

文章编号: 2095-2163(2021)11-0043-07

中图分类号: TP391

文献标志码: A

图像分类方法对比评价研究

周雨航¹, 车明亮¹, 王晓文², 钞振华¹, 张 驰¹, 于扬鸿¹

(1 南通大学 地理科学学院, 江苏 南通 226000; 2 南通市规划设计院有限公司, 江苏 南通 226004)

摘要: 现有的图像分类方法种类繁多,但一直缺少关于图像分类方法评价的相关研究,为此选用不同数据集对具有代表性的图像分类方法进行评价分析。待评价的图像分类方法包括主动学习(HOG-SVM、SqueezeNet 和 SimpleNet)和惰性学习(KNN 和 OTSU-KNN)两类。结果显示:(1)主动学习相比惰性学习分类精度更高,且在纹理特征较为复杂的图像分类中泛化能力更好。在时间效率方面,主动学习的运行时间要明显短于惰性学习,且前者对数据规模的依赖度远低于后者。(2)对两种分类方法而言,图像的纹理特征复杂度、清晰度以及图像数量都会对分类精度产生影响。此外,参数化方案对分类精度也具有显著影响。

关键词: 主动学习; 惰性学习; 对比评价; 最近邻域; 卷积神经网络

Comparative evaluation of image classification methods

ZHOU Yuhang¹, CHE Mingliang¹, WANG Xiaowen², CHAO Zhenhua¹, ZHANG Chi¹, YU Yanghong¹

(1 School of Geographic Science, Nantong University, Nantong Jiangsu, 226000, China;

2 Nantong Urban Planning and Design Institute Co., Ltd., Nantong Jiangsu, 226004, China)

[Abstract] There are many kinds of existing image classification methods, but there has been a lack of research on the evaluation of image classification methods. Therefore, different data sets are selected to evaluate and analyze the representative image classification methods. Image classification methods to be evaluated include the active learning (HOG-SVM, SqueezeNet and SimpleNet) and the inert learning (KNN and OTSU-KNN). The results show that: (1) The active learning has higher classification accuracy than the inert learning, and has better generalization ability in image classification with complex texture features. In terms of time efficiency, the running time of the active learning is significantly shorter than that of the inert learning, and the dependence of the former on data size is far lower than that of the latter. (2) For the two classification methods, the complexity, definition and number of texture features of images will affect the classification accuracy. In addition, the parameterization scheme also has a significant impact on the classification accuracy.

[Key words] active learning; lazy learning; comparative evaluation; nearest neighborhood; convolutional neural network

0 引言

图像分类是计算机视觉中的基本任务,构成了其它计算机视觉任务的基础,如定位、检测和分割^[1]。现如今,图像分类已渗入到各领域,如无人驾驶场景目标识别、遥感影像分类、医学疾病诊断、气象灾害预报等等。在每天产生的大量图像中,通过对其分类,可以更轻松、快捷地访问图像信息,从而做出高效、准确判断。尽管图像分类被视为人类的第二天性,但对于自动化系统而言,却面临巨大挑战^[2]。其中遇到的最复杂问题包括:视点相关的对象可变性和具有许多对象类型的类内高度可变性^[3]。为应对该挑战,近年来,新的图像分类方法

和技术不断涌现。因此,有必要对这些分类方法进行审查评估,这将有助于为特定研究选择适当的分类方法。

根据训练样本性质,图像分类方法可被分为非监督分类和监督分类两种^[4]。其中非监督分类也称聚类分析或点群分类。应用该方法有助于识别数据中的聚类,且速度快,但无法确定类别属性。监督分类又称训练分类,其不仅能对图像类别进行区分,而且能判定类别属性,但耗时严重。此外,该方法的分类精度取决于典型样本的丰度。如果选择的训练样本数量少或不具代表性,则分类结果容易出现人为错误。在监督分类方法中,根据样本学习特点,又将其分为惰性学习(Lazy Learning)和主动学习(Active

基金项目: 泰州市建设工程项目(JSJWZBDL2020-62);南通市科技局项目(JC2020174);南通大学大学生创新训练计划项目(2021219)。

作者简介: 周雨航(1999-),男,本科生,主要研究方向:图像分类;车明亮(1987-),男,博士,讲师,主要研究方向:机器视觉定位;王晓文(1988-),女,硕士,中级工程师,主要研究方向:图像处理与三维建模;钞振华(1977-),男,博士,副教授,主要研究方向:遥感影像分类;张 驰(1982-),男,博士,副教授,主要研究方向:建筑信息建模;于扬鸿(1999-),男,本科生,主要研究方向:图像分割。

通讯作者: 车明亮 Email: dawnche@163.com

收稿日期: 2021-08-10

Learning) 两类。前者又称记忆性学习,其通过记忆训练,集中所有的样本,来分析与待分类数据之间的关系。其中,K最近邻域法(K-Nearest Neighbor, KNN)及其改进方法是该类方法中的代表性算法。主动学习算法是通过训练样本,利用特征提取器预先训练好分类器,然后利用分类器对待分类数据进行分类。目前,图像分类器种类繁多,主要包括特征描述符和图像卷积。特征描述符用于从图像中提取手工特征,主要包括方向梯度直方图(Histogram of Oriented Gradient, HOG)^[5]、尺度不变特征变换(Scale Invariant Feature Transform, SIFT)^[6]、加速稳健特征(Speeded Up Robust Feature, SURF)^[7]和Brief特征(Binary Robust Independent Elementary Features)^[8]等。图像卷积是基于卷积神经网络(Convolutional Neural Networks, CNN)中的卷积层来提取图像高维抽象特征。在主动学习分类方法中,具有代表性的分类器包括专家系统、支撑向量机(Support Vector Machines, SVM)、神经网络、决策树分类器、关联规则挖掘、贝叶斯分类和后向传播等。

在上述分类方法中,有些技术较为成熟已被广泛应用到解决实际分类问题中^[9-10],而有些方法因为较为新颖则正处于实践测试中。因此,有必要从应用层面对这些新颖分类方法进行评价,以评估其与常规方法性能表现的差异,尤其是对于监督学习分类方法。为此,本研究通过在监督分类方法中选择有代表性的惰性学习方法和主动学习方法,利用两种数据集分别对所选分类方法的分类精度和运行时间进行评价分析,以期能对分类方法进行客观评估,弥补目前分类方法评价研究的不足,为合理选择图像分类方法提供理论依据,对推动图像分类技术的应用起到促进作用。

1 数据与方法

1.1 数据集

本研究使用的数据集均为语义丰富的场景数据。其中包括交通灯数据集和花数据集。交通灯数据集来源于行车记录仪收集的彩色街景图像。该街景图像的分辨率为 800×600 像素,含有1 000多个交通灯,包含简单和复杂两类场景。在简单场景中,交通灯仅暴露在天空中,而在复杂场景中,交通灯的背景复杂多变,可能包括树木、建筑物、汽车尾灯和广告牌等等。通过对该街景图像的交通灯兴趣区进行裁剪,得到交通灯数据集,并按交通灯颜色分为红灯、绿灯和黄灯图像,每类图像均包括直行、左转弯

和右转弯,如图1(a)所示。花集数据来源于“创作共用(Creative Commons)”组织开放的花集图像数据。该数据集为高分辨率($>800 \times 600$)彩色图像,包含了大约3 000幅实景图像,可分为蒲公英、雏菊、太阳花、玫瑰和郁金香等5类,如图1(b)所示。该数据集中的各目标物尺寸占比不低于30%,因此未对其进行裁剪。




图 1 数据集示例

Fig. 1 Examples of data sets

在使用上述数据集评估图像分类方法之前,需先对各数据集进行必要的图像预处理。为保持各类别图像数量一致,对数量少的各类图像进行适当的图像增强,包括图像模糊、图像锐化、图像均衡化、图像缩放、图像拉伸、图像旋转等。预处理后的交通灯数据集图片数每类保持在2 000幅左右,花数据集图片数每类保持在300幅左右。与此同时,由于本研究的分类算法均为监督分类算法,因此将上述数据集按8:2划分为训练集和测试集。前者用于在线或离线训练分类模型,后者用于测试分类模型的性能。

1.2 分类方法

本研究选择了KNN算法及其改进算法OTSU-KNN作为惰性学习分类方法;选择HOG-SVM模型、SqueezeNet模型和SimpleNet模型作为主动学习分类方法。

1.2.1 KNN算法

KNN算法是一种最基本的分类回归算法^[11],其通过选择一种距离计算方式,根据数据特征来计算新数据与已知类别数据集中数据点的距离,按照距离递增次序进行排序,并选取与当前距离最小的 K 个点用于分类或回归^[12]。对于分类, K 个点出现频率最多的类别将作为分类预测值,对于回归, K 个点的加权值将作为回归预测值。KNN属于非参数学习方法,其是基于记忆训练实例,并在有监督的学习环境中使用。

KNN 算法的基本要素: 距离度量、 K 值选择和类别判定规则。通常, 距离度量按欧式距离计算, 距离越近意味着两个点属于同一类别的可能性越大。 K 值用于确定待分类数据点周围所要计算距离的训练样本个数。 K 值太小, 分类结果易受噪声点影响, K 值太大, 近邻域中可能包含太多的其它类别点。因此, 可通过对距离进行加权降低 K 值设定的影响。根据经验, K 值的选择一般低于训练样本数的平方根。为此, 本文将 K 值设为 5。在 KNN 中, 用于类别判定的准则不唯一, 但通常使用简单投票法和加权投票法^[13]。两种方法各有优缺点, 本文中使用了加权投票法。

1.2.2 OTSU-KNN 方法

OTSU 算法又称大津法, 是一种图像灰度自适应阈值分割算法。其基本思想是基于图像的灰度特征来计算一个灰度阈值, 并将图像中每个像素的灰度值与阈值相比较, 将图像分割成背景和前景两部分^[14]。背景和前景的分界值就是要计算的阈值。通过遍历不同的阈值, 可以计算不同阈值下对应的背景和前景之间的类间方差。当类间方差取得极大值时, 此时对应的阈值就是大津法所求的阈值, 因此该方法又称为最大类间方差法。对于给定单一目标图像, 大津法可以快速地计算最佳的全局前景/背景分割阈值。

利用 OTSU 算法对图像进行阈值分割处理后, 再使用 KNN 算法对图像类别进行判定。在 KNN 分类过程中, 距离的计算方法设定为欧氏距离, 类别判定准则设定为加权投票法。

1.2.3 HOG-SVM 模型

HOG 为方向梯度直方图特征描述符, 是计算机视觉和图像处理中用来进行物体检测和特征匹配的重要描述符^[15]。其通过计算和外推图像局部区域的梯度方向直方图来构成特征。首先, 将图像分成小的连通区域, 称之为细胞单元, 分别计算各细胞单元的梯度方向直方图, 然后采集细胞单元中各像素点的梯度或边缘的方向直方图, 将其合成为较大的块区域。块区域特征不仅便于归一化, 而且考虑了光影变化。最后将块区域特征组合为特征描述符。

本研究利用 HOG 离线提取图像特征后, 需要对特征进行类别判定, 即采用支撑向量机 (Support Vector Machines, SVM) 进行分类。SVM 是一种有监督学习的广义线性分类算法, 其决策边界是对学习样本求解的最大边距超平面。SVM 在处理线性不可分数据时, 会使用核函数作特征空间映射。在本

研究中, 核函数设定为 *poly*。通过计算图像 HOG 特征, 辅以图像标签对 SVM 进行训练, 最后构成 HOG-SVM 分类器^[16]。

1.2.4 SqueezeNet 模型

SqueezeNet 模型属于轻量级的深度卷积神经网络, 使 CNN 在有限的参数预算上能保持同等的准确性, 同时提高运行效率^[17]。在 SqueezeNet 架构中, fire 模块为构建模块, 由压缩卷积层和扩展层组成。SqueezeNet 模型从单独的卷积层 (conv1) 开始, 然后是 8 个 fire 模块 (fire 2~9), 最后以卷积层 (conv10) 结束。从头到尾, 每个 fire 模块的滤波器数量逐渐增加。另外, SqueezeNet 模型在 conv1、fire4、fire8 和 conv10 层之后, 执行步长为 2 的最大池化操作。在本研究中, 根据 SqueezeNet 架构, 利用 PyTorch 对其进行了模型复现。根据研究需要, 输入图像的尺寸被调整为 64×64 像素, 每层通道保留其原始值, 学习率设置为 0.000 1。在训练 SqueezeNet 模型之前, 对所有输入图像进行了均衡化处理。

1.2.5 SimpleNet 模型

SimpleNet 模型为简洁的卷积神经网络分类器^[18]。该模型采用 6 层网络结构, 前 4 层分别由 3×3 卷积层和 2×2 池化层构成, 用于提取图像特征, 最后两层为全连接分类层, 使用 *softmax* 函数输出分类概率。在优化器方面, 该模型采用自适应学习率优化算法作为优化函数, 学习率设置为 0.001。在计算分类向量和期望向量差异时, 该模型采用交叉熵作为损失函数。在训练 SimpleNet 模型之前, 所有输入图像都进行了均衡化处理。

1.3 评价方法

为了评价各分类方法的性能, 通用的评价标准: 准确率、精确率、召回率和 F_1 值等方法被使用。其表达式如下:

$$Acc = (TP + TN) / N_{all} \quad (1)$$

$$Pre = TP / (TP + FP) \quad (2)$$

$$Rec = TP / (TP + FN) \quad (3)$$

$$F_1 = 2 \times (Pre \times Rec) / (Pre + Rec) \quad (4)$$

式中: Acc 为准确率; TP 为真正样本数, 即分类方法将正样本分类为正样本数; TN 为真负样本数, 即分类方法将负样本分类为负样本数; N_{all} 为所有样本数; Pre 为精确率; FP 为假正样本数, 即分类方法将负样本分类为正样本数; Rec 为召回率; FN 为假负样本数, 即分类器将正样本分类为负样本数; F_1 值是对精确率和召回率的调和平均值。

2 结果分析

2.1 分类精度

根据交通灯和花集数据,各分类方法分类精度对比如图2所示。从图中可以看出,无论是从准确率、精确率、召回率方面,还是 F_1 得分来看,主动学习分类方法相比惰性学习分类方法,在交通灯数据集和花数据集分类中,都表现出较好的分类性能。使用主动学习分类方法对交通灯数据集进行分类的 F_1 得分可以达到98%以上,甚至接近100%;对花数据集分类的 F_1 得分也达到85%甚至90%以上。相比之下,惰性学习分类方法在交通灯数据集和花数据集上的分类性能差别较大。具体表现为对交通灯数据集进行分类的 F_1 得分可以达到94%~97%,但对花数据集进行分类的 F_1 得分仅在42%左右。两类方法的结果差异和方法结构有紧密关系。虽然两类方法同属有监督分类,但其模型结构有显著区别。主动学习分类方法是通过预先训练一系列的参数,以提取图像特征从而进行分类,而惰性学习分类方法则直接通过对比图像模板,以计算欧式距离来分类。前者提取的图像特征相对抽象,而后者提取的图像特征则较为具体。在对测试数据集进行分类时,显然具有抽象特征的主动学习方法适应性更强,对应的分类精度更高。




图2 各分类方法分类精度对比

Fig. 2 Accuracy comparison of each classification method

在主动学习方法中,各分类模型分类性能也存在一定差异。在对交通灯数据集进行分类中,HOG-SVM模型具有更高的精确率($Pre = 99.7%$),而SqueezeNet模型则具有更高的召回率($Rec = 99.6%$)。从 F_1 得分和准确率方面可以看出,SqueezeNet模型具有更好的分类表现。在对花数据集进行分类中,SimpleNet模型具有更高的精确率(90.8%)和召回率($Rec = 90.2%$)。这种结果差异也和模型提取的图像特征有关。HOG-SVM提取的图像特征为方向梯度直方图,尽管能捕捉一定的图像纹理,但会丢失一些语义信息。而SqueezeNet模型和SimpleNet模型均为卷积神经网络模型,不仅能

提取多通道图像特征,而且通过不断的卷积-池化运算,能获得更高维的抽象特征,从而减少信息损失,这在纹理特征复杂的图像上尤其明显。因此,HOG-SVM方法在花数据集分类方面不如SqueezeNet模型和SimpleNet模型表现好。

在惰性学习分类方法中,两种算法对交通灯数据集都具有较高的分类指标,但KNN算法表现更好。在对花数据集进行分类中,两种方法的分类指标都不高,这意味着这两种方法在该数据集上的分类性能表现都不好。尽管如此,OTSU-KNN方法的分类性能要优于KNN算法,这表明使用OTSU算法分割目标物有利于提高图像分类精度。

如图3所示,从各分类算法对每种类别分类结果的累积 F_1 得分可以看出,无论是主动学习分类方法,还是惰性学习分类方法,其在交通灯各类数据集上的分类性能都表现较好。显而易见,各分类方法在绿灯上的 F_1 得分都在97%以上甚至接近100%,而在黄灯和红灯上的 F_1 得分相对较低,但也普遍高于90%。在各类花数据集上,5种分类方法的分类性能具有较大差别。从图3(b)中可以看出,累积 F_1 得分显著较高的分类算法分别为HOG-SVM方法、SimpleNet模型和SqueezeNet模型。其中SimpleNet模型具有最高的累积 F_1 得分($\sum F_1 = 4.51$),其次为SqueezeNet模型($\sum F_1 = 4.49$)和HOG-SVM方法($\sum F_1 = 4.2$)。相比之下,OTSU-KNN方法和KNN算法的累积 F_1 得分均较低,前者为2.1,后者为2.0。从花数据集各类别分类结果总体对比来看,5种分类算法对太阳花的分类都具有较好的分类表现($\sum F_1 = 4.1$),其次为玫瑰($\sum F_1 = 3.6$)和雏菊($\sum F_1 = 3.5$),最后为郁金香($\sum F_1 = 2.9$)。在主动学习分类方法中,各类别的分类结果相对均衡,但在惰性学习分类方法中,各类别的分类结果差异显著。




图3 各分类方法累积 F_1 值对比

Fig. 3 Comparison of cumulative F_1 values of each classification method

上述分类方法在不同数据集上的结果, 显示出各方法的分类性能在稳定性方面存在显著差异。从交通灯数据集到花数据集, SqueezeNet 模型的总体分类精度 F_1 得分降低了 9.9%, 而 HOG-SVM 方法的 F_1 得分降低了 14.8%。相比之下, KNN 算法的 F_1 得分降低了 57.7%。这表明主动学习分类方法的稳定性相对较强, 而惰性学习分类方法则变化剧烈。

2.2 运行时间

各分类算法运行时间对比如图 4 所示。从中可以看出, 主动学习分类方法相比惰性学习分类方法在交通灯数据集和花数据集分类中的运行时间都较少, 且基本保持稳定。总体来看, 3 种主动学习分类方法对交通灯数据集的分类时间(平均为 6 ms)要短于花数据集(平均为 7ms), 这和模型参数的训练有关。在主动学习分类方法中, 模型参数已通过训练集数据离线训练完成, 在对测试集图片进行分类时, 只需加载训练好的参数, 按模型前向传播即可完成分类任务。因此主动学习分类方法的总体运行时间和训练集图片数量及测试集图片数量无关。单张图片的分类时间仅取决于模型加载参数、模型加载图像数据和模型结构复杂程度等内容。所以, 无论是交通灯数据集还是花数据集, 3 种主动学习分类方法的运行时间变化不大。但由于花数据集的图像分辨率远大于交通灯数据集, 且其图像纹理特征也比交通灯数据集复杂, 因此在花数据集上的分类时间相对延长。图 4 还显示了两种深度学习模型(SqueezeNet 和 SimpleNet)处理单张图片的分类时间相差无几, 但 HOG-SVM 方法处理单张图片的分类时间略微延长, 这可能和模型的特征提取有关。深度学习模型采用卷积和池化按网络深度提取图像特征, 而 HOG-SVM 方法采用方向梯度直方图提取特征。当图像分辨率增加以及图像特征变得复杂, 后者提取的特征数量会显著增加。因此特征数量的显著差异可能会导致运行时间的不同。




图 4 各分类方法运行时间对比

Fig. 4 Comparison of running time of each classification method

在惰性学习分类方法中, 两种分类方法在交通灯数据集的分类时间比较长(平均为 155 ms), 在花数据集上的分类时间相对较短(平均为 48 ms), 这和主动学习分类方法刚好相反。在惰性学习分类方法中, 算法的总体运行时间不仅与测试集图片数有关, 还和训练集图片数有关。无论是 KNN 算法还是 OTSU-KNN 方法, 在对测试集中的每张图片进行分类时, 都需要暴力枚举训练集中的所有图片, 以计算未分类图片和训练集中图片的特征距离。在本研究中, 交通灯数据集的数量明显多于花数据集, 因此这两种惰性学习分类方法在交通灯数据集上的分类时间更长。从图 4 中还可以看出, 这两种分类方法在交通灯数据集上的运行时间相差不大, 但在花数据集上差异显著, 这和图像特征复杂度以及使用 OTSU 算法分割目标物有关。交通灯数据集图像特征比较简单, 因此使用 OTSU 算法的运行时间可以忽略, 但花数据集的图像特征要显著复杂, OTSU 算法需要花费一定的时间才能计算灰度阈值。总体而言, OTSU-KNN 方法的运行时间要长于 KNN 算法。


3 讨论

3.1 图像质量及数量的影响

在图像质量方面, 图像目标物的纹理特征复杂度和图像清晰度是主要影响因素。图 5 显示了不同数据集上的图像方向梯度直方图特征。可以看出, 交通灯数据集的纹理特征相比花数据集要简单和易于识别。这使得分类方法在交通灯数据集上具有较高的分类精度(如图 2(a)); 而在花数据集上的分类精度有所下降且降低幅度不一(如图 2(b))。另一方面, 图像清晰度对分类结果也具有一定影响。无论是交通灯数据集中还是花数据集中, 在异类数据之间都存在一定的相似性, 尤其是颜色和形状相似的异类图像, 而在图像清晰度下降时, 这种相似性将大幅提高。如图 6 所示, 清晰图中的蒲公英和太阳花之间的余弦相似度为 0.898, 而在模糊图中两者之间的余弦相似度高达 0.972。当图像清晰度下降时, 图像之间的高相似度给分类算法的分类精度带来消极影响。统计显示, 清晰图像的分类精度要显著高于模糊图像的分类精度。在本研究中, 花数据集中存在一定的模糊图像和有噪声图像, 这些不清晰图像最终降低了分类算法的分类精度。

在图像数量方面, 训练样本的数量对分类算法的分类精度也有显著影响。对于主动学习分类方法, 通常样本数量越多, 模型越能提取出更充分的关

键特征,越能对数据集进行更好地分类。在本研究中,交通灯数据集数量较为充足,而花数据集数量相对较少。因此,对于交通灯数据集,经训练后的分类模型具有更强的泛化能力,能更好地进行分类。相比之下,主动学习分类方法在花数据集上的训练相对不足,泛化能力弱,在分类花数据集时其精度降低。为此在后续研究中,应进一步增加花数据集数量,以提高主动学习分类方法的泛化能力。另外,图像数量对惰性学习分类方法的影响较为复杂,训练样本过多、过少都会降低其分类精度。具体量化研究和原因探讨将在后续研究中展开。



(a) 红灯 (b) 为雏菊

图 5 两种数据集 HOG 特征对比

Fig. 5 HOG feature comparison between two datasets



(a) 蒲公英 (b) 太阳花

图 6 图像之间的相似度

Fig. 6 Similarity between images

3.2 算法参数化方案的影响

无论是主动学习分类方法还是惰性学习分类方法,其参数化方案也会对分类精度产生一定影响。在主动学习分类方法中,除去用于提取特征及分类的权重及偏置参数外,还存在一些额外的敏感性参数,这些参数的本地化,也显著影响分类结果。对于惰性学习分类方法,其情况类似。表 1 显示了 HOG-SVM 方法的特征提取参数化方案。可以看出,采用不同的元胞大小、块大小、块步幅和直方条数,最后的分类精度将产生显著变化。从中可以看

出,当元胞大小为 6×6 像素时,所构建的局部 HOG 特征最为合理;当块尺寸和块跨度分别为 12×12 像素和 6×6 像素时,所提取的块 HOG 特征能更好地描述光照变化和阴影效果;当直方条数取 9 时,分类算法的分类精度最高。可见,选择不同的参数化方案,将产生差异显著的分类结果。因此,在使用复杂模型进行图像分类之前,进行必要的参数化研究非常重要。

表 1 HOG 参数化方案

Tab. 1 HOG Parameterization Scheme

Cell	F_1	Block	F_1	Bins	F_1	Stride	F_1
2×2	0.611	6×6	0.504	3	0.556	6×6	0.843
4×4	0.675	12×12	0.843	6	0.649	12×12	0.556
6×6	0.843	24×24	0.679	9	0.843	24×24	0.545
8×8	0.638	36×36	0.657	18	0.642		

注:Cell 为元胞大小,Block 为块大小,Bins 为直方条数,Stride 为块跨度

4 结束语

本研究通过使用两类数据集对主动学习分类方法和惰性学习分类方法的分类性能进行了对比评价。在分类精度和时间效率两方面,主动学习分类方法相比惰性学习分类方法表现更好。无论对于主动学习分类方法还是惰性学习分类方法,图像的纹理特征复杂度、图像的清晰度以及图像的数量都会对分类精度产生影响。此外,模型的参数化方案对分类精度也是具有显著的影响。

参考文献

- [1] LI F, KRISHNA R, XU D, et al. Cs231n: convolutional neural networks for visual recognition [J/OL]. Stanford, 2021, (3):1.
- [2] RAWAT, WASEEM, WANG Z H. Deep convolutional neural networks for image classification: A comprehensive review [J]. Neural computation, 2017,29(9): 2352-2449.
- [3] DAN C, CIRES A, UELI M, JONATHAN M, et al. Flexible, high performance convolutional neural networks for image classification[C]//Twenty-second international joint conference on artificial intelligence. 2011:1237-1242.
- [4] SIDDHARTHA S N, GIRISH M, JAJNYASENI K, et al. A survey of image classification methods and techniques[C]//2014 International conference on control, instrumentation, communication and computational technologies (ICCICCT). IEEE, 2014: 554-557.
- [5] 朱信熙, 张尤赛. 基于 HOG 特征的实景交通标志检测[J]. 计算机与数字工程, 2020,48(5):1217-1221.
- [6] 李旋, 韩天园, 吕凯光, 等. 基于改进 SIFT 算法的交通标志图像匹配[J]. 中国安全生产科学技术, 2021,17(1):182-188.
- [7] 徐瑞端, 雷添杰, 程结海, 等. 一种改进 SURF 算法的无人机影像快速配准方法[J]. 水利水电技术(中英文), 2021,52(4):22-31.

(下转第 53 页)