



基于局部 Haar 和 PHOG 特征的月球撞击坑综合检测方法

蒋先刚*, 蒋兆峰, 盛梅波, 丘赞立

华东交通大学基础科学学院, 南昌 330013

*联系人, E-mail: jxg_2@tom.com

收稿日期: 2013-06-17; 接受日期: 2013-09-17

国家自然科学基金(批准号: 61262031)和中国科学院地理研究所科研项目(编号: YQZX-HT-KY-QT-20120119-1)资助

摘要 基于月貌图像的撞击坑的检测需要采用合理的特征选择和机器学习策略, 我们提出了一种基于区域局部灰度和梯度分布特征与机器学习方法相结合的撞击坑检测方法. 这种方法将 Haar 特征与 AdaBoost 结合, 使候选撞击坑区域的定位更加快捷, 采用局部区域的塔式梯度方向直方图(PHOG)与高效的支持向量机学习算法相结合的方法用来精确地对撞击坑候选区域进行分类. 考虑到 Haar 特征数的繁多而采用 AdaBoost 作为特征提取和分类方法, 并由于 PHOG 特征的每一项都对分类起作用, 将撞击坑区域统一预处理为不含阴阳面的各向梯度向量基本一致的圆形模糊边界, 使圆形撞击坑的正样本特征具备更多的稳定性. 文中还讨论了几种特征和分类方法的机理和集成, 以及参数调整对撞击坑检测的效率分析.

关键词 撞击坑检测, 塔式梯度方向直方图特征, Haar 特征, 机器学习

PACS: 96.20.-n, 96.20.Ka, 95.75.Mn, 95.75.Pq

doi: 10.1360/132013-293

撞击坑是由流星体撞击行星表面而产生的地形学物征, 对撞击坑、月海和高地等典型月貌的影像特征的检测与识别是探月工程数据处理环节中亟待解决的一个关键问题, 这将极大提高月球地貌的标记和分析的速度, 可以快速准确地推断月球表面的相对地质年龄和地表特性, 这些技术和处理方法还可以用于航天器导航的定位和障碍物躲避等^[1,2]. 目前许多撞击坑探测方法都是基于撞击坑呈现出半圆月

牙状的高亮和阴影对区域, 但这些撞击坑识别方法对光照条件有较大的依赖, 其识别效率受到一定的影响.

本文探索利用每一个撞击坑所含有的特有纹理特征, 将具备和不具备半圆月牙状的高亮和阴影对的撞击坑统一处理为含模糊圆形边缘的区域图像, 结合撞击坑的区域和边缘分布的 Haar 特征和 AdaBoost 组成强分类器对月球地貌图像中撞击坑的

引用格式: 蒋先刚, 蒋兆峰, 盛梅波, 等. 基于局部 Haar 和 PHOG 特征的月球撞击坑综合检测方法. 中国科学: 物理学 力学 天文学, 2013, 43: 1421-1429
Jiang X G, Jiang Z F, Sheng M B, et al. A Compositive detection method of lunar crater based on partial Haar and PHOG feature (in Chinese). Sci Sin-Phys Mech Astron, 2013, 43: 1421-1429, doi: 10.1360/132013-293

候选区域进行快速定位, 并利用局部纹理的塔式梯度方向直方图(Histogram of Oriented Gradients, HOG)特征与支持向量机(Support Vector Machine, SVM)结合对提取的候选区域紧支集的每个撞击坑进行校验和分类, 并将这些特征和方法进行合理搭配和组合以提高月球图像撞击坑识别系统的识别效率和鲁棒性.

1 典型月貌影像特征区域的分割和提取

撞击坑识别策略实现的前提是获得撞击坑与背景对比强烈的图片, 这就需要首先采用比较合适的图像预处理, 第二阶段致力于有效地分割出一组可能性较大的撞击坑候选区域, 这包括合适的特征选择和搜索方法, 而第三阶段是构建出非撞击坑和撞击坑分类器^[3].

1.1 月球整体地貌图像的预处理

图像预处理的目的是使描述撞击坑特征的图像更加简练、独特性更强、信息量少而唯一, 减少了需要用于区分每个撞击坑图像的训练集. 月球图像的预处理主要包括直方图规范化、形态学和基于 Hessian 特征的过滤运算等. 灰度图像直方图规范化是自适应的按金标准调整的优于归一化的空域对此增强的方法. 直方图规范化易于处理不同光照条件下的月球表面图像, 即将一幅图像通过灰度变换后, 使其具有与某一标准图像相似的直方图或具有某一特定函数形式的直方图.

(1) 首先将原始图像(图 1(a))进行灰度均衡化处理, 其中 n_j 是灰度为 j 的像素的个数, n 是所有像素的个数, S_k 为原始图像灰度的累积概率, G 为累积概率的投影函数.

$$S_k = G(r_k) = \sum_{j=0}^k P_r(r_j) = \sum_{j=0}^k \frac{n_j}{n}, \quad k = 0, 1, \dots, L-1. \quad (1)$$

(2) 然后将目标图像也进行灰度均衡化处理, 其中 V_k 是目标图像灰度的累积概率.

$$V_k = G(Z_k) = \sum_{j=0}^k P_z(z_j) = \sum_{j=0}^k \frac{n_j}{n}, \quad k = 0, 1, \dots, L-1. \quad (2)$$

(3) 由于 $P_r(r_j)$, $P_z(z_j)$ 具有同样的均匀密度, 即 $V_k = S_k$, 将 S_k 代入式(2)的逆变换函数 G^{-1} , 其结果就是所求变换后的灰度级. 其中, Z_k 是均衡化图像的原始灰度 k 的输出灰度.

$$Z_k = G^{-1}(V_k) = G^{-1}(S_k). \quad (3)$$

图 1 是按统计上的金标准原始图片进行直方图规范化处理前后的对比效果图, 图 1(a)是阳光照射较强的一个月貌区域, 图 1(b)是规范化后的结果, 其撞击坑的各向基本一致的圆形边界已变得更加清晰明了, 且还可削弱部分阴阳月牙对效果. 另外, 阴影补偿^[4]的方法还可使阴暗月牙区域细节更加清晰和明亮.

1.2 撞击坑区域的特征提取与分类

1.2.1 撞击坑区域的灰度分布特征提取和候选区域分类

Haar 特征计算检测窗口中每一个矩形区域的像素和并取其差值, 该值的大小取决于检测窗口的大小. HOG 特征则是通过计算和统计图像局部区域的梯度方向直方图来构成特征, 即计算每个像素的梯度并统计出每个方向的像素的数量.

撞击坑图像呈现边界模糊, 阴面和阳面成对出现, 在整体上表现为椭圆形状, 呈点状和弧线状灰度等级分布等显性特征, 这些适应于用纹理特征进行表述. 我们选择了一个简单的几何纹理 Haar 特征提取方法作为区域的初步划定, 该特征将一个矩形区域划分为黑色和白色的 2 个部分, 其特征值由研究区域的黑色区域与白色区域的灰度值相减而获得. 在一个标准尺寸区域里还包括更小尺度的同样黑白相间模型的叠加和交错排列而包括许多 Haar 特征, 这样的特征值在空间和尺度上都是具备纹理特征的小波属性. 在训练和识别过程中, 对于每一个撞击坑候选区域图像块能根据自身原始大小调整为标准尺寸的像素块, 在标准尺寸下选取八种不同黑白相间部分组成的 Haar 边缘和线性特征模型(左边八个)及选

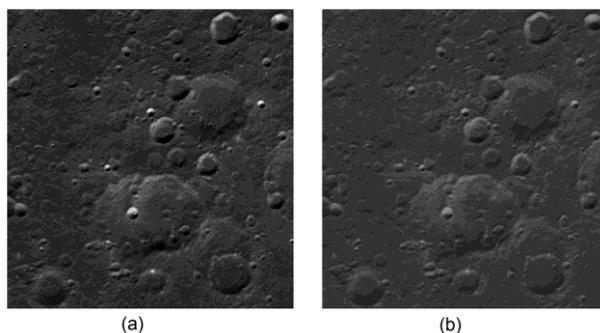


图 1 直方图规范化处理前后的对比效果图

Figure 1 The images before and after being processed by the histogram specification.

取的不同尺寸和位置的的特例的特征(右边两个)如图 2 所示.

每种尺度块应用于标准尺寸区域里的各个交错位置, 如取标准样本的尺寸均为 48×48 , 每种尺度块的变化范围从 2×2 到 48×48 , 宽、高每次变化均增加 2 个像素, 步长为尺度块搜索窗口大小的一半, 则对应于 3314 个搜索窗口的 6 个 Haar-Like 边缘特征类型, 得到共 19884 个包含特征类型和相应矩形位置及其大小的特征, 需要在这些特征中选出最能反映撞击坑纹理特性的特征. 图 3 是矩形特征对所有样本的平均特征值分布图, 图 3(a)是按所有样本的特征值平均数升序排列的正样本(撞击坑图像)和负样本(非撞击坑图像)的平均特征分布图, 图 3(b)和图 3(c)分别是图 3(a)里前 200 个特征和后 200 个特征的平均特征分布图, 由这三幅图像可知, 负样本在整个分布图上都呈现非常小幅值的变化, 正样本在分布图中间的特征值呈现非常小幅值的变化, 而前 200 个特征和后 200 个特征对于正样本的特征值却呈现较大的幅值变化, 故 Haar 矩形特征在这个范围内具有较好的识别能力.

为了更好地说明所有 Haar-Like 矩形特征对撞击坑的不同区别能力, 本文从 19884 个特征中选取两个特征进行分析对比, 两个被分析的矩形如图 2 中的第 9 和 10 幅图所示. 特征 A 从前 200 个和后 200 个特征中随机选取, 其特征序号为 38, Haar 特征类型为图 2 排列的第 6 种, 区域的左上角的坐标为(22, 11), 区域的右下角的坐标为(43, 32), 特征 B 从第 201 个特征到第 19684 个特征中随机选取, 其特征序号为 5455, Haar 特征类型为图 2 的第 5 种, 区域的左上角的坐标为(24, 44), 区域的右下角的坐标为(27, 47).

表 1 是特征 A 和特征 B 在所有样本相应的特征值的统计结果, 而图 4 和图 5 则是相应的特征分布图. 比较分析后可知, 撞击坑和非撞击坑样本的特征 A 的值的差比较大, 且在 0 点的位置有明显的区别, 分



图 2 六种用于撞击坑 Haar 特征提取的模型及选取的不同尺度和位置的特征

Figure 2 6 Haar feature templates and 2 selected feature images with different scales and positions.

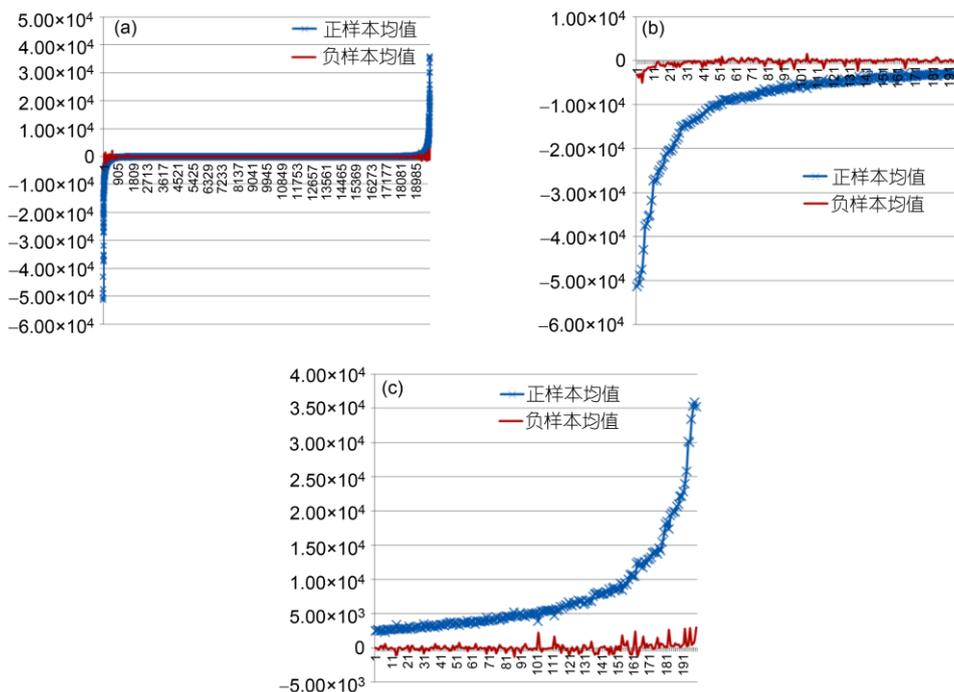


图 3 (网络版彩图)矩形特征对所有样本的平均特征值分布图

(a) 图 2 所有矩形特征, (b) 前 200 个矩形特征, (c) 后 200 个矩形特征

Figure 3 (Color online) The average rectangular feature distribution to all positive and negative samples. (a) To all features, (b) to the first 200 features, (c) to the last 200 features.

表 1 特征 A 和特征 B 对正、负样本特征值的统计分析

Table 1 The statistics of features of positive and negative samples of features A and B

特征实例 统计值	特征 A			特征 B		
	撞击坑	非撞击坑	差值	撞击坑	非撞击坑	差值
样本数量	1181	2901		1181	2901	
总和	-803041.00	-1935.00	-801106.00	-399.00	59.00	-458.00
平均值	-13384.02	-64.50	-13319.52	-6.65	1.97	-8.62
中间值	-11664.00	-198.50	-11465.50	-0.50	1.50	-2.00
最大值	1470.00	3538.00	-2068.00	143.00	51.00	92.00
最小值	-32375.00	-2965.00	-29410.00	-186.00	-90.00	-96.00
0 左边的特征百分比	98%	57%	42%	50%	40%	10%

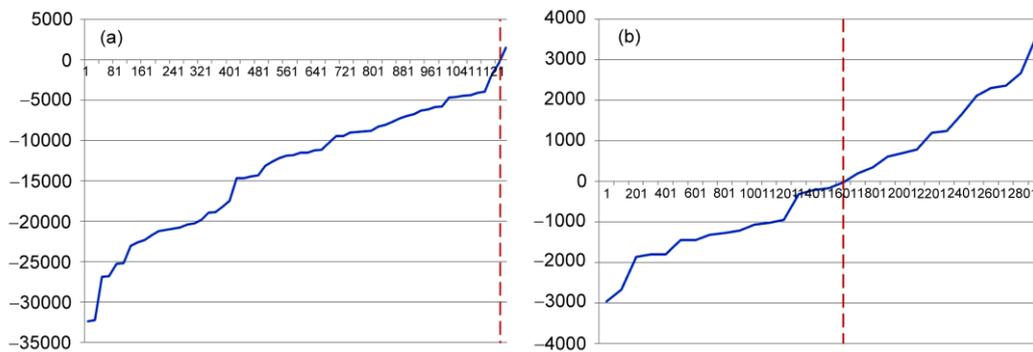


图 4 (网络版彩图)特征 A 在所有样本中的特征值分布图

(a) 撞击坑的特征, (b) 非撞击坑的特征

Figure 4 (Color online) The distribution graph of feature A. (a) About craters, (b) about non-craters.

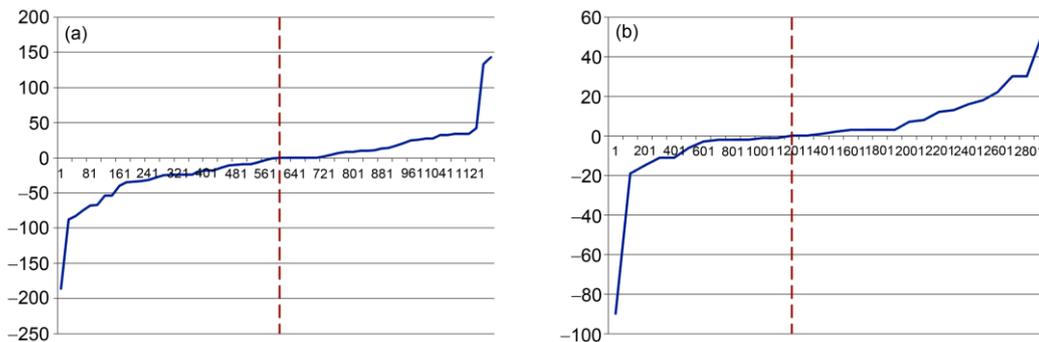


图 5 (网络版彩图)特征 B 在所有样本中的特征值分布图

(a) 撞击坑的特征, (b) 非撞击坑的特征

Figure 5 (Color online) The distribution graph of feature B. (a) About craters, (b) about non-craters.

别为 98%和 57%, 而特征 B 的值相差较小, 且在 0 点的位置十分接近, 分别为 50%和 40%. 相比之下, 特征 B 对撞击坑和非撞击坑几乎没有识别能力.

AdaBoost 方法^[5]能同时选择最好的特征和构成分类器. Adaboost 方法对大样本训练集中的多个特征或者分类器进行择选而组成一个有限子集, 使用投票等方法将多个弱分类器集成而产生一个复杂的强

分类器, 强分类器中的 T 个简单弱分类器或者特征构成

$$h(C; f, p, \theta) = \begin{cases} 1, & p \cdot f(C) \geq p \cdot \theta, \\ 0, & \text{others.} \end{cases} \quad (4)$$

其中, C 是一个代表某撞击坑候选区域的图像块, $f(C)$ 是 C 的一个纹理特征数值, 如 Haar 特征或者 HOG 特征. 弱纹理特征分类器 $h(C)$ 是由阈值 $f(C)$ 和方向值

$p=\{1, -1\}$ 来确定, 并且其值为1代表撞击坑和0代表非撞击坑. 每个弱分类器反映的纹理灰度值分布的 Haar 值或者灰度梯度向量分布 HOG 的值对单个尺度和位置的纹理属性并没有很高的判断力, 但选择出的各个不同的特征反映了撞击坑与非撞击坑在某一特定区域、方向的灰度和梯度的细小变化和不同, 这些特征的组合在整体上表现了撞击坑与非撞击坑类间的差异而具备很强的分类能力.

AdaBoost 算法选择每一个样本图像块中 N (如 19884)个特征集来描述撞击坑和非撞击坑, 同时分配一个权重参数 α_i 给选择的弱分类器, 在每次循环中所有的训练样本都需重新分配权重, 以便减少在当前这一轮已被正确识别的训练样本的权重, 使越难分类的样本的权重系数设置得越高, 再重新用分类器对新加权的样本学习, 通过共 T 次选择的弱分类器和它们的权重因子而构成强分类器. 如图 2 中的第 6 个图表示的特征 A 在排序中为第 1 个较优, 具备较强的分类能力, 而图 2 中的第 7 个图表示的特征 B 在排序中为第 12084 个较优, 表现为无分类能力. 图 6 是从撞击坑的六种模型的 19884 个 Haar 特征中经 AdaBoost 选取的较优选择的前 6 个不同尺度的 Haar 特征. AdaBoost 算法通过用每轮选取的权重因子对特征进行排序, 其权重因子的变化级别为选择特征数的最小限度提供了一个分析基础, 如果图 6 中的 6 个底图用正样本的平均图像来表示, 则 6 个黑白矩形表示的 Haar 特征是这个平均图像的较优的前几个最显著特性的表达, 通过权重因子、阈值和方向值的定义而使得所有正样本都能通过它们的检测, 这些选定的特征着重于检测灰度变化强烈部分的撞击坑的阴

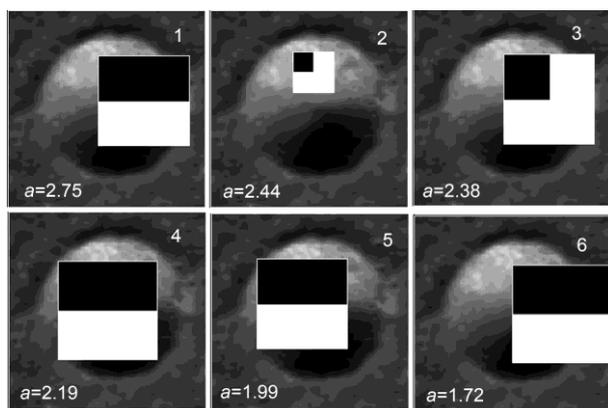


图 6 适应撞击坑识别的较优选择的前 6 个 Haar 特征
Figure 6 The 6 Selected Better Haar Features for Craters.

阳面及区域.

1.2.2 撞击坑区域的有向梯度方向直方图特征提取

撞击坑精选是在一组撞击坑候选区域上进行检测, 需采用分辨能力更强的 PHOG(Pyramid HOG, 塔式梯度方向直方图)特征. HOG 是同 SIFT 特征类似的一种局域描述符, 它对规定区域的边缘或梯度向不同的角度方向范围进行累计而形成直方图特征, 可以很好地表征局部区域内目标的梯度结构和变化, 进而表征一幅图像的局部形状以及形状的空间关系, 由于 PHOG 是将区域划分为许多不同层次的块而对 HOG 进行描述和计算, 并将其图像中的各层次的 HOG 特征进行级联, 反映了纹理变化在整体上的统计特性, 它们对光照辐射差异、环形结构分布和配准误差有较强的鲁棒性. 如在 48×48 的规定区域内定义塔式梯度方向直方图特征, 将其分为 4 层, 后一层子区域的尺寸是前一层区域的 $1/4$, 每层梯度的角度方向数为 $K=9$, 第 1 层是整个图像, 特征数为 9, 第 2 层将特定区域分为 2×2 的块, 共有特征数为 36, 第 3 层将特定区域分为 4×4 的块, 共有特征数 144, 第 4 层将特定区域分为 8×8 的块, 共有特征数 576, 整个区域图像共有 PHOG 特征为 765 维特征. 为了更确切地反映图像的边缘信息, 需先采用 Canny 边缘检测算子对撞击坑区域图像进行边缘滤波而后统计其梯度特征, 图 7 是一个月球撞击坑正样本在 4 个层的塔式梯度方向直方图特征分布, 每个层的特征参数按 1:2:3:4 的权重比例进行运算后串联为一整体特征值, 每个块中的各细胞的特征值和整体特征值都按 L1 范数规范化后将对图像几何和光学的形变保持较好的不变性, 且实验表明其识别效率将提高 15% 左右. 图 7 的上方是包含一定阴阳面撞击坑的 PHOG 特征, 图 7 的下方是基本不含强烈对比阴阳面撞击坑的 PHOG 特征, 下方区域的第 1 层的 HOG 特征在各个方向比较平稳. 如将各个区域(受不同光照方向、强度的区域)的撞击坑区域图像都处理成图 7 下方相似的模糊圆周图像, 将使 PHOG 的特征的应用更加具备鲁棒性.

有向梯度方向直方图表达的是在各个弧度方向区域梯度变化的累计, 要反映撞击坑的最大局部特性就是表现出圆形周边模糊的边界方向梯度分布, 表 2 显示了圆坑在整个样本矩形中的占比及预处理

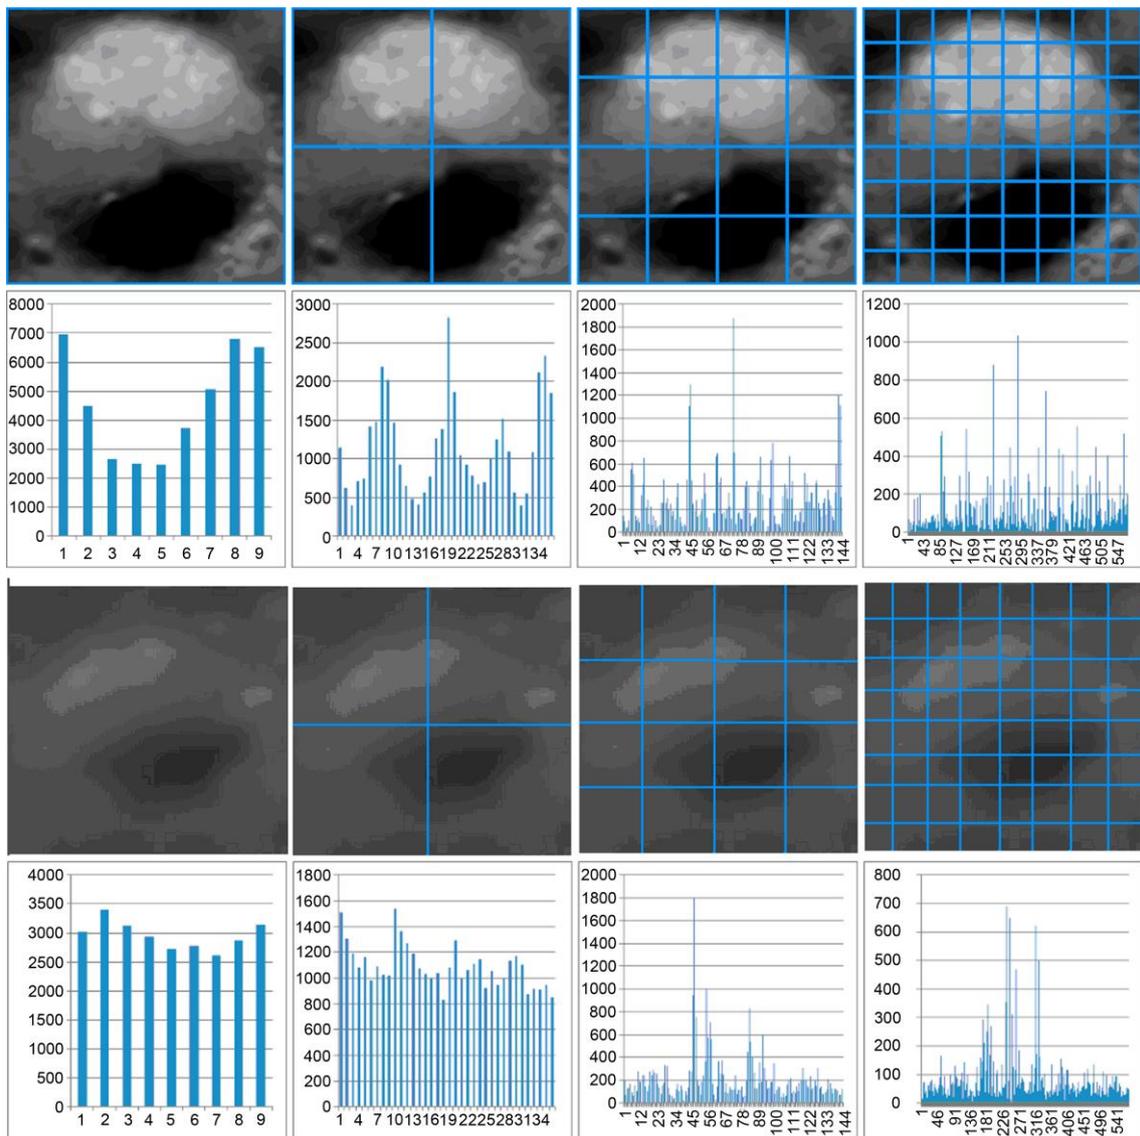


图 7 (网络版彩图)月球撞击坑的塔式梯度方向直方图特征分布

Figure 7 (Color online) The bar chart of pyramid HOG features of craters.

方法对第一层 HOG 特征的影响程度, 实验的两组正样本数各为 400 个, 一组选择撞击圆坑的直径约为矩形宽(48×48)的 3/4 左右, 即这些样本的圆坑基本占据整个矩形区域, 另一组选择撞击圆坑的直径约为矩形宽(48×48)的 1/2 左右, 即这些样本的圆坑占据整个区域的一半. 显然, 经过高亮及阴暗区域消除预处理后的约占据整个区域 3/4 的圆坑样本组, 更加表现出圆形周边模糊变化特性, 其样本组特征具备一定的稳定性, 且更适应撞击坑重叠的区域搜索, 这些经过预处理后的撞击坑区域的正照射面和背阳面与其他灰度区域平滑过渡, 其区域图像特征此时主要表现

在撞击坑圆形周边的梯度变化, 且第 1 层的 9 个 Bin 的值比较接近, 这样也避免了对于不同方向太阳光照射区域需要采用不同训练样本的繁琐, 使撞击坑分类的训练和识别算法具备更大的通用性.

HOG 特征与 SVM 分类方法的结合将发挥样本数少且分类精确的特点. 支持向量机的基本思想是寻找一个分类界面使正类样本和负类样本达到最优分类^[6], 能较好地解决小样本、非线性、高维数等分类问题, 本实验中采用 SVM 的二分类方式, 用塔式梯度方向直方图特征与支持向量机分类相结合可对候选的撞击坑区域进行校验和识别. 为了减少 SVM

表 2 圆坑占比及预处理方法对第一层 HOG 特征的影响

Table 2 The effect of different proportions of the crater's size to the whole image's on first layer of HOG

方向特征		Bin1	Bin2	Bin3	Bin4	Bin5	Bin6	Bin7	Bin8	Bin9
无预处理	坑直径 \geq 均值	4210.1	4660.3	2568.0	2429.4	2477.7	3905.5	5058.1	6774.5	6700.6
	3/4 矩形宽 方差	259.1	159.5	100.9	46.3	4.0	179.7	9.8	18.2	201.3
	坑直径 \leq 均值	3109.4	3530.2	3265.8	2901.6	2685.8	2821.4	2578.1	2775.7	3116.0
规范化、高亮及阴影消除预处理	1/2 矩形宽 方差	124.9	128.5	134.2	36.8	38.7	46.2	35.0	91.5	21.9
	坑直径 \geq 均值	3808.6	3347.0	3108.7	2735.0	2840.6	2494.0	3289.3	3637.7	4208.9
	3/4 矩形宽 方差	53.0	57.3	36.1	32.2	1.5	65.1	3.1	6.1	90.8
坑直径 \leq 均值	2901.0	3460.5	3197.4	2853.9	2447.4	2685.1	2553.9	2513.6	2851.3	
	1/2 矩形宽 方差	82.7	128.2	124.5	33.3	35.4	43.7	33.9	91.2	20.7

对 PHOG 特征的训练时间和识别时间, 通过 AdaBoost 对 PHOG 特征进行选择, 然后将选择的特征送入 SVM 训练学习, SVM 的核函数采用线性、多项式、径向基高斯、Sigmoid 核函数, 本实验中应用径向基核函数表现为较为稳定的识别效率.

2 撞击坑识别试验分析

2.1 数据和实验建立

为了试验集成方法对不同光照和地貌下的不同大小撞击坑的检测性能, 选定两个不同区域的月貌图像, 如图 8 选择的搜索窗口的尺寸范围为 24×24 到 48×48 . 原始的撞击坑正样本需要从不同经、纬度的月球图像中人工抠取, 负样本是随机地挑选的没有任何撞击坑的区域, 正负样本数都为 400 个, 每个正样本的撞击坑中的圆直径约占矩形长的 $3/4$, 不同尺寸的图像块通过双线性插值而成规定长、宽的样本集, 撞击坑样本库还可通过本系统正确识别的撞击坑区域进行扩充和修改. 搜索计算方法的快捷就需考虑遗传算法或依赖积分图计算的方法. 依靠穷举的多尺度的窗口搜索过程的完成需要易于计算的特征、分类方法及它们的配合^[7], 考虑到太小尺寸的撞击坑的标记没什么意义, 一幅图像中可辨别的大尺寸撞击坑是很少的且易于采用人工识别和标记, 故应用程序搜索的撞击坑等的区域搜索范围采用边宽在 12 到 200 像素之间, 搜索窗口尺寸的增长按前一窗口的 1.5 倍. 本文中的实验主机采用 CPU Duo 8700, 内存为 4 GB, 开发环境为编程平台 Delphi 7.

2.2 撞击坑识别方法的性能评价

实验中采用六种模型的 Haar 原始特征 19884 个和 PHOG 的原始特征为 765 维特征. 撞击坑正样本集

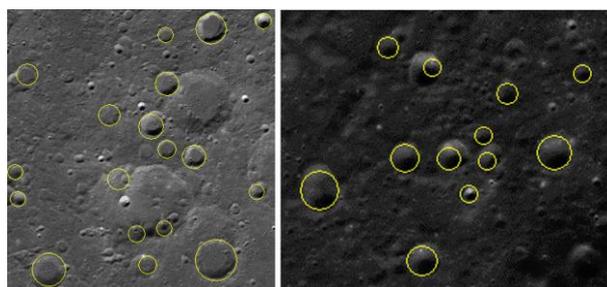


图 8 (网络版彩图)月球表面的撞击坑探测结果

Figure 8 (Color online) The Detection Results of Lunar Surface Images.

的每个图像块中的纹理特征由一系列的子集组成, 需要从这些子集中抽取反映它们共有特性的紧致集, 正样本库中撞击坑圆形区域在规定的矩形区域的占比是变化的且对采用 HOG 特征进行分类的影响如表 3 所示. 这种占比对基于 Haar 特征的分类器的影响不大, 对基于 PHOG 特征的分类器的影响较大, 分类过程中选取的特征数或向量机越多, 矩形区域的直径占比的变化对识别率影响越小. 训练用 Haar 和 PHOG 特征数的选择方法包括不经筛选和用 PCA 或者 AdaBoost 选择较优级区分度的特征, 分类方法采用单独的 AdaBoost 分类、单独的 SVM 分类、AdaBoost 特征选择+SVM 分类、AdaBoost 初分类+SVM 精分类四种分类方式进行分类. AdaBoost 弱分类器构成的 Haar 特征数为 100 个, 构成的 PHOG 特征数为 80 个. 用 AdaBoost 进行特征选择的 Haar 特征数为 150 个, 特征选择的 PHOG 特征数为 120 个.

用于测试的月球图片的大小为 621×559 个像素. 表 3 是选取 Haar 和 PHOG 特征在不同分类器下测试的测试精度、训练时间和识别时间对比表. 直接采用 AdaBoost(C)比直接采用 SVM(C)对 Haar 特征进行分类能得到较快的训练和识别时间, 但识别率要低些.

表 3 不同特征在不同分类器下实验的测试精度、训练时间和识别时间对比

Table 3 The accuracy, training time and elapsed time with different features and classifiers

特征	AdaBoost(C)	SVM(C)	AdaBoost(F)+SVM(C)	AdaBoost(RC)+SVM(FC)
Haar	80.2%/5 min/4.2 s	83.2%/3 min /8.8 s	91.2%/8 min /5.6 s	92.3%/12 min /8.1 s
PHOG	82.4%/4 min /8.8 s	87.5%/3 min /15.6 s	93.2%/9 min /6.3 s	94.6%/10 min /7.8 s

采用 AdaBoost(F)+SVM(C)方式是用 Adaboost 进行特征选择,然后将选择的特征送入 SVM 中进行训练和分类,这能达到比采用所有 Haar 或者所有 PHOG 特征进行训练得到的分类器具备更快的识别时间,特征选择上虽然花费了一定的时间,但排除了不相关特征对分类器训练的干扰. AdaBoost(RC)+SVM(FC)方式是用 AdaBoost 和 Haar 特征进行撞击坑初选候选区域,然后用 SVM 和 PHOG 特征对候选区域进行精确校验,这种方式既利用了 Haar 与 AdaBoost 快速定位区域的优点,又利用了 PHOG 精确特征描述和 SVM 合理分类的特性,其分类方法可在较快的时间里得到最佳的识别效率.

表 3 清楚显示了在采用单一分类方法的情况下,基于借助积分法快速求解的 Haar 特征,比基于 PHOG 特征的识别效率更高,而识别精确度则正好相反.进一步的研究则发现,AdaBoost(F)择选特征和 SVM(C)分类在利用 AdaBoost 对特征进行降维处理后使得 SVM 可以在较低的维度下实现较快的识别分类,而 AdaBoost(RC)初始和 SVM(FC)精选则使得集

成的识别分类算法同时具备 AdaBoost 高效和 SVM 分类的精确.

3 结论

本文提出了一种用于检测高分辨率的月球撞击坑的集成算法.该算法利用基于 Haar 特征的 AdaBoost 算法得到撞击坑的候选区域,并用基于 PHOG 特征的 SVM 对候选区域作进一步筛选而得到更加准确的撞击坑区域及其几何参数和统计数据.借助积分法快速求解的 Haar 特征大大提高了 AdaBoost 的效率,而更能反映撞击坑纹理分布并具有一定程度的旋转不变性的 PHOG 特征应用到 SVM 则能保存算法有较高的准确率.下一步的研究重点将放在提高系统对不同图像质量和多种形态的月球撞击坑的适用性上,以及如何提高机器学习算法的识别性能和鲁棒性^[8,9],并探索使用学习迁移法使新的样本子集适应和更新已建立的样本库和分类器.

致谢 感谢中国科学院天文台提供的嫦娥月球遥感影像数据作为本文的实验数据来源.

参考文献

- Andersson L E, Whitaker E A. NASA Catalogue of Lunar Nomenclature. Chicago: NASA Reference Publication, 1982
- Bandeira L, Saraiva J, Pina P. Impact crater recognition on mars based on a probability volume created by template matching. IEEE Trans Geosci Remote Sensing, 2007, 45(12): 4008-4015
- Urbach E R, Stepinska T F. Automatic detection of sub-kilometer craters in high resolution planetary images. Preprint Submitted to Planetary and Space Science, 2008, 57(7): 880-887
- Yang J, Zhao Z M, Yang J. A shadow removal method for high resolution remote sensing image (in Chinese). Geomatics Inf Sci Wuhan Univ, 2008, 33(1): 17-20 [杨俊, 赵志明, 杨健. 一种高分辨率遥感影像阴影去除方法. 武汉大学学报, 2008, 33(1): 17-20]
- Martins R, Pina P, Marques J S, et al. Crater detection by a boosting approach. IEEE Geosci Remote Sensing Lett, 2009, 6(1): 127-131
- Papageorgiou C P, Oren M, Poggio T. A General Framework for Object Detection // Sixth International Conference on Computer Vision. Bombay: Springer, 1998. 555-562
- Salamuniccar G, Loncaric S, Pina P, et al. MA130301GT catalogue of Martian impact craters and advanced evaluation of crater detection algorithms using diverse topography and image datasets. Planet Space Sci, 2011, 59(1): 111-131
- Yuan Y F, Zhu P M, Zhao N. Automatic identification of circular mare craters based on mathematical morphology (in Chinese). Sci Sin-Phys Mech Astrono, 2013, 43(3): 423-332 [袁悦锋, 朱培民, 赵娜. 基于数学形态学的月海圆形撞击坑自动识别方法. 中国科学:物理学 力学 天文学, 2013, 43(3): 423-332]
- Ding W, Stepinski T, Mu Y, et al. Sub-kilometer crater discovery with boosting and transfer learning. ACM Trans Intell Syst Technol, 2011, 2(4): 39-42

A Compositive detection method of lunar crater based on partial Haar and PHOG feature

JIANG XianGang^{*}, JIANG ZhaoFeng, SHENG MeiBo & QIU YunLi

School of Basic Science, East China Jiaotong University, Nanchang 330013, China

It should adopt a reasonable strategy of selecting features, which are comparatively easy to achieve and can be exactly used for lunar crater detection, and the machine learning methods, which are of high efficiency or of high accuracy, to promote the efficiency of lunar crater detection. We present an integrated method based on the local gray level, the gradient distribution and the machine learning for higher recognition efficiency in high resolution lunar terrain images. The combination of the Haar feature and the AdaBoost classification method provides faster and higher accuracy of crater candidate area detection, and the combination of the local Pyramid Histogram of Oriented Gradients feature and the Support Vector Machine gains an accurate geometric orientation and verification for the candidate craters. It adapts the AdaBoost algorithm as the both feature selection and classification method considering the miscellaneous Haar features. Whereas every item of the Pyramid Histogram of Oriented Gradients feature having influence on classification, it preprocess all crater region image into that each oriented gradient has almost same bin's modulus without shadow and highlight pairs. The paper has discussed the mechanism and integration of features selection, classification methods, parameters adjustment and recognition efficacy analysis.

crater detection, pyramid histogram of oriented gradients feature, Haar feature, machine learning

PACS: 96.20.-n, 96.20.Ka, 95.75.Mn, 95.75.Pq

doi: 10.1360/132013-293