

文章编号:0253-9993(2012)06-1051-05

# 基于行程长度纹理特征的焦炭显微图像分类算法

王培珍<sup>1</sup>, 缪家龙<sup>1</sup>, 周 可<sup>1</sup>, 张代林<sup>2</sup>

(1. 安徽工业大学 电气信息学院, 安徽 马鞍山 243002; 2. 安徽工业大学 煤的洁净转化与综合利用安徽省重点实验室, 安徽 马鞍山 243002)

**摘 要:**在分析焦炭显微图像各向异性光学组织中片状与纤维状显微图像特征的基础上,通过对纹理特征的差异性的研究,提出了一种基于行程长度纹理特征和支持向量机(Support Vector Machine)的焦炭显微图像分类方法。该方法首先计算焦炭显微图像中4个方向上的行程长度矩阵,利用行程长度矩阵求得对图像纹理具有不同表征能力的纹理特征量,通过对各个特征量的数据分析,选取有效特征量组合作为分类器的训练向量,然后用支持向量机对实验样本进行分类。实验结果表明,该方法能够有效地识别出焦炭各向异性组织中纤维状、片状等不同光学组分。

**关键词:**焦炭光学组织;纹理特征;行程长度;支持向量机;分类器

中图分类号:TQ533.6 文献标志码:A

## Coke microscopic image classification algorithm based on run-length texture features

WANG Pei-zhen<sup>1</sup>, MIAO Jia-long<sup>1</sup>, ZHOU Ke<sup>1</sup>, ZHANG Dai-lin<sup>2</sup>

(1. School of Electrical & Information, Anhui University of Technology, Maanshan 243002, China; 2. Anhui Key Laboratory of Clean Conversion and Utilization, Anhui University of Technology, Maanshan 243002, China)

**Abstract:** After analyzing texture characteristics of graphite and fibrous subclass in coke optical texture micrograph, a classification algorithm, combining run-length textural features and Support Vector Machine (SVM), was proposed. Firstly, the run-length matrix and a series of related texture features of coke optical texture micrograph were calculated, validities of these features for subclasses classification were analyzed. Then Support Vector Machine based classifier was trained with those valid features and their combination. Experimental results show that with the proposed algorithm, some subclasses among different optical textures of anisotropic, such as fibrous and graphite, can be classified more reasonably and effectively.

**Key words:** coke optical texture; texture feature; run-length; SVM; classifier

焦炭的光学组织结构与焦炭的性能(如反应性、热传导性、强度、石墨化性等)有直接的联系<sup>[1-3]</sup>,因此对焦炭光学组织进行分析与识别对指导高炉生产具有重要的理论和实际意义。已有学者在焦炭图像分析方面做过一些研究<sup>[4-5]</sup>,但主要是关于焦炭孔结构参数和光学组织部分特性的分析。目前,光学组织的分析仍然是依靠专家经验的人工方式。SVM(Support Vector Machine)是 Vapnik 等根据统计学习理论提出的一种机器学习方法<sup>[6]</sup>,它建立在统计学习理

论和结构风险最小化原理基础上,根据有限的样本信息在模型的复杂性和学习能力之间寻求最佳折中,以期获得最好的推广能力,在解决小样本、非线性及高维模式识别中表现出特有的优势<sup>[7-9]</sup>。针对焦炭光学组织中片状组织和纤维状组织的特点,如片状组织中像素值在各个方向都相差不大,而纤维状组织中像素值只在一个方向相差不大,本文提出一种利用行程长度矩阵表征图像的纹理特征,以此作为 SVM 的特征向量,来识别焦炭光学组织各向异性中的片状和纤

维状的方法。该方法较灰度共生矩阵 SVM 纹理分类器方法<sup>[10-11]</sup>在识别准确率上有明显提高。

## 1 支持向量机原理

SVM 的思想来源于最优分类超平面,考虑最简单的情况:线性分类器在可分数据上的训练。对于由  $l$  个样本组成的训练样本集  $\{(x_i, y_i), i=1, \dots, l\}$ , 其中  $y_i \in \{-1, 1\}$  是样本指标集,  $x_i \in R^n$ ,  $n$  是输入空间的维数。对此样本集假设可以得到分类超平面  $H: w \cdot x + b = 0$ , 如图 1 所示, 该超平面可以将两类样本分开。假设所有训练数据都满足下面的约束:

$$\begin{cases} x_i \cdot w + b \geq +1, y_i = +1 & (1) \\ x_i \cdot w + b \leq -1, y_i = -1 & (2) \end{cases}$$

合并为

$$y_i(x_i \cdot w + b) - 1 \geq 0, \forall i \quad (3)$$




图 1 最优分类面示意

Fig. 1 The sketch of optimal classification plane

使不等式(1)取等号的点位于超平面  $H_1$  之上:  $x_i \cdot w + b = 1$ ; 类似地, 使得不等式(2)取等号的点位于超平面  $H_2$  之上:  $x_i \cdot w + b = -1$ 。超平面  $H, H_1$  和  $H_2$  的法向量都是  $w$ 。定义  $d_+$  为分类面  $H$  到最近正值样本的距离;  $d_-$  为分类面  $H$  到最近负值样本的距离;  $H_1$  和  $H_2$  之间的垂直距离即为分类超平面  $H$  的分类间隔  $d$ , 可得到  $d = 2 / \|w\|$ 。最优分类超平面就是满足式(3), 并且使得  $f(w) = \|w\|^2 / 2$  最小, 即分类间隔最大的超平面。超平面  $H_1$  和  $H_2$  上的向量称为支持向量, 支持向量满足  $y_i(x_i \cdot w + b) = 1$ 。

将上述问题表示为优化问题:

$$y_i(w \cdot x + b) \geq 1, i = 1, \dots, l \quad (4)$$

引进拉格朗日乘子  $\alpha_i \geq 0, (i = 1, \dots, l)$ , 得拉格朗日方程:

$$L = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i y_i (x_i \cdot w + b) + \sum_{i=1}^l \alpha_i \quad (5)$$

对  $w$  和  $b$  求微分, 得:  $w = \sum \alpha_i y_i x_i, \sum \alpha_i y_i = 0$ , 代入到拉格朗日方程, 可得最优解为

$$w_0 = \sum_{i=1}^{N_{SV}} y_i \alpha_i^0 x_i, b_0 = y_j - w_0 \cdot x_j \quad (6)$$

式中,  $N_{SV}$  是支持向量的个数。

由此可得最优分类面的决策函数:

$$f(x) = \text{sgn}((w_0 \cdot x) + b_0) \quad (7)$$

对于线性不可分情况, 须允许一定数目的样本被误分。引入核函数  $K(x_i, x_j) = (f(x_i) \cdot f(x_j))$ , 最优分类函数可写为

$$f(x) = \text{sgn} \left[ \sum_{i=1}^{N_{SV}} \alpha_i^0 y_i K(x_i \cdot x) + b_0 \right] \quad (8)$$

常见的核函数有以下几种:

多项式核函数:  $K(x, x_i) = [(x \cdot x_i) + 1]^q$ , 其中  $q$  是正整数;

Gauss 径向基向基核函数:  $K(x, x_i) = \exp\{-\|x - x_i\|^2 / 2\sigma^2\}$ ,  $\sigma$  是核半径, 它们都是正定核;

Sigmoid 核函数:  $K(x, x_i) = \tanh[\nu(x \cdot x_i) + c]$ , 其中  $\nu > 0, c < 0$ 。

选择最佳核函数的方法是采用 Cross-Validation 方法, 即核函数选用时, 分别试用不同的核函数, 误差最小的核函数为最佳核函数; 核函数的参数也用同样的方法选定。由此, 本文选用 Gauss 径向基核函数。

## 2 纹理特征提取

焦炭各项异性光学组织图像是在不同偏光下通过 500 倍显微镜后由 CCD 成像获取, 图 2 是 4 幅典型的光学组织图像。




图 2 典型焦炭光学组织图像

Fig. 2 Typical coke optical texture images

如图 2(a) 和 (b) 所示, 在图像中占据一定的面积, 表面平滑的区域为片状组织; 细而长, 呈流线状的区域属于纤维状组织, 如图 2(c) 和 (d) 所示。在图 2(a) 和 (b) 中, 像素值在一块区域内差别不大, 特别是当像素值量化等级减少后, 差别更小; 而在图 2(c) 和

(d)中,像素值在一块区域内反复变化。针对这一特点,提取行程长度特征来识别图像。

## 2.1 行程长度矩阵及其特点

行程长度是指某个方向上连续灰度相同的像素的累加值。

设有一幅分辨率为  $N_w \times N_h$  的数字图像  $f(x, y)$ ,  $g$  即二维平面上点  $(x, y)$  处的灰度值。引入参数  $n$  和  $\theta$ ,  $\theta$  是两点在二维平面的角度,  $n$  表示从任一点出发沿  $\theta$  方向上连续具有灰度值为  $g$  的个数。统计出任一点出发沿  $\theta$  方向上连续  $n$  个点都具有灰度值  $g$  的出现的次数, 记为  $P^\theta(g, n)$ , 在某一方向上具有相同灰度值的像素个数称为行程长度, 沿  $\theta$  方向一般分 4 种情况:  $0, 45^\circ, 90^\circ$  和  $135^\circ$ 。对于灰度级为 256 的  $N_w \times N_h$  图像, 行程长度矩阵  $\mathbf{P}$  是一个  $256 \times N$  的矩阵, 并且具有以下特点:

(1) 行程长度矩阵具有方向性, 同一幅图像在不同方向上的行程长度矩阵不同。

(2) 若行程长度矩阵元素的分布重心位于行程矩阵的左边, 说明整幅图像的灰度值变化较大, 纹理较细; 反之, 若行程长度矩阵元素的分布重心位于行程矩阵的右边, 则说明整幅图像的灰度值变化较小, 纹理较粗。

## 2.2 基于行程长度的特征量分析

行程长度矩阵揭示了图像的纹理变化规律性, 其维数由图像的灰度级和图像的大小决定。由行程长度矩阵可以提取出能够较好地描述纹理图像变化特性的参数。设行程长度矩阵  $\mathbf{P}$  的元素为  $p(i, j)$ ,  $i$  为灰度,  $j$  为行程。用窗口移动统计整幅图像的特征。设窗口大小为  $N \times N$ , 灰度级为  $M$ , 行程度为  $N$ , 可提取如下的 5 种传统统计量<sup>[12-15]</sup>。

(1) 长行程加重 (LRE):

$$L_{RE} = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N p(i, j) j^2$$

(2) 短行程加重 (SRE):

$$S_{RE} = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j)}{j^2}$$

(3) 行程分数 (RP):

$$R_p = \frac{n_r}{n_p}$$

(4) 灰度级的非均匀性 (GLN):

$$G_{LN} = \frac{1}{n_r} \sum_{i=1}^M \left( \sum_{j=1}^N p(i, j) \right)^2$$

(5) 行程长度的非均匀性 (RLN):

$$R_{LN} = \frac{1}{n_r} \sum_{i=1}^M \left( \sum_{j=1}^N p(i, j) \right)^2$$

式中,  $n_r$  是行程总数;  $n_p$  是窗口中像素总数。

上述大多特征都没有考虑到灰度级的作用, Chu 等<sup>[16]</sup>提出了 2 种新的特征量在行程长度矩阵中提取灰度级信息。

(1) 低灰度级行程加重 (LGRE):

$$L_{GRE} = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j)}{i^2}$$

(2) 高灰度级行程加重 (HGRE):

$$H_{GRE} = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N p(i, j) i^2$$

随后, Dasarathy 和 Holder 基于灰度级和行程长度的联合统计方法又提出了 4 种特征量<sup>[17]</sup>。

(1) 短行程低灰度级加重 (SRLGE):

$$S_{RLGE} = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j)}{i^2 j^2}$$

(2) 短行程高灰度级加重 (SRHGE):

$$S_{RHGE} = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j) i^2}{j^2}$$

(3) 长行程低灰度级加重 (LRLGE):

$$L_{RLGE} = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j) j^2}{i^2}$$

(4) 长行程高灰度级加重 (LRHGE):

$$L_{RHGE} = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N p(i, j) i^2 j^2$$

## 3 SVM 分类器

在对片状和纤维状的行程长度纹理特征量进行分析后, 发现其中有些特征向量在 2 种类别中差别较大, 而有的特征值交错在一起, 图 3 给出了 4 种典型特征向量的分布, 其中横坐标表示样本序号, 纵坐标表示不同类别各特征量的统计值。

从图 3(a) 和 (b) 可以看出, LRHGE 和 RLN 能够较好地地区分片状和纤维状, 而图 3(c) 和 (d) 中的 GLN 和 LGRE 两种特征向量交织在一起, 用来识别片状和纤维状的效果不理想。SVM 分类器的具体步骤为: ① 将样本图像宽  $n_w$  高  $n_h$  共  $n$  张经过去噪处理后, 转换为 256 级灰度图; ② 求行程长度矩阵, 将灰度级量化为  $L$  个等级, 为方便计算取纹理窗口大小为  $n \times n$ , 求  $0, 45^\circ, 90^\circ$  和  $135^\circ$  四个方向的行程长度矩阵均值, 用均值矩阵求 11 种特征量; ③ 分别用每个特征量作为 SVM 分类器的输入, 采用 Gauss 径向基核函数, 核半径取 10; ④ 对待测样本进行识别。SVM 分类器训练流程和分类算法流程如图 4 所示。

## 4 实验结果及分析

在分类器时, 片状组织和纤维状组织各取 200

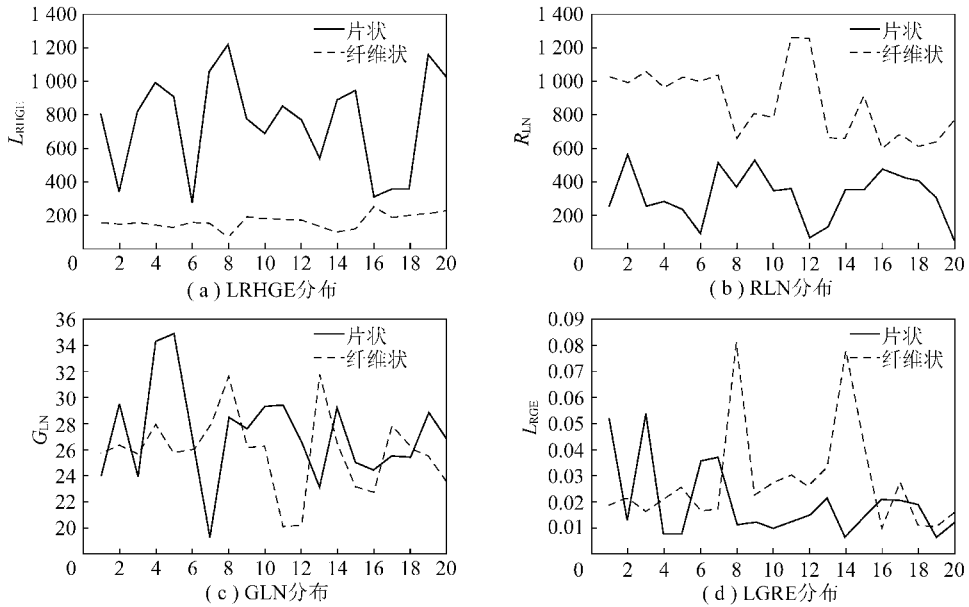


图 3 片状和纤维状特征量分布

Fig. 3 Feature distribution of graphite and fibrous

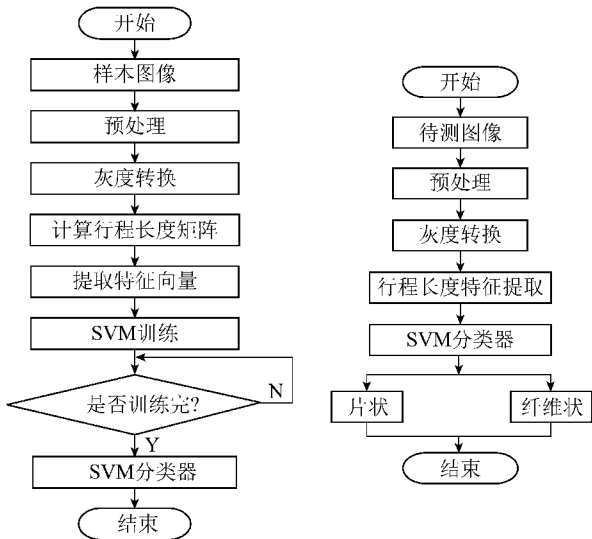


图 4 分类器训练流程和分类流程

Fig. 4 The flow charts of classifier training and classification. The flow chart on the left shows the training process: starting with sample images, preprocessing, grayscale conversion, calculating the run-length matrix, extracting feature vectors, and training the SVM classifier. A decision diamond asks if training is complete. If not, it loops back; if yes, it proceeds to the SVM classifier and ends. The flow chart on the right shows the classification process: starting with an image to be tested, preprocessing, grayscale conversion, extracting run-length features, using the SVM classifier, and outputting '片状' (graphite) or '纤维状' (fibrous) before ending.

幅,用来训练 SVM。用待测图像各 100 幅来检验,表 1 给出的是选择分类效果较好的 2 个特征量和效果较差的 2 个特征量作为 SVM 分类器的特征向量进行分类的结果,在计算行程长度矩阵时,灰度图像量化为 16 个等级,窗口大小取 16×16。  
由图 2 可以发现片状组织的均匀性优于纤维状组织,但仅用灰度级信息无法很好识别二种组织。图 3 和表 1 也证明了这一点。图 3 中,片状的 LRHGE 值高于纤维状的,而纤维状的 RLN 值高于片状的,说明纤维状的行程长度的均匀性要比片状的差;表 1 中特征向量为 LRHGE 和 RLN 时的分类准确率高,特征向量为 GLN 和 LGRE 时的分类准确率低。表 2 是用

行程长度纹理特征和灰度共生矩阵纹理特征分别作为 SVM 分类器的特征向量时的识别率。在行程长度矩阵中选取 LRHGE 和 RLN 分别作为特征向量用来训练分类器,在灰度共生矩阵中选取效果较好的能量 (Energy) 和惯性矩 (Moment of inertia) 分别作为特征向量训练分类器,结果见表 2。

表 1 分类器识别率

Table 1 Recognition rate of classifier

光学组织	特征向量	样本数量	样本准确率/%	待测数量	待测准确率/%
片状	LRHGE	200	99	100	94
	RLN		96.5		92
	GLN		72		68
	HGRE		78		75
纤维状	LRHGE	200	99	100	93
	RLN		97		91
	GLN		77		70
	HGRE		75		76

表 2 不同纹理特征分类器识别率

Table 2 Recognition rate of different feature classifier

特征向量	待测数量	准确率/%		平均耗时/s	
		片状	纤维状	片状	纤维状
LRHGE	100	94	93	0.949	0.950
RLN	100	92	91	0.949	0.950
Energy	100	78	90	0.493	0.492
Moment of inertia	100	74	77	0.493	0.492



表2中,特征向量为LRHGE和RLN的识别准确率明显高于特征向量为能量和惯性矩的识别准确率。表1,2给出的是采用单一的特征向量识别对结果,当取基于行程长度的二维纹理特征时,识别率见表3。

表3 二维特征向量分类器识别率

Table 3 Recognition rate of two dimensional classifier

特征向量	待测数量	准确率/%		平均耗时/s	
		片状	纤维状	片状	纤维状
RLN,HGRE	100	99	99		
RLN,SRHGE	100	98	98		
RLN,LRHGE	100	98	98	0.987	0.988
HGRE,SRHGE	100	99	99		
HGRE,LRHGE	100	99	98		
SRHGE,LRHGE	100	98	99		

从表3中可以看出,选择RLN,HGRE,SRHGE和LRHGE中的任意二种作为二维特征量分类,准确率可以达到98%以上。由表2中可以看出,当取灰度共生矩阵纹理特征时,耗时大约为取行程长度纹理特征时的一半。原因是由于在计算灰度共生矩阵纹理特征时,只统计了单一方向上的数据,而在计算行程长度纹理特征时,统计的是4个方向上数据的平均。从表3可知,在行程长度纹理特征中,取二维特征向量计算需要时间虽然比取一维特征向量时多0.038s左右,但准确率提高到了98%以上。

## 5 结 论

将基于行程长度矩阵的特征量和SVM方法应用于焦炭显微图像分类上,对不同光学组织进行识别。从实验结果可以看出,用 $0^\circ$ , $45^\circ$ , $90^\circ$ 和 $135^\circ$ 四个方向的行程长度矩阵均值来求特征向量,削弱了方向对特征提取的影响,与灰度共生矩阵纹理特征相比较,本文方法有效地提高了分类准确率。合理地选择特征向量,可使识别准确率可以得到进一步的提高。

## 参考文献:

[1] Lin Qilang, Tang Haiyan, Li Chuanhui, et al. Carbonization behavior of coal-tar pitch modified with lignin/silica hybrid and optical texture of resultant semi-cokes[J]. Journal of Analytical and Applied Pyrolysis, 2011, 90(1): 1-6.

[2] Zhang D L, Zhao M M, Wang P Z, et al. Study on factors of influencing on coke thermal property[J]. Iron & Steel, 2009, 44(10): 10-13.

[3] 郭 治, 杜铭华, 曲思建. 焦炭反应性及反应后强度预测模型研究[J]. 煤炭学报, 2005, 30(1): 113-117.

Guo Zhi, Du Minghua, Qu Sijian. Prediction model for coke reactivity

index and coke strength after reaction[J]. Journal of China Coal Society, 2005, 30(1): 113-117.

- [4] Wang Peizhen, Wang Qinfang. Fractal-based image analysis of coke optical texture[A]. Proceeding on 2007 IEEE International Conference on Control and Automation[C]. 2007: 3223-3225.
- [5] Dailin Z. Study on determination of coke pore structure by image analysing[J]. Fuel & Chemical Processes, 2003, 34(4): 175-178.
- [6] Vapnik V N. The nature of statistical learning theory[C]. 2nd Statistics for Engineering and Information Science[A]. New York: Springer, 2000: 314.
- [7] Jung C, Liu Q, Kim J. Accurate text localization in images based on SVM output scores[J]. Image and Vision Computing, 2009, 27(9): 1295-1301.
- [8] 王圆圆, 陈云浩, 李 京. 基于支持向量机(SVM)特征加权/选择的光谱匹配算法[J]. 光谱学与光谱分析, 2009, 29(3): 735-739.
- Wang Yuanyuan, Chen Yunhao, Li Jing. Improving hyperspectral matching method through feature-selection/weighting based on SVM[J]. Spectroscopy and Spectral Analysis, 2009, 29(3): 735-739.
- [9] 谭 琨, 杜培军. 基于支持向量机的高光谱遥感图像分类[J]. 红外与毫米波学报, 2008, 27(2): 123-128.
- Tan Kun, Du Peijun. Hyperspectral remote sensing image classification based on support vector machine[J]. Journal of Infrared and Millimeter Waves, 2008, 27(2): 123-128.
- [10] Xian G. An identification method of malignant and benign liver tumors from ultrasonography based on GLCM texture features and fuzzy SVM[J]. Expert Systems with Applications, 2010, 37(10): 6737-6741.
- [11] Wang P, Zhou K, Zhou F, et al. Optical textures classification of coke microscopic image based on SVM[A]. 2010 International Conference on Computer Application and System Modeling[C]. 2010: 596-600.
- [12] Zhang J, Tan T. Brief review of invariant texture analysis methods[J]. Pattern Recognition, 2002, 35(3): 735-747.
- [13] Maji S, Berg A C, Malik J. Classification using intersection kernel support vector machines is efficient[A]. Proceedings, CVPR 2008[C]. Anchorage, Alaska, 2008: 1-8.
- [14] Kim K I, Jung K, Park S H, et al. Support vector machines for texture classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002: 1542-1550.
- [15] 曹治国, 肖 阳, 邹腊梅. 行程长度纹理特征在 SPOT 遥感图像分类中的应用[J]. 模式识别与人工智能, 2008, 21(2): 260-265.
- Cao Zhiguo, Xiao Yang, Zou Lamei. Application of run-length texture features to SPOT remote sensing image classification[J]. Pattern Recognition and Artificial Intelligence, 2008, 21(2): 260-265.
- [16] Chu A, Sehgal C M, Greenleaf J F. Use of gray value distribution of run lengths for texture analysis[J]. Pattern Recognition Letters, 1991, 11(6): 415-420.
- [17] Dasarathy B R, Holder E B. Image characterizations based on joint gray-level run-length distributions[J]. Pattern Recognition Letters, 1991, 12(8): 479-502.