

基于概率神经网络和分形的植物叶片机器识别研究

黄 林^a,贺 鹏^a,王经民^b

(西北农林科技大学 a 信息工程学院,b 理学院,陕西 杨凌 712100)

【摘 要】 【目的】提出一种将植物叶片的形状特征与其纹理特征相结合的综合特征识别方法,有效解决了传统的植物机器识别分类特征单一且识别率较低的问题,为植物的快速机器识别提供技术参考。【方法】提取植物叶片样本的综合特征信息,以概率神经网络(PNN)为分类器对所得的特征信息进行训练,训练好的网络用来识别植物叶片的类别,从而确定相应植物的种类。【结果】有效提取了含有 8 个分量的植物叶片综合特征向量,通过对 PNN 分类器的训练,实现了 30 种植物叶片的快速机器识别,平均识别率达 98.3%。比较测试表明,若去掉叶片纹理特征,单以其形状特征作为识别依据,平均识别率仅为 93.7%。【结论】植物叶片综合特征识别方法有效弥补了传统单特征识别方法的不足,使识别效率得到了较大的提高。

【关键词】 植物叶片;机器识别;概率神经网络;分形维数;特征提取
【中图分类号】 TP183;TP391.41 【文献标识码】 A 【文章编号】 1671-9387(2008)09-0212-07

Leaf recognition for plant based on Probabilistic
Neural Networks and fractal

HUANG Lin^a, HE Peng^a, WANG Jing-min^b

(a College of Information Engineering, b College of Science, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: 【Objective】This paper gave a recognition approach, which combined the shape feature and the texture feature of the plant leaf, to effectively solve the problem that the classification features of traditional plant recognition were usually not synthetic and the recognition rate was always slightly low, hoping to provide technical reference for rapid machine recognition for plant. 【Method】 Firstly, the synthetic features of leaf were extracted; secondly the values of synthetic features of leaf, which had been extracted, were put into a classifier, which is Probabilistic Neural Networks(PNN), to be trained; finally, the PNN trained well could work to classify the plant leaves. 【Result】 The synthetic feature vector of plant leaf, which included 8 elements, were extracted efficiently. By training the classifier PNN, the rapid recognition for thirty kinds of plant leaves was realized and the average recognition rate reached 98.3%. Comparison tests demonstrated that if the shape features of plant leaf was solely used as the recognition features without the texture features, the average recognition rate just reached 93.7%. 【Conclusion】 The synthetic feature recognition method has effectively made up for the drawbacks of traditional recognition method towards unitary feature, strongly advancing the recognition rate.

Key words: plant leaf; machine recognition; Probabilistic Neural Network; fractal dimension; feature extraction

* 【收稿日期】 2007-09-28
【基金项目】 西北农林科技大学专项基金项目(08080;08080209)
【作者简介】 黄 林(1951—),女,陕西杨凌人,教授,硕士生导师,主要从事计算机农林应用研究。E-mail:hl@nwsuaf.edu.cn

植物保护的一个重要方面就是对植物进行分类研究。随着计算机技术的飞速发展,对植物的分类研究,已经突破了单纯从植物细胞及化学遗传成分的角度去鉴定植物种类的方法,可以综合应用图像处理技术、模式识别技术,并辅以图像获取设备实现对植物的快速识别。

无论从植物分类学的角度还是从计算机图谱模式识别的角度,识别一种植物最直接有效、最简单的方法就是从其叶片着手。对于同一种植物,尽管随着时间变化叶片的大小老嫩都会变化,但是其叶片的脉络结构比较稳定,一些比例参数也基本保持恒定,如:叶片内切圆周长与叶片周长的比值、叶片面积与叶片最小包围盒面积的比值等。而对不同种植物,其叶片的叶脉结构差异较大,如上述的比例参数也有很大差异。

纵观国内外植物叶片机器识别的方法,发现以单特征识别为主^[1-8],主要是单独利用植物的位置、形状、颜色、光谱和纹理等特征进行分类识别,其正确识别率往往不是很高。如 Ingrouille 和 Laird^[1]在 1986 年提取 27 个叶片形状特征对橡树进行了分类;1993 年 Guyer^[3]提取了 17 个叶片形状特征对 40 类植物进行了分类,分类结果并不理想。直到 2006 年,国内才开始着手针对植物叶片综合特征的分类识别研究,如 2006 年,王晓峰等^[9]尝试对植物叶片纹理特征进行提取,但结果并不理想,最后单用形状特征作为识别依据,平均识别率为 92%;2007 年,张蕾^[10]将叶片的形状特征与纹理特征相结合,利用自组织特征映射(SOM)神经网络作为分类器来识别植物种类,平均识别率达 95.8%,但所提取的叶片特征过多,难免有所冗余,同时,采用小波变换对叶脉图像进行分解,但其算法比较复杂,时间开销比较大。

本文将植物叶片的形状特征信息和纹理特征信息相结合,以概率神经网络为分类器,对植物叶片的机器识别进行了新的尝试。将优化精选出的 6 个叶片形状特征和 2 个叶片纹理特征相结合,从而构成一个含有 8 分量的综合特征向量,这 8 个分量分别为:脉序类型、分形维数、矩形度、横纵轴比、面积凹凸度、周长凹凸度、圆形度和偏心率,然后将这个综合特征向量作为分类器的输入特征矢量,通过网络训练,对植物叶片进行分类识别,以期为植物的快速机器识别提供技术参考。

1 图像预处理

植物叶片图像识别的整个流程如图 1 所示。首先,需有针对性地采集 30 种周围常见的树木叶片,采集时有意挑选斑点较少或无斑点、叶缘完整的优良叶片,同时为了有效提高训练样本集的自相容能力^[11]和泛化能力,有代表性地按每种树木叶片大小、老嫩的不同各采集 15 片,使其尽可能多的囊括该种植物叶片的特征信息,然后通过扫描仪将采集到的 450 多片树叶制成数字图像;其次,对叶片图像进行预处理,用提取出来的叶脉图像和叶片轮廓,分别计算出叶片纹理特征参数和形状特征参数,从而得到每种叶片的特征向量;最后,用概率神经网络(PNN)分类器对样本进行训练,从而识别出叶片所属的种类。




图 1 植物叶片图像的识别流程
Fig. 1 Flow diagram of plant leaf recognition

1.1 图像灰度化

由于本文主要使用叶片的形状与纹理特征作为分类依据,因此颜色信息对于识别来说并不重要,使用灰度图像同样能获得足够的图像细节,完全可以满足叶片图像识别的要求。所以在进一步处理之前,首先需要把彩色图像转成灰度图像,计算公式如下:

$$\text{Gray} = 0.299 \cdot \text{Red} + 0.587 \cdot \text{Green} + 0.114 \cdot \text{Blue}.$$
其中 Red、Green、Blue 分别是 RGB 图像中红、绿、蓝 3 个分量的值。利用以上公式所得 BMP 灰度图像如图 2 所示。

1.2 叶脉图像的提取

利用文献[12]中提出的基于人工神经网络的叶脉信息提取方法,成功而准确地提取出叶脉图像。该方法利用边缘梯度、局部对比度和邻域统计特征等 10 个参数来描述像素的邻域特征,并将其作为神

经网络的输入层。试验结果表明,与传统方法相比,经过训练的神经网络能够更准确地提取叶脉图




图 2 叶片的 BMP 灰度图像

Fig. 2 BMP gray level image

1.3 阈值分割

分割的目标是把叶片图像与背景分开并形成二值图像,以便于其后进行叶片轮廓提取和形状特征参数计算。由于使用了扫描仪,所以叶片图像与其背景的灰度级存在着明显差别,为此选取计算较为简单方便的双峰法,用 VC++ 语言编程计算出灰度门限值对图像进行分割。结果表明,尽管在大部分情况下所得叶片二值图像内部并无小的孔洞,但也有少数例外情况。为了快速而准确地填充叶缘内部的细小孔洞,引入文献[13]提出的一种新的基于链码的填充算法,利用该算法可快速而准确地对部分叶缘内的小孔洞进行填充。图 4 即为采用上述思路



图 4 阈值分割后的叶片二值图像

Fig. 4 Binary image after thresholdlizing

1.5 叶片图像轮廓的提取

除计算分形维数要用到叶脉图像外,其他的几个特征参量只涉及叶片的轮廓信息。本文采用文献[14]提出的二值图像快速边缘提取算法,对叶片的无柄二值图像进行边缘提取,提取结果如图 6 所示。




图 6 叶片轮廓的二值图像

Fig. 6 Binary image of leaf profile

结果发现,与传统的轮廓跟踪法相比,此种边缘提取算法能够更快地对有复杂细节的轮廓进行准确提取。由图 6 可知,叶缘锯齿细节信息得到了完整

像^[12]。图 3 为提取出的叶脉图像。




图 3 叶片的叶脉图像

Fig. 3 Vein image of leaf

进行的阈值分割结果。

1.4 叶片图像形态学处理

由于在采集时叶片的叶柄大都受到不同程度损伤,而且不同叶片的叶柄长度并不相同,因此有必要将其从二值图像中剔除。使用形态学处理中的开运算,即先进行腐蚀运算,再进行膨胀运算,即可成功剔除叶柄。然而,经开运算所得叶片无柄二值图像的叶缘锯齿细节受到了不同程度损伤,为了恢复原来的完整叶缘锯齿细节,将之与剔除叶柄前的二值图像作“与”运算,便可得到剔除叶柄而又具有清晰完整叶缘细节信息的二值图像,结果如图 5 所示。



图 5 剔除叶柄后的叶片二值图像

Fig. 5 Two binary image without leafstalk

的保留。

2 纹理特征参数的提取

从图 3 可知,叶片的叶脉图像蕴含着非常丰富的纹理信息。由植物形态学理论^[15-16]可知,植物叶片的一级脉(中脉)和二级脉(侧脉)的分布方式是有规律可循的,然而从二级脉继续向下分,不同植物间的差异性却很大。针对此种情况,本研究将从以下两个途径对植物叶片的纹理特征进行提取。

2.1 脉序的人工标定

由文献[15-16]可知,叶脉在叶片上的分布形式一般分为两大类:网状脉序和平行脉序。网状脉序因中脉分出侧脉的方式不同,又可分为羽状脉序和掌状脉序;平行脉序又可分为直出平行脉、弧形平行脉、射出平行脉和横出平行脉。另外,分叉状脉常见于蕨类植物。图 7 所示为各类脉序。




图 7 脉序类型

a. 分叉状脉;b. 掌状脉序;c. 羽状脉序;d. 直出平行脉;
e. 弧形平行脉;f. 射出平行脉;g. 横出平行脉

Fig. 7 Nervation types

a. Bifurcation type;b. Palm type;c. Feather type;d. Straight parallel type;e. Arc parallel type;f. Injection parallel type;
g. Sideways parallel type

从叶脉图像中可以很容易看出其脉序类型,将这 7 种脉序做如表 1 所示的人工标定,且将对应脉序的标定值作为分类器的一个输入分量。将标定的范围确定在 0 到 1 之间,主要是为了便于直接将其作为分类器的输入分量而无需再进行其他操作,这可以在一定程度上简化阔叶树机器识别流程;另外,将脉序类型标定值确定为等差分布,主要是因为阔叶植物世界中,这 7 种脉序类型所属植物种类在数量上基本是均值分布的,这也是由大自然生态平衡法则所决定的。

表 1 脉序类型标定值	
Table 1 Label values of nervation types	
脉序类型 Nervation type	标定值 Label value
分叉状脉 Bifurcation type	0.1
掌状脉序 Palm type	0.2
羽状脉序 Feather type	0.3
直出平行脉 Straight parallel type	0.4
弧形平行脉 Arc parallel type	0.5
射出平行脉 Injection parallel type	0.6
横出平行脉 Sideways parallel type	0.7

2.2 叶脉图像分形维数的计算

纹理特征主要包括共生矩阵特征、功率谱特征、Law’s 纹理能量函数、Markov 纹理随机场等。Philippe 等^[17]对多种纹理特征进行了多种试验比较,一致认为分形维数是一种非常有效的纹理特征,无论从计算精度、速度还是从判别正确率方面都比较高。Dubuisson^[18]、Kasparis^[19]的研究结果表明,用单个尺度上的分形维数作为识别特征参数,不能

很好地实现各种自然纹理特征的识别,这是因为大多数自然物纹理(相对人造物纹理而言)在不同尺度上有不同的分形维数,也就是说单个分形维数不能全面描述图像的分形特征。本研究在文献[20]的基础上,提出一种校订盒子边界的差分盒维数求取算法,用此算法求取的叶脉图像分形维数,有效地克服了传统分形维数求取方法的不足之处,使纹理图像的分形维数具有良好的动态范围,结果的准确性得到了较好提高。算法主要思想如下。

将 $M \times M$ 大小的图像分割成 $L \times L$ 的子块,令 $r=L/M$,将图像想象成三维空间中的曲面:

$(x,y,f(x,y))$,其中 $f(x,y)$ 为图像在 (x,y) 位置处的灰度值。 X,Y 平面被分割成许多 $L \times L$ 的网格。在每个网格上,是一列 $L \times L \times h$ 的盒子, h 为单个盒子的高度。设在第 (i,j) 网格中图像灰度的最小值和最大值分别落在第 k 和第 l 个盒子中,则:

$n_r(i,j)=l-k+1$ 是覆盖第 (i,j) 网格中图像所需的盒子数,可求出覆盖整个图像所需的盒子数 N_r 为:

$$N_r=\sum_{i,j}n_r(i,j)。$$

而分形维数 D 为:

$$D=\lim_{r\rightarrow\infty}\frac{\log(N_r)}{\log(1/r)}。$$

经研究试验,当盒子的边界在范围 $M^{1/3} \leq L \leq M/2$ 时,叶脉图像的分形维数值基本保持稳定(当叶脉图像尺度放大及缩小倍数不超过 4 时)。

最后,选取一组 L ,计算 N_r ,通过线性拟合即可求得分形维数 D 。本研究统一选取原始叶脉图像尺度的 2 倍图像,对其进行分形维数求取。

3 形状特征参数的提取

植物叶片的形状特征也是识别叶片所属种类的有效依据。由于同种叶片有大有小,这样就不能用一些绝对值特征作为分类依据,如周长、面积、横纵轴长等。研究中使用一些相对值特征,从叶片轮廓信息图 6,可得到图 7 所示带最小包围盒和内接圆的叶片轮廓。由图 7 可以得到以下一些形状描述,如:最小包围盒、凸包、内接圆、外接圆等。得到上面这些形状描述之后,利用文献[9]所提出的 8 个叶片形状特征参数,本研究作了进一步精选。精选方法如下:

(a) 针对文献[9]中所提出的每一个形状特征参数,分别求出所采集到的每种叶片 15 个样本的对应特征值,然后求其平均值。

(b) 针对每一特征,在(a)的基础上求取 30 种叶片平均特征值的方差。

(c) 将(b)所获取的 8 个方差值进行降序排列,选出前 6 个,再把这 6 个方差所对应的形状特征作为本研究所确定的叶片形状特征参数。这 6 个参数的定义如下:

- (1)矩形度(Rectangularity):叶片面积与其最小包围盒面积的比值;
- (2)横纵轴比(Axis ratio):叶片最小包围盒宽与长的比值;
- (3)面积凹凸度(Area convexity):叶片凸包面积与叶片面积的比值;
- (4)周长凹凸度(Perimeter convexity):叶片凸包周长与叶片周长的比值;
- (5)圆形度(Circularity):叶片内接圆半径与其外接圆半径之比;
- (6)偏心率(Eccentricity):叶片自身短轴与长轴的比值。

以上 6 项几何形状特征都具有旋转、平移和尺度不变性,加上两个叶片纹理特征共 8 个叶片特征参数,可以构成一个非常有效的特征向量。表 2 即为图 2 所示叶片的 8 项特征参数值。




图 7 带最小包围盒和内接圆的叶片轮廓二值图像
Fig. 7 Profile with bound-box and inscribed circle

表 2 图 2 所示叶片的 8 项特征参数值
Table 2 Values of eight feature parameters of Fig. 2

参数名 Name of parameter	参数值 Value
矩形度 Rectangularity	0. 611
横纵轴比 Axis ratio	0. 452
面积凹凸度 Area convexity	1. 103
周长凹凸度 Perimeter convexity	0. 897
圆形度 Circularity	0. 368
偏心率 Eccentricity	0. 475
脉序类型 Nervation type	0. 300
分形维数 Fractal dimension	1. 596

为了便于对特征向量的进一步处理,用以下公式对所得特征值进行归一化处理:

$$E=\frac{E-E_{\min }}{E_{\max }-E_{\min }}。(1)$$

式中: E 为特征值; $E_{\min }$ 为对应特征的所有叶片样本

特征值中的最小值,类似地 $E_{\max}$ 是最大的特征值。

4 PNN 分类器

人工神经网络技术由于其自学习、自适应和高度并行性等优点而倍受关注。迄今为止,BP 算法是应用最普遍的前馈神经网络学习算法之一,但由于算法本身的制约,其网络训练速度通常较慢,也比较容易陷入局部极小值。尽管采用一些改进的快速学习算法,可在一定程度上解决某些实际问题,但在设计过程中往往都要经过反复的试凑和训练过程,从而无法严格确保每次训练时 BP 算法的收敛性和全局最优性^[21]。与 BP 算法相比,概率神经网络(Probabilistic Neural Networks,PNN)学习速度较快,收敛性好,并且网络结构设计灵活方便,因此得到了广泛的应用^[22]。PNN 的基本结构如图 8 所示。输入变量的维数为 M ,需要识别的模式数为 N ,各模式的训练样本数目分别为 $S_1, S_2, \cdots, S_N$ 。从输入到输出共分输入层、模式层、加和层和输出层 4 层。加和层到输出层的权重为相应模式样本在样本集中所占的比重:

$$w_i=S_i/\sum_i S_i。$$

其余各层间的连接权重均为 1。PNN 中,模式层神经元的总数等于训练样本总数,各模式层神经元并行计算当前输入与本身所代表样本的相似度,即输入是相应样本的概率。加和层神经元对同一模式所有模式层神经元的输出求和,加和层神经元的输出与权重相乘后得到输入属于相应模式的概率。




图 8 PNN 的结构图

Fig. 8 Network structure of PNN

假设求出的叶片训练样本特征值矩阵为:

$$P=\left\{p_1, p_2, \cdots, p_n\right\}。$$

其中 $p_i=\left[x_1, x_2, \cdots, x_M\right]^T(x \in R)。$

再令训练样本数据类别的下标向量为:

$$T=[z_1,z_2,\cdots,z_n]。$$

其中: $z_j,j=1,2,\dots n$,表示 p_j 所属类别。

然后,用 Matlab 去创建一个 PNN 网络对其进行仿真,用仿真后的 PNN 网络作为分类器,可以对测试样本集中的元素进行分类。核心代码如下:

```
T=ind2vec(T);
sp=0.5;
net=newpnn(P,T,sp);
Y=sim(net,P);
Y1=vec2ind(Y)。
```

5 测试结果及分析

本研究选取银杏叶片、柏杨叶片、垂柳叶片、石榴叶片、桂花叶片等 30 种植物叶片,测试 PNN 分类

器的性能及植物叶片的纹理特征作为其分类特征的有效性。每种叶片采集 15 个样本,然后随机抽取 10 个作为训练样本,剩余的 5 个作为测试样本。测试配置为:P4,2.4 GHz 主频,80 G 硬盘,512 M 内存。

为了更客观地观察 PNN 分类器的分类性能,用同一批叶片特征数据对 4-近邻分类器、最近邻分类器以及 BP 网络分别进行了测试,4 种分类器的训练时间、识别时间和平均识别率结果见表 3。同时,为了更好地观察本研究针对植物叶片图像综合特征的识别效果,又去掉叶片图像的纹理特征,仅保留其形状特征,同样用上面所提到的 4 种分类器进行了测试,结果如表 3 所示。

表 3 针对综合特征和形状特征的 4 种分类器的性能对比

Table 3 Compare of 4 types of classifiers toward synthetic features and shape features

4 种分类器 Names of 4 kinds of classifiers	训练时间/ms Training time		识别时间/ms Recognition time		平均识别率/% Average recognition rate	
	综合特征 Synthetic	形状特征 Shape	综合特征 Synthetic	形状特征 Shape	综合特征 Synthetic	形状特征 Shape
4-近邻分类器 4-NN classifier	—	—	8.4	8.6	94.8	92.1
最近邻分类器 1-NN classifier	—	—	3.2	3.1	95.1	92.6
BP 网络 BP network	6 504	5 962	1.6	1.9	96.4	93.2
PNN 分类器 PNN classifier	2.3	2.1	1.2	1.5	98.3	93.7

从表 3 可以看出,PNN 分类器训练时间较 BP 网络大大缩短;4-近邻分类器和最近邻分类器虽然不需要进行训练,但其识别时间明显较 BP 网络和 PNN 分类器长,二者的平均识别率均低于 BP 网络和 PNN 分类器,PNN 分类器平均识别率最高;基于叶片综合特征的平均识别率较基于单纯叶片形状特征高,其中以 PNN 分类器在平均识别率方面的变化最为显著(从 98.3%降到 93.7%),平均识别率的这种变化不仅反映出本研究所提取出的叶片纹理信息的准确性,更说明了植物叶片的纹理特征在植物机器识别中的重要性。同时,通过 4 种分类器的横向比较,可以很直观地看出 PNN 分类器在本研究中的卓越表现。

然而,PNN 分类器也有其自身的弱点,由于模式层神经元的数量等于训练样本的数量,所以,随着训练样本数量的增多,大量高冗余度的训练样本会严重增加 PNN 的结构复杂度,从而影响运算速度和使用效果^[23]。在本研究中,随着训练集中植物叶片种类的增多,无疑也会遇到类似问题,这在以后的研究中还有待对 PNN 分类器做进一步的优化改良,从而继续加深和拓宽植物物种的机器识别研究,以期达到植物保护和生态改良的初衷。

[参考文献]

[1] Ingrouille M J,Laird S M. A quantitative approach to oak variability in some north London woodlands [J]. Lond Nat,1986,65:35-46.

[2] Guyer D E,Miles G E,Schreiber M M,et al. Machine vision and image processing for plant identification [J]. Trans ASAE,1986,29:1500-1507.

[3] Guyer D E,Miles G E,Gaultney L D,et al. Application of machine vision to shape analysis in leaf and plant identification [J]. Trans ASAE,1993,36:163-171.

[4] McDonald T,Chen Y R. Application of morphological image processing in agriculture [J]. Trans ASAE,1990,33(4):1345-1352.

[5] Shearer S A,Holmes R G. Plant identification using color co-occurrence matrices [J]. Trans ASAE,1990,33(6):2037-2044.

[6] Timmermans A J M,Hulzebosch A A. Computer vision system for on-line sorting of pot plants using an artificial neural network classifier [J]. Computers and Electronics in Agriculture,1996,15(1):41-55.

[7] Yonekawa S,Sakai N,Kitani O. Identification of idealized leaf types using simple dimensionless shape factors by image analysis [J]. Trans ASAE,1996,39(4):1525-1533.

[8] Abbasi S,Mokhtarian F,Kittler J. Reliable classification of chrysanthemum leaves through curvature scale space [J]. IC-SSTCV,1997,97:284-295.

- [9] 王晓峰,黄德双,杜吉祥,等. 叶片图像特征提取与识别技术的研究 [J]. 计算机工程与应用,2006,3:191-192.
Wang X F, Huang D S, Du J X, et al. Feature extraction and recognition for leaf images [J]. Computer Engineering and Application, 2006, 3: 191-192. (in Chinese)
- [10] 张 蕾. 基于叶片特征的计算机自动植物种类识别研究 [D]. 长春:东北师范大学,2007.
Zhang L. Research of plant species identification based on leaf features [D]. Changchun City: Northeast Normal University, 2007. (in Chinese)
- [11] Cai Y D, Liu X J, Chou K C. Artificial neural network for predicting protein sub cellular location [J]. Computers and Chemistry, 2002, 26: 179-182.
- [12] 傅 弘,池哲儒,常 杰,等. 基于人工神经网络的叶脉信息提取 [J]. 植物学通报,2004,21(4):429-436.
Fu H, Chi Z R, Chang J, et al. Extraction of leaf vein feature based on artificial neural network [J]. Chinese Bulletin of Botany, 2004, 21(4): 429-436. (in Chinese)
- [13] 巨志勇,陈优广. 一种新的基于链码的填充算法 [J]. 计算机工程,2007,33(17):211-215.
Ju Z Y, Chen Y G. New filling algorithm based on chain code [J]. Computer Engineering, 2007, 33(17): 211-215. (in Chinese)
- [14] 吴雪刚,程小平. 二值图像快速边缘提取的算法 [J]. 计算机应用与软件,2007,24(5):153-155.
Wu X G, Cheng X P. Fast contour tracing algorithm in binary image [J]. Computer Applications and Software, 2007, 24(5): 153-155. (in Chinese)
- [15] 李正理,殷宏章. 植物形态·植物生理 [M]. 北京:中国大百科全书出版社,1988:179-181.
Li Z L, Yin H Z. Plant form and plant physiology [M]. Beijing: China Cyclopedia Publishing Company, 1988: 179-181. (in Chinese)
- [16] 张 彪,淮虎银,金银根. 植物分类学实验 [M]. 南京:东南大学出版社,2007:3-5.
Zhang B, Huai H Y, Jin Y G. Plant taxonomy experiment [M]. Nanjing: Southeast University Publishing Company, 2007: 3-5. (in Chinese)
- [17] Philippe P O, Ricard C D. Performance evaluation for four classes of texture features [J]. Pattern Recognition, 1992, 25(8):819-833.
- [18] Dubuisson M P. Efficacy of fractal features in segmenting images of natural textures [J]. Pattern Recognition Letters, 1994, 15(4):419-430.
- [19] Kasparis T. Texture description using fractal and energy features [J]. Computers & Electrical Engineering, 1995, 21(1): 21-31.
- [20] Chaudhuri B B, Sarkar N. Texture segmentation using fractal dimension [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1995, 17(1):72-77.
- [21] 许 东,吴 铮. 基于 MATLAB6. x 的系统分析与设计——神经网络 [M]. 西安:西安电子科技大学出版社,2002:24.
Xu D, Wu Z. System analysis and engineering based on MATLAB6. x——neural networks [M]. Xi'an: Publishing Company of University of Xi'an Electronic Science and Technology, 2002: 24. (in Chinese)
- [22] Gomm J B, Yu D L. Selecting radial basis function network centers with recursive orthogonal least squares training [J]. IEEE Trans on Networks, 2000, 11(2):306-314.
- [23] Labonte G. On the efficiency of OLS reduced probabilistic neural networks for aircraft-flare discrimination [C]. Proceedings of the International Joint Conference on Neural Networks. New York: IEEE Press, 2003:2306-2311.