

基于贝叶斯优化神经网络的物体形状分类

张善新, 范强*, 周治平

江南大学物联网技术应用教育部工程研究中心, 江苏 无锡 214000

摘要 针对传统物体形状分类算法中图像的空间结构特征表示不够准确,以及分类器模型参数易陷入局部最优的问题,提出结合重叠金字塔与贝叶斯优化神经网络的物体形状分类方法。首先,将物体轮廓分割为不同长度的轮廓片段作为形状的基本特征,并用局部线性编码器对其编码;然后,使用提出的空间重叠金字塔模型,将图像表示为空间金字塔直方向量;最后,使用贝叶斯优化的前馈神经网络分类器对得到的图像表达进行分类。在常用的Animal标准图像库上实验证明,本文方法可以完整记录形状的内容和结构信息,与轮廓片段包算法相比,准确度提高了1.4%。

关键词 图像处理; 形状分类; 贝叶斯优化; 重叠金字塔; 前馈神经网络

中图分类号 TP391 文献标识码 A

doi: 10.3788/LOP55.061011

Object Shape Classification Based on Bayesian Optimized Neural Network

Zhang Shanxin, Fan Qiang, Zhou Zhiping

Engineering Research Center of Internet of Things Technology Applications, Ministry of Education, Jiangnan University, Wuxi, Jiangsu 214000, China

Abstract In order to solve the problems of traditional object classification methods, such as the inaccurate expression of spatial structure features, and the classification model parameters trapped in local optimum, we propose a method that combines the overlapping pyramid method with the Bayesian optimized neural network. Firstly, we extract the contour fragments of different lengths from the object contour as features, and encode them with the locality-constrained linear coding encoder. Then, the proposed spatial overlapping pyramid histogram is used to represent the images. Finally, the Bayesian optimized feedforward neural network classifier is used to accomplish the classification. The experimental results based on the standard Animal dataset show that the accuracy of the proposed method is improved by 1.4% as compared to the Bag of Contour Fragment method, indicating that the proposed method can accurately represent the context and structure of the shape and is effective in object classification.

Key words image processing; shape classification; Bayesian optimization; overlapping pyramid; feedforward neural network

OCIS codes 100.2000; 150.0155; 200.3050; 100.4999

1 引言

形状是人类理解图像的基本属性之一,即使没有颜色、纹理和光照等因素,人类依然可凭借物体的形状信息识别其类别。因此,物体形状分类在图像领域及模式识别中获得了广泛关注^[1-7]。目前的研究重点是寻找一个可完整表达物体轮廓信息和空间

结构信息的形状表达,来解决由遮挡、角度和姿态造成的形状变化问题^[2]。Belongie等^[3]提出使用形状上下文算法,通过描述若干个参考点周围的形状分布来记录物体轮廓的形状信息,实现对结构简单物体的形状分类。Jia等^[4]为解决物体的几何变换问题,使用分层投影不变的形状描述符来记录形状信息,该方法虽然具有较强的抗干扰能力,但缺乏对轮

收稿日期: 2017-11-14; 收到修改稿日期: 2017-12-13

基金项目: 江南大学自主科研基金(1252050205170640)

作者简介: 张善新(1987—),男,博士,讲师,主要从事人工智能与模式识别方面的研究。E-mail: 491435718@qq.com

* 通信联系人。E-mail: 478581367@qq.com

廓细节的描述。王云鹏等^[5]为识别出飞机目标,使用回波时频图算法提取灰度共生矩阵和 Tamura 纹理特征,相对于轮廓特征,该方法需要较复杂的预处理过程。Wang 等^[6]采用轮廓片段包(BCF)方法,使用形状上下文描述物体轮廓信息,并使用空间金字塔记录轮廓的空间分布,获得图像表达,并通过支持向量机分类器证明该方法相对之前算法具有良好的分类性能。最近,许多研究工作将改进的轮廓片段包方法应用到图像分类问题中。Palazón-González 等^[7]使用隐马尔科夫算法将物体轮廓描述为一个环形线条来实现形状分类,但环形线条在物体轮廓上开始点的确定情况对分类性能影响很大。Shen 等^[8]使用轮廓词包模型将物体的骨架特征与轮廓特征结合起来,但其模型训练复杂及计算复杂度远大于单独使用轮廓特征的算法。此外,Hasim 等^[9]提出使用重心线距离描述符记录物体轮廓的形状信息,实现了对树叶的形状分类,但该方法需要清晰的树叶图像,且易受噪声影响。Bicego 等^[10]利用生物序列记录物体的形状信息,依据得到的形状表达的相似性进行分类,但该方法缺少物体的结构信息。程效军等^[11]利用形状内部的颜色信息和强度信息完成联合分类,但忽略了图像中的形状信息,识别精度不高。范强等^[12]提出改进贝叶斯程序学习算法,通过轮廓片段库去拟合测试样本,可有效处理物体的形状变化,但对形状细节描述不够。Li 等^[13]在文献^[6]得到的图像表达上使用预处理的随机梯度下降之万动力(pSGLD)分类方法,以多次迭代为代价训练出最优分类模型,得到较好结果。

针对上述形状描述片面,以及训练分类模型的问题,在 BCF^[6]的基础上,提出一种基于改进的贝叶斯优化神经网络的物体形状分类算法。在用传统空间金字塔模型分割物体轮廓时,第三层分割用的是面积较小的 4×4 模板,对物体整体结构表达不够完整,也易产生不包含轮廓信息的空白金字塔块,影响算法性能。本文设计的重叠空间金字塔在原金字塔第二层表达的基础上,增加更多的空间结构信息,并将每个子空间金字塔块剩余的图像区域作为其互补金字塔块,得到轮廓信息更加完整的图像表达。在分类阶段,使用 Chen^[14]提出的自适应动量的随机退火温度调节(Santa)算法,并结合前馈神经网络方法。Santa 算法将模拟退火算法、预处理器与随机梯度的尔可夫链蒙特卡罗(SG-MCMC)算法相结合,快速并稳定地计算出模型的全局最优参数,得到最优分类器。

2 相关算法

2.1 轮廓片段包

BCF^[6]是使用形状上下文记录物体轮廓的形状信息,并通过局部线性编码(LLC)算法与空间金字塔算法得到一个信息丰富的图像表达的算法。相较于其他形状描述方法,BCF 融合了物体轮廓的形状信息与空间分布信息,整个算法流程分为以下 4 步。

1) 使用离散曲率演化算法(DCE)^[6]提取某一物体轮廓 S 的几何顶点 $u = (u_1, \dots, u_T)$, 顺时针方向以任意两几何顶点间的物体轮廓作为一个轮廓片段,因而得到物体轮廓 S 的轮廓片段集 $C(S)$, 其中 $C(S) = \{c_{ij} = (u_i, u_j), i \neq j, i, j \in [1, \dots, T]\}$ 。

2) 使用形状上下文算法^[4]对提取的每个轮廓片段 c_{ij} 计算其轮廓片段特征 \mathbf{X}_{ij} , 并使用 K 最近邻算法对所有轮廓片段特征训练特征字典 $\mathbf{B} \in \mathbf{R}^{d \times M}$ 。

3) 使用 LLC 编码算法将每个轮廓片段特征 \mathbf{X}_{ij} 编码为特征编码 \mathbf{W}_{ij} 。

4) 使用空间金字塔算法分割图像,并用最大池方法计算每个子金字塔块的特征,依次连接得到图像表达。

2.2 空间金字塔

空间金字塔方法^[15]是从空间角度将图像按照多种尺度分成子图像块,然后使用最大池方法计算每个尺度上的子金字塔块的图像特征,将所有子金字塔块特征按顺序连接,得到最终的图像表达,以有效记录图像的空间结构。

空间金字塔建立图像表达的整个流程如下。首先,将图像 S 在不同尺度 $l = 0, 1, \dots, L$ 上划分 $2^l \times 2^l$ 个子图像块;然后,对每个子图像块 M_l^i , 使用最大池方法:

$$f(S, r) = \max(\mathbf{W}^Z \mid Z \in M_l^i), \quad (1)$$

式中 \mathbf{W}^Z 表示在位置 Z 的轮廓片段编码。因此,每个子图像块得到相同维度的 $f(S, r)$, 图像 S 的最终图像表达为 $f(S), R$ 为子图像块个数。

$$f(S) = [f(S, 1), \dots, f(S, R)]^T. \quad (2)$$

3 贝叶斯优化神经网络算法

本文算法的整个流程如图 1 所示,在训练阶段,利用 2.1 节的 BCF 对图像进行轮廓片段提取,并使用 LLC 编码得到特征编码,然后使用本文提出的重叠空间金字塔方法对图像进行空间分割,利用最大池方法计算每个子金字塔块的空间金字塔直方图向量,从而得到最后的图像表达,用于贝叶斯优化神经

网络分类器的模型训练。在测试阶段,使用训练阶段得到的特征字典对测试样本的轮廓片段集进行编码,并使用重叠空间金字塔得到测试样本的图像表达,最后由贝叶斯优化神经网络分类器完成分类。

以下主要介绍算法的两个改进点,即针对图像空间结构问题的重叠空间金字塔算法与针对分类器参数优化的贝叶斯优化神经网络算法。

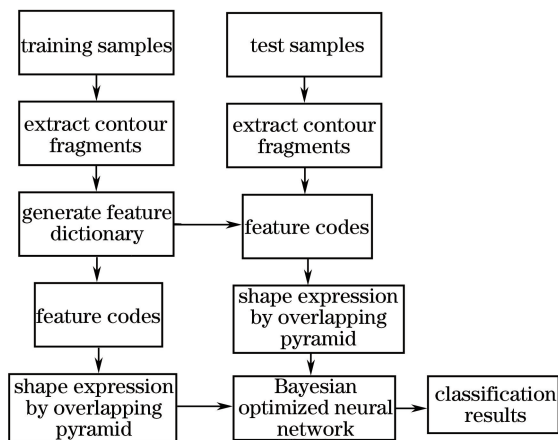


图1 算法流程图

Fig. 1 Algorithmic framework

3.1 重叠空间金字塔

重叠空间金字塔是针对传统金字塔在物体形状分类中空间结构表达不清,以及易生成空白金字塔块而设计的新金字塔模型。主要对空间金字塔的第二层通过重叠子金字塔块和互补子金字塔块的方法,增加更多的关于物体形状的结构信息^[15]。此外,还将传统金字塔第三层 4×4 的分割尺度改变为 3×3 的尺度,用此来尽量减少无轮廓片段的子金字塔块。第二层重叠子金字塔块均可以描述 $1/4$ 的图像区域,依次连接可以描述出物体的空间形状分布,每个互补子金字塔块则记录了重叠子金字塔块区域的形状与整个物体形状的分布情况,因而相较于传统空间金字塔方法具有更好的空间表达能力。

在金字塔第二层 ($l=2$),每个子金字塔块的大小为 $A=1/(2 \times 2) \times S$,使用平移的方法获取重叠子金字塔块,平移的步长为 $w_{\text{step}}=1/4l_s$,最终从一幅图像中得到 9 个重叠子金字塔块。对每个子金字塔块 A ,将图像中去除此子金字塔块的其他区域作为它的互补子金字塔块 A_{co} ,然后将所有提取到的子金字塔块集合作为第二层的金字塔池 p_{pool} 。

$$p_{\text{pool}} = \{A_r, A_{\text{cor}}\}, r = 1, 2, \dots, 9. \quad (3)$$

获得的第二层金字塔池再与第一层与第三层的金字塔池结合起来,最终得到由 28 个子金字塔块组成的重叠金字塔模型。之后,按照 2.1 节的训练出

轮廓片段的特征字典,对每一个子金字塔块区域 A_r ,获得此块区域包含的所有轮廓片段,即轮廓片段的两个端点在此区域内,使用 LLC 编码算法^[6]计算其编码,通过最大池方法得到每个子金字塔块的特征 $f(S, r)$,最后整个的图像表达是

$$f(S) = [f(S, 1), \dots, f(S, R)]^T, R = 28. \quad (4)$$

3.2 贝叶斯优化神经网络分类器

贝叶斯优化神经网络分类器主要通过贝叶斯推断来解决传统分类器中模型参数的病态曲率问题和参数过拟合问题,从而解决局部最优问题,以达到模型参数的全局最优化^[13]。相对于 pSGLD 算法,贝叶斯优化神经网络分类器使用退火算法动态优化全局,减少了优化时间。

在物体形状分类中,同类物体内部由于姿态、结构和角度的变化,提取的图像表达具有较大差异,因此本文使用前馈神经网络分类器结合 Santa 算法训练出一个全局最优模型。优化算法的目的是最小化前馈神经网络模型参数的目标函数 $U(\theta)$,设 $\theta \in \mathbf{R}^p$ 为模型参数, $\{x_n\}$ 为从每个图像上得到的图像表达,其中 $n=1, \dots, N$, $p(\theta)$ 是前验, $p(x_n | \theta)$ 是第 n 次似然项,目标函数为

$$U(\theta) \triangleq -\log p(\theta) - \sum_n \log p(x_n | \theta), \quad (5)$$

式中 $-\sum_n \log p(x_n | \theta)$ 表示损失函数。假设某一最小批样本的随机梯度 $\tilde{f}_i(\theta) = \nabla \tilde{U}_i(\theta)$,即与真实梯度的无偏估计,辅助变量 $u_i \in \mathbf{R}^p$ 表示动量, $\alpha_i \in \mathbf{R}^p$ 表示每个参数的动量权重, η_i 表示学习速率,系统温度 $1/\beta$ 代表迭代步长。动量权重在采样过程中不断更新以平衡系统温度 $1/\beta$,模型参数 θ 的更新公式为

$$\begin{cases} \theta_i = \theta_{i-1} + \eta_i u_i \\ u_i = (1 - \eta_i \alpha_{i-1}) \odot u_{i-1} - \eta_i \tilde{f}_{i-1}(\theta) + \sqrt{2\eta_i/\beta} \zeta_i \end{cases}, \quad (6)$$

式中 ζ_i 为标准的正态随机向量。

在求解时,使用对称分裂算法^[14]将 Santa 算法的微分方程分解为几个子方程,然后逐步进行解决:

$$\begin{cases} d\theta = G_1(\theta) p dt \\ dp = \left[-G_1(\theta) \nabla_{\theta} U(\theta) + \frac{1}{\beta} \nabla_{\theta} G_1(\theta) \right] + \\ G_1(\theta) [\Xi - G_2(\theta)] \nabla_{\theta} G_2(\theta) dt + \left[\frac{2}{\beta} G_2(\theta) \right]^{\frac{1}{2}} d\omega \\ d\Xi = \left[\text{diag}(p \odot p) - \frac{1}{\beta} I \right] dt \end{cases}, \quad (7)$$

式中 t 表示迭代次数, w 表示标准布朗动量即参数权重。 $G_1(\theta)$ 和 $G_2(\theta)$ 表示 $U(\theta)$ 和布朗运动的几何信息, 动量 $p = u/\eta^{1/2}$, 矩阵 $\Sigma = \text{diag}(\alpha)/\eta^{1/2}$, 从而求出 $\nabla_{\theta}G_1(\theta)$ 和 $\nabla_{\theta}G_2(\theta)$, 控制边缘概率分布变化。退火算法对迭代过程动态优化时, 使用一系列变化的温度倒数变量 $\beta = \{\beta_1, \beta_2, \dots\}$, s.t. $\beta_i < \beta_j, i < j$ 作为动态迭代步长, 当微分方程达到平衡状态时 $\beta_n \rightarrow \infty$, 此时温度的边缘概率分布 $\rho_{\theta}(\theta) \triangleq \lim_{\beta \rightarrow \infty} \exp[-\beta U(\theta)]$, 从而求出全局最优模型 $U(\theta)$, 得到全局最优的前馈神经网络分类器。之后, 将使用重叠金字塔算法得到的图像表达作为输入, 代入此 Santa 模型中进行训练, 可以有效解决由于物体形状之间较大差异而造成的分类模型参数局部最优的

问题, 提高分类性能。

4 实验与结果分析

仿真实验基于 Windows 7 系统、MATLAB 2014a 平台, 计算机配置为 Intel Core i5-4200M CPU 2.5 GHz、16 GB RAM。

4.1 Animal 图像库

Animal 图像库^[2]包含马、兔、猴子等 20 类自然界动物, 每类 100 张图片, 共 2000 张图像, 样本图如图 2 所示, 每类物体选择 4 张样本图。由于同一类动物会有各种各样的姿态, 图像库具有较大的类内形态变化, 因此它是标准形状库中识别率最低的一个。




图 2 Animal 库样本图

Fig. 2 Examples of Animal dataset

以 Animal 数据库作为标准库, 与其他分类方法进行比较, 设置 Santa 算法的神经网络大小为 800×800 , 批大小为 500。神经网络的输入为使用重叠空间金字塔得到的图像表达, 其余参数与文献[16]一致, 自适应曲率 $\lambda = 10^{-5}$ 、默认梯度为 0.99。实验主要通过准确度、精确度、召回率和 F1 值等多分类器常用的性能指标进行比较, 各指标均是值越高性能越好。使用折半训练方法, 即随机取一半样本作为训练样本, 其余作为测试样本, 重复 10 次, 此方法每次实验具有较多的测试样本, 可以更准确地显示分类精度随着模型参数的变化趋势, 实验结果如表 1 所示。在实现文献[13]提出的形状分类方法时, 由于实验环境的变化, 仿真后的分类精度为 83.9%, 低于原文提到的 84.7%。本文提出的重叠金字塔结合 Santa 的方法及 pSGLD 算法均使用文献[6]提取的轮廓片段特征。本文算法与 BCF 相比, 在提取同样的特征基础上准确度提高 1.4%, 召回率提高 1.75%, 原因是重叠金字塔算法对形状空间结构的描述更为详细, 且贝叶斯优化使得分类器具有最好的分类性能。Santa 算法与 pSGLD 算法相比, 同属于贝叶斯优化神经网络方法, 此算法是在

SG-MCMC 算法基础上结合了自适应预处理器和模拟退火算法, 本文将 Santa 算法与重叠空间金字塔相结合, 得到的分类结果在准确率、F1 值几个指标上平均提高约 0.7%。

表 1 Animal 图像库的实验结果

Table 1 Results of the Animal dataset %

Method	Accuracy	Precision	Recall	F1
BCF ^[6]	83.20	83.19	82.85	83.02
Bioinformatics approach ^[11]	83.70	83.67	83.60	83.63
pSGLD ^[14]	83.90	83.98	84.00	83.83
Proposed	84.60	84.67	84.60	84.63

折半训练方法得到的每个类别的详细分类准确度如表 2 所示, 可以看出, 本文算法在多数类别上优于 BCF 算法, 并且在牛、猴和兔几个类别上相对 BCF 算法准确度明显提高, 这是因为本文算法通过迭代选择最优分类模型, 但本文算法在海豚一类上的精度较低, 主要是因为海豚和鱼的轮廓空间分布类似。同 pSGLD 算法相比, 本文方法在大多数类别上的准确度相差不多, 主要在豹和鼠两类上的准确度有所提高, 原因主要是本文算法对物体的空间结构信息记录较为详细, 故对物体的姿态稳健性较强。

表 2 在 Animal 库中各方法的详细精度
Table 2 Detailed accuracy of each method in Animal Dataset

Method	Bird	Butterfly	Cat	Cow	Crocodile	Deer	Dog	Dolphin	Duck	Elephant
BCF ^[6]	87.6	92.2	73.8	77.4	74.8	90.4	82.6	89.0	87.0	95.2
pSGLD ^[13]	87.8	97.4	76.3	87.2	72.8	89.7	84.4	78.2	88.0	95.5
Proposed	88.0	97.8	76.0	87.8	72.5	89.7	86.2	80.0	88.3	95.5
Method	Fish	Fly-bird	Hen	Horse	Leopard	Monkey	Rabbit	Rat	Spider	Tortoise
BCF ^[6]	79.8	70.0	94.2	95.4	66.4	58.4	85.8	70.6	99.2	93.6
pSGLD ^[13]	81.8	68.2	91.4	96.0	67.9	70.2	91.1	64.5	100	90.0
Proposed	81.8	68.2	91.5	95.8	70.0	71.9	92.1	68.2	100	90.5

4.2 ETH-80 图像库

ETH-80 图像库如图 3 所示,包含 8 类,每类有 10 个物体,每个物体采集角度不同的 41 张彩色图像,整个图像库包含 3280 张图像。此图像库提供了每张图像的二进制图像,因此可以直接使用本方法进行物体分类。ETH-80 图像库不仅包含自然界中的一些动植物,而且还包含一些人造物体,如杯子、汽车等,对每类物体采集的图像角度更为广泛。为统一训练方法,也使用折半训练方法进行测试,得到的分类实验结果如表 3 所示。在常见真实物体的形状分类中,本文算法的性能明显优于之前的算法,使用折半训练法可达到 92.05% 的准确度,与 BCF 算法相比提高了约 1.8%,相较于 pSGLD 算法,本文算法在准确度、F1 值等各性能指标上均有所提高,体现出本文算法适用于生活中的人造物体及自然界各种动植物的图像分类。



图 3 ETH-80 图像库的 80 个物体

Fig. 3 80 objects in ETH-80 dataset

表 3 ETH-80 图像库的分类结果

Table 3 Classification results in ETH-80 dataset %

Method	Accuracy	Precision	Recall	F1
BCF ^[6]	90.22	90.03	89.92	89.97
Bioinformatics approach ^[11]	90.68	90.47	90.34	90.40
pSGLD ^[14]	91.66	91.62	91.69	91.65
Proposed	92.05	92.08	92.10	92.09

4.3 算法分析

在 Animal 图像库实验中,本文算法与传统的支持向量机(SVM)分类器相比,在精度上有大幅度的提高,但需要损耗较长的模型参数训练时间作为代价。在分类器模型训练时,传统 SVM 分类器训练仅仅需要几秒钟即可完成,而 Santa 算法完成 1000 次模型参数迭代需要约 1.5 h,两者的测试时间没有太大差别。和另一贝叶斯优化神经网络的 pSGLD 算法^[13]相比,本文方法精确度更高,而且 Santa 算法通过模拟退火算法降低了参数优化的迭代次数。

图 4 所示为在折半训练方法下,本文算法、单独的 Santa 算法和 pSGLD 算法随着模型参数优化的分类性能比较。本文算法和 Santa 算法具有较平稳的增长速率,并且需要迭代约 650 步达到平稳最优精度;而 pSGLD 算法增长速率波动较大,达到最优模型精度 83.9% 时需要迭代约 850 步。因此本文选择将重叠空间金字塔方法与 Santa 算法结合起来,在得到最高精度的同时,花费最少迭代时长。

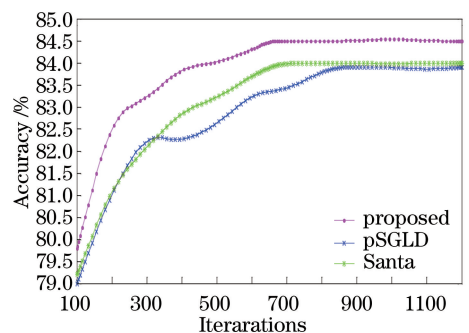


图 4 本文算法与 pSGLD 算法实验对比

Fig. 4 Comparison of proposed method and pSGLD method

5 结 论

所提出的贝叶斯优化神经网络方法在物体形状表达上综合考虑了形状结构的分布和形状的具体信息,通过重叠空间金字塔将图像中物体的形状

信息与结构信息相结合生成图像表达,之后使用贝叶斯推断训练前馈神经网络分类器的模型参数,使得分类精度相对传统方法提高较多。另外,本文算法相对之前的贝叶斯优化分类器 pSGLD 算法,在精度提高的同时,在模型参数的训练时间上减少了迭代次数。然而,相较于传统分类器,本文方法模型参数训练时间较长,另外,物体形状分类主要依靠物体轮廓信息分类,在真实复杂场景中需要先对图像中的物体进行较好分割,本文方法才能得到较好的分类结果。

参 考 文 献

- [1] Luo S, Mou W, Althoefer K, *et al.* Novel tactile-sift descriptor for object shape recognition [J]. *IEEE Sensors Journal*, 2015, 15(9): 5001-5009.
- [2] Bai X, Liu W, Tu Z. Integrating contour and skeleton for shape classification [C] // *Computer Vision Workshops (ICCV Workshops)*, 2009: 360-367.
- [3] Belongie S, Malik J, Puzicha J. Shape matching and object recognition using shape contexts [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24(4): 509-522.
- [4] Jia Q, Fan X, Liu Y, *et al.* Hierarchical projective invariant contexts for shape recognition [J]. *Pattern Recognition*, 2016, 52: 358-374.
- [5] Wang Y P, Hu Y H, Lei W H, *et al.* Aircraft target classification method based on texture feature of laser echo time-frequency image [J]. *Acta Optica Sinica*, 2017, 37(11): 1128004.
王云鹏, 胡以华, 雷武虎, 等. 基于激光回波时频图纹理特征的飞机目标分类方法 [J]. *光学学报*, 2017, 37(11): 1128004.
- [6] Wang X, Feng B, Bai X, *et al.* Bag of contour fragments for robust shape classification [J]. *Pattern Recognition*, 2014, 47(6): 2116-2125.
- [7] Palazón-González V, Marzal A, Vilar J M. On hidden Markov models and cyclic strings for shape recognition [J]. *Pattern Recognition*, 2014, 47(7): 2490-2504.
- [8] Shen W, Jiang Y, Gao W, *et al.* Shape recognition by bag of skeleton-associated contour parts [J]. *Pattern Recognition Letters*, 2016, 83: 321-329.
- [9] Hasim A, Herdiyeni Y, Douady S. Leaf shape recognition using centroid contour distance [C] // *IOPC onference Series: Earth and Environmental Science*, 2016, 31(1): 012002.
- [10] Bicego M, Lovato P. A bioinformatics approach to 2D shape classification [J]. *Computer Vision and Image Understanding*, 2016, 145: 59-69.
- [11] Chen X J, Guo W, Li Q, *et al.* Joint classification method for terrestrial LiDAR point cloud based on intensity and color information [J]. *Chinese Journal of Lasers*, 2017, 44(10): 1010007.
程效军, 郭王, 李泉, 等. 基于强度与颜色信息的地面 LiDAR 点云联合分类方法 [J]. *中国激光*, 2017, 44(10): 1010007.
- [12] Fan Q, Zhang S X. Object shape classification based on improved Bayesian program learning [J]. *Laser & Optoelectronics Progress*, 2017, 54(12): 121504.
范强, 张善新. 基于改进贝叶斯程序学习的物体形状分类 [J]. *激光与光电子学进展*, 2017, 54(12): 121504.
- [13] Li C, Stevens A, Chen C, *et al.* Learning weight uncertainty with stochastic gradient MCMC for shape classification [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 5666-5675.
- [14] Chen C, Carlson D, Gan Z, *et al.* Bridging the gap between stochastic gradient MCMC and stochastic optimization [C] // *Proceedings of the 19th International Conference on Artificial Intelligence and Statistics*, 2016: 1051-1060.
- [15] Shi Z L, Ye Y D, Wu Y P, *et al.* Crowd counting using rank-based spatial pyramid pooling network [J]. *Acta Automatica Sinica*, 2016, 42(6): 866-874.
时增林, 叶阳东, 吴云鹏, 等. 基于序的空间金字塔池化网络的人群计数方法 [J]. *自动化学报*, 2016, 42(6): 866-874.
- [16] Li C, Chen C, Carlson D E, *et al.* Preconditioned stochastic gradient Langevin dynamics for deep neural networks [C] // *Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence*, 2016: 1788-1794.