分析

对铝合金断口的疲劳、解理、沿晶、韧窝 4 类断口图像进行训练和识别,每类断口包含 25 幅图像,实验中选取每类 10 幅共 40 幅进行训练,全部 100 幅断口进行识别。HMM 中的一个重要问题就是确定模型的隐含状态个数。由于不能在理论上确定最

优的 HMM 状态数目,实验中考察了状态数目分别为 2,3 和 4 的情况,断口分类识别的结果与运行时间如表 2 所示。为了进行对比,计算在最近邻分类器下识别的准确率,如表 3 所示。表中所示的特征集 GLCM 表示参数系统 II, FGLCM₁ 和 FGLCM₂ 分别表示在隶属度函数为线性分布和高斯分布时的得到的 FGLCM 的参数系统 I。本实验的运行环境为 P4 2.0 GHz CPU, 512 MB 内存。

表 2 HMM 分类器的断口图像识别率

Tab. 2 The right recognition rate of fracture surface image based on HMM classification

特征集	状态数	疲劳	韧窝	沿晶	解理	平均识别率	识别时间/s
GLCM	1	0.92	0.88	0.92	0.94	0.94	32.45
FGLCM ₁	2	1	0.92	0.92	0.96	0.95	32.25
FGLCM ₂	1	0.92	0.88	1	0.95	0.95	32.11
GLCM	1	0.92	0.92	1	0.96	0.96	35.47
FGLCM ₁	3	1	0.92	1	1	0.98	35.36
FGLCM ₂	1	0.96	0.92	1	0.97	0.97	36.72
GLCM	0.96	0.92	0.88	0.96	0.93	0.93	38.51
FGLCM ₁	1	0.92	0.92	0.96	0.95	0.95	38.24
FGLCM ₂	1	0.88	0.92	0.92	0.93	0.93	39.02

表 3 最近邻分类器的断口图像识别率

Tab. 3 The right recognition rate of fracture surface image based on the nearest classification

特征集	疲劳	韧窝	沿晶	解理	平均识别率	识别时间/s
GLCM	0.92	0.76	0.68	0.76	0.8	11.23
FGLCM ₁	0.92	0.84	0.76	0.84	0.86	12.05
FGLCM ₂	0.92	0.8	0.76	0.8	0.82	11.48

通过分析表 2 和表 3 中的实验数据,可以得出以下结论:

- 1) HMM 分类器比最近邻分类器更适合进行断口图像分类,在各种特征集下,前者得到的识别率都在 90% 以上,而后者只有 80% 左右;
- 2) 在 HMM 状态数分别取 2,3,4 时,3 状态的识别率最高;
- 3) 利用相同的分类器模型,特征集 FGLCM₁ 的识别结果最好,特别是在 3 状态的 HMM 下,对 4 类断口的平均识别率达到 98%,即在隶属度函数服从线性分布而构造的 FGLCM 要优于传统的 GLCM;
- 4) 采用相同的分类器模型时,特征集 GLCM,

FGLCM₁, FGLCM₂ 的识别时间基本一致;尽管采用 HMM 分类器时耗时较多,但识别结果明显优于最近邻分类器。

5 结 论

在传统的灰度共生矩阵的基础上,定义了模糊灰度共生矩阵,并应用于金属断口图像识别。通过实验验证, FGLCM 在特征描述上更优于传统的 GLCM,而且 HMM 对金属断口图像分类是十分有效的,把 FGLCM 的统计特征与 3 状态 HMM 相结合,对断口图像的平均识别率可达 98%。

参考文献 (References)

- [1] Zhong Qunpeng, Zhao Zihua. Fracture Surface Study [M]. Beijing: Higher Education Press, 2005. [钟群鹏,赵子华. 断口学 [M]. 北京: 高等教育出版社, 2005.]
- [2] Zhang Dong, Zhong Peidao, Tao Chunhu, et al. Failure Analysis [M]. Beijing: National Defence Industry Press, 2004. [张栋, 钟培道,陶春虎,等. 失效分析 [M]. 北京: 国防工业出版社, 2004.]
- [3] Yan Yunhui, Gao Jinhe, Liu Yong, et al. Recognition and classification of metal fracture surface modes based on wavelet transform [J]. Acta Metallurgica Sinica, 2002, 38 (3): 309-314. [颜云辉, 高金鹤, 刘勇, 等. 基于小波变换的金属断口模式识别与分类 [J]. 金属学报, 2002, 38 (3): 309-314.]
- [4] Yan Yunhui, Wang Dejun. Image processing techniques in analysis of metal fracture surface [J]. Acta Metallurgica Sinica, 1996, 32 (5): 552-556. [颜云辉, 王德俊. 图像处理技术与金属断口分析 [J]. 金属学报, 1996, 32 (5): 552-556.]
- [5] Wu Songlin, Su Enze. The texture visual pattern recognition based on edge neighborhood Morphology analysis [J]. Signal Processing, 1995, 11 (4): 313-316. [吴松林, 苏恩泽. 基于边缘邻域形态分析的纹理视觉模式识别 [J]. 信号处理, 1995, 11 (4): 313-316.]
- [6] Haralick R M, Shanmugam K, Dinstein I. Textural features for image classification [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part A, 1973, 3 (6): 610-621.
- [7] Bastos L De O, Liatsis P, Conci A. Automatic texture segmentation based on k-means clustering and efficient calculation of co-occurrence features [C] // Proceedings of the 15th International Conference on Systems, Signals and Image Processing. New York, NY, USA: IEEE, 2008: 141-144.
- [8] Soh L K, Tsatsoulis C. Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices [J]. IEEE Transactions on Geoscience and Remote Sensing, 1999, 37 (2): 780-795.
- [9] Tesař L, Shimizu A, Smutek D, et al. Medical image analysis of 3D CT images based on extension of Haralick texture features [J]. Computerized Medical Imaging and Graphics, 2008, 32 (6): 513-520.
- [10] Bo Hua, Ma Fulong, Jiao Licheng. Research on computation of GLCM of image texture [J]. Acta Electronic Sinica, 2006, 34 (1): 155-158. [薄华, 马缚龙, 焦李成. 图像纹理的灰度共生矩阵的计算问题的分析 [J]. 电子学报, 2006, 34 (1): 155-158.]
- [11] Zou Chao, Zhu Desen, Xiao Li. Textural defect detection based on fuzzy label co-occurrence matrix [J]. Journal of Image and Graphics, 2007, 12 (1): 92-97. [邹超, 朱德森, 肖力. 基于模糊类别共生矩阵的纹理疵点检测方法 [J]. 中国图象图形学报, 2007, 12 (1): 92-97.]
- [12] Rishi J, Clausi D A. Texture analysis using Gaussian weighted grey level co-occurrence probabilities [C] // Proceedings of the First Canadian Conference on Computer and Robot Vision. New York, NY, USA: IEEE, 2004: 51-57.
- [13] Brodatz P. Textures: A Photographic Album for Artists and Designers [D]. Dover, New York, 1966.
- [14] Chien J T, Liao C P. Maximum confidence hidden markov modeling for face recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 4 (30): 606-616.
- [15] Somervuo P, Harma A, Fagerlund S. Parametric representations of bird sounds for automatic species recognition [J]. IEEE Transactions on Audio, Speech, and Language Processing, 2006, 14 (6): 2252-2263.
- [16] Yu L, Wu L N. Comments on a separable low complexity 2D HMM with application to face recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29 (2): 368-368.