

DOI:10.19651/j.cnki.emt.2209744

基于共性与特性信息融合的遥感场景图像分类^{*}

高翔 王李祺 魏志晴 白艳萍
(中北大学理学院 太原 030051)

摘要:由于遥感场景图像类内差距大即同一类别图像的特性信息相差较大,仅仅依靠特性信息分类的准确率不高,而现有遥感场景图像分类方法忽视了同一类别所具有的相同的共性信息也可以辅助图像识别,对此本文提出一种基于共性与特性信息融合的遥感场景图像分类方法。首先,图像通过卷积网络较浅层与深层得到的简单特征图与复杂特征图相叠加,可认为是此图像注意力集中的特征图,提取此特征图的手工特征LBP作为共性信息。之后与卷积网络提取的特性信息融合并进行分类。本文使用经贝叶斯优化优化超参数的SVM分类器,使其性能达到最佳来消除分类器对实验的影响。在两个数据集UC Merced和AID上的实验,验证其分类精度分别达到了98.80%和96.06%,表明该方法能有效地提升遥感场景图像准确率。在国防,城市规划,地质勘查等领域有重要意义。

关键词:图像分类; SVM; 特征融合; 特征工程

中图分类号: TP751 文献标识码: A 国家标准学科分类代码: 110.87

Remote sensing scene image classification based on the fusion of common and characteristic information

Gao Xiang Wang Liqi Wei Zhiqing Bai Yanping
(School of Science, North University of China, Taiyuan 030051, China)

Abstract: Due to the large intra-class gap of remote sensing scene images, that is, the feature information of the same category of images is quite different, the accuracy of classification based only on feature information is not high, and the existing remote sensing scene image classification methods ignore the same common information of the same category. It can assist in image recognition. This paper proposes a remote sensing scene image classification method based on the fusion of common and characteristic information. First, the simple feature map and the complex feature map obtained by the shallower and deeper layers of the convolutional network are superimposed on the image, which can be considered as the feature map with concentrated attention of the image, and the handcrafted feature LBP of this feature map is extracted as the common information. It is then fused with the feature information extracted by the convolutional network and classified. In this paper, the SVM classifier whose hyperparameters are optimized by Bayesian optimization is used to achieve the best performance to eliminate the influence of the classifier on the experiment. Experiments on the two datasets UC Merced and AID verify that the classification accuracy reaches 98.80% and 96.06%, respectively, indicating that the method can effectively improve the accuracy of remote sensing scene images. It is of great significance in the fields of national defense, urban planning, and geological exploration.

Keywords: image classification; SVM; feature fusion; feature representation

0 引言

当下依托于空间技术和计算机技术的进步遥感技术也取得了巨大发展,不仅在诸如地质勘查,城市规划,灾害预防等传统的行业有更大的比重,也拓宽了诸如零售,医疗,

无人驾驶等新领域。而近年来越来越多的有关军事设施的高分遥感图像在网络上的传播也使得遥感技术的军事意义深入人心,对遥感的关注也日益加大。

随着遥感技术的发展与其应用领域的拓宽,遥感场景图像的数据量也呈指数级增长。遥感技术的一大重点便是

收稿日期:2022-04-25

*基金项目:国家自然科学基金(61774137,51875535 and 61927807)、山西省重点研发计划项目(201903D121156)、山西省回国留学人员科研项目(2020-104,2021-108)资助

遥感场景图像识别,其下游任务如城市规划,自动驾驶等都要建立在识别的基础上。在这种背景下对遥感数据的有效处理也显现其价值,因为哪怕是微小的识别误差在海量的数据前也会造成巨大的影响。如何有效地提升遥感场景图像的准确率就成为一个很有价值的研究。

图像分类的准确率直接由所提取的图像特征决定。图像特征是一幅图像区别于另一幅图像的基本信息,其提取方法可分为手工特征和卷积特征,各特征提取方法所提取的特征信息虽各有不同,但均着眼于最能反映图像的特性,以此来提高分类准确率。韩彬彬等^[1]提出了基于稠密金字塔网络的遥感影像建筑物提取方法,石梵等^[2]提出了一种基于稀疏词典的遥感影像震后建筑物检测方法,高原等^[3]通过传统卷积神经网络中大量的空间特征信息问题的研究,提出一种基于 Octave 卷积(octave convolution, OctConv)的深度卷积神经网络(DCNN)模型将遥感场景分类的识别率推到了新的高峰。而近年来的注意力机制为图像的特征提取提供了新的思路:通过对图像区域或卷积通道的权重分配,聚焦于图像分类最密切的特征来提升分类精度,如唐建宇等^[4]提出了基于旋转框和注意力机制的遥感图像目标检测算法等。

根据上述研究发现,现有遥感场景图像分类方法着重于图像的特性信息,但由于遥感场景图像类内差距大的特点,对同类图片仅仅依靠提取的特性信息难以实现精确分类。对此本文提出了一种基于共性+特性的遥感场景图像分类方法,能有效地提升分类准确率。

1 基本原理

如图 1 所示,图 1(a)棒球场可以很好地利用特性学习分类,但图 1(b)和(c)特性信息集中于沙滩边的石头和农田边的房屋,不易区分类别。本文提出的基于共性+特性的遥感场景图像分类方法,能有效地提升分类准确率。

1.1 局部二值模式

纹理是像素值矩阵高级的语义理解和总结。局部二值



图 2 LBP 特征提取相关示例

式。通过这种改进,二进制模式的种类大大减少,而不会丢失太多信息,对于 3×3 邻域内 8 个采样点来说,模式数量由原来的 2^8 种减少为 $(p \times (p-1) + 2) + 1$ 种。

等价模式计算公式如式(2)所示,引入变量 $U, U \leq 2$ 的模式为等价模式,LBP 值的计算如式(1),其余为非等价模式,LBP 值为 0。

$$U(LBP) = |s(g_{p-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{p-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (2)$$

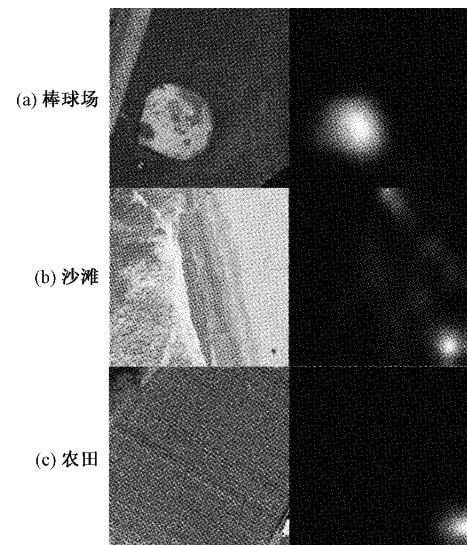


图 1 不同类别注意力集中区域

模式(local binary pattern, LBP)是 OJALA 于 1994 年提出的特征提取方法,该方法就是通过图片中的每一个像素点与其邻域像素比较来提取图片的纹理信息。

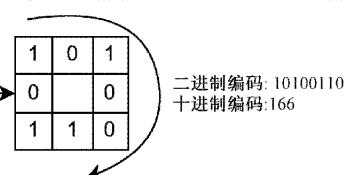
计算各点的 LBP 值,其编码方法为:

$$LBP(x_c, y_c) = \sum_{p=0}^{P-1} 2^p s(g_p - g_c) \quad (1)$$

其中, (x_c, y_c) 是待计算的中心像素, P 为相邻像素的个数, p 为邻域 P 个像素点的第 p 个, g_c 是中心像素的灰度值, g_p 是相邻像素的灰度值,而 $s(\cdot)$ 指符号函数,
 $s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & \text{其他} \end{cases}$, LBP 特征编码如图 2 所示。

由于原始的 LBP 提取模式种类有 2^P 种,这使得特征维数过高,本文采用改进的 LBP 方法来提取特征:

等价模式:OJALA 认为图像中,某个局部二进制模式所对应的循环二进制数从 $0 \rightarrow 1$ 或从 $1 \rightarrow 0$,最多有两种跳变,该局部二进制模式所对应的二进制就成为一个等价模



当选取 2 为采样半径,与其相邻的采样点 P 则为 8,而模式数量降为 $(8 \times (8-1) + 2) + 1$ 共计 59 种。统计 59 种模式数量即为此图像的 LBP 特征图。将同一幅图片划为不同的区域使用 LBP 等价模式提取特征,每一区域特征维数均为 59,图片总特征维数为各区域特征维数相加为 59 的倍数。

1.2 贝叶斯优化

当下随着网络越来越复杂,超参数也越来越多,当超参数相关的目标函数及其导数未知,无法利用梯度下降法

等方法求解,此外若由于计算目标函数时间成本大,像蚁群算法、遗传算法等元启发式算法亦会失效,因此,解决这种问题需要设计一种高效的算法以期在有限的时间里面找到一个相对不错的解,贝叶斯优化算法便是其中之一。

算法的思路是首先生成一个初始候选解集合,然后根据这些点寻找下一个有可能是极值的点,将该点加入集合中,重复这一步骤,直至迭代终止。最后从这些点中找出极值点作为问题的解,这些点即为我们要寻找的超参数的值,公式如下:

$$x^* = \operatorname{argmin}_{x \in X} f(x) \quad (3)$$

其中, x 为超参数的一组值, X 为取值范围, $f(x)$ 为超参数优化函数, x^* 为寻找的最佳超参数。

迭代过程如图 3 所示,横坐标 X 为取值范围,纵坐标为将取值范围内某个 x 代入优化函数的适应度值 $f(x)$,黑色虚线为真实的波动,红点为选取的采集点。在第 t 次循环中已知 4 个采集点,根据这 4 个点拟合曲线,得到区域的 95% 置信区间与虚线预测的曲线波动。根据代理函数构建相应的采集函数,用来确定下一采集点的位置,如垂直虚线所示。循环以往直至达到预设条件停止迭代,预测的虚线贴合于实际的蓝色实现,从而得到函数的极值。

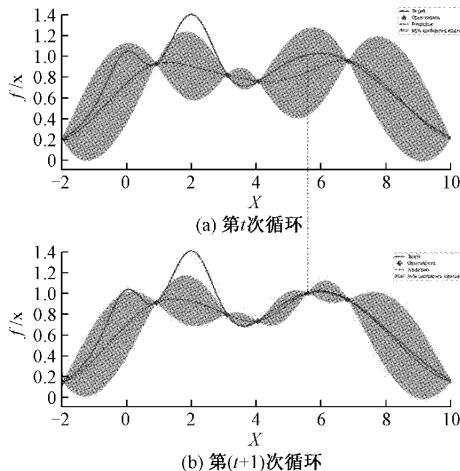


图 3 贝叶斯优化示例图

本文通过贝叶斯优化优化支持向量机,实际上是通过此方法寻找到合适的超参数:正则化系数与核参数,超参数寻优步骤如下:

输入: 初始化点个数 n_0 , 最大迭代次数 N , 代理函数 $g(x)$, 采集函数 $\alpha(x | D)$

- 1) 随机初始化 n_0 点 $X_{init} = \{x_0, x_1, \dots, x_{n_0-1}\}$
- 2) 获得对应函数值 $f(X_{init})$, 初始点集 $D_0 = \{X_{init}, f(X_{init})\}$ 令 $t = t_0, D_{t-1} = D_0$
- 3) 根据当前获得的点集 D_{t-1} , 构建代理函数 $g(x)$ 。
- 4) 基于当前代理函数 $g(x)$ 。最大化采集函数 $\alpha(x | D_{t-1})$, 获得下一个评估点: $x_t = \operatorname{argmax}_{x \in X} \alpha(x | D_{t-1})$

5) 获得评估点 x_t 的函数值 $f(x_t)$ 将其加入到当前评估点集合中: $D_t = D_{t-1} \cup \{x_t, f(x_t)\}$, 转步骤 3)

end

输出: 最优候选评估点 $\{x^*, y^*\}$

1.3 特性与共性

特性与共性的概念来源于多模态融合 (multimodal fusion)。一般来说,模态是指事物发生或存在的方式,而多模态融合通过融合不同模态对同一事物的不同表现方式达到比单一模态更优的效果。虽然不同模态的特征能够互补(所以比单个特征更优秀)如刘爽等^[5]提出的稠密融合卷积神经网络的多模态地基云状分类方法,但无法避免地会出现相同的特征在不同模态间的交叉(所以存在信息冗余),总体来讲就是多模态融合存在冗余性和互补性。

而随着广大科研工作者的不懈努力,通过考虑模态特异性和模态不变特征来解决模态的非定性和冗余性逐步取代以往的融合方式(如学习不同模态的动态权重等)。Lu 等^[6]提出了一种新的跨模态共享特征转移算法(cm-SSFT),通过对同一图像的不同模态(RGB 图与红外 IR 图)经 Two-stream 结构提取不同模态的共性与特性特征以解决信息冗余问题;而 Qin 等^[7]则是设计两个网络 P-net (projection network) 和 C-net (common feature learning network) 来提取特性信息与共性信息。

而在单一图像来源的分类中,往往采用提取图像特征,通过比较各个特征的相似程度来确定图像所属的类别。但在遥感场景图像识别中由于其类内差距大的特点,所提取的特征往往难以实现准确分类。考虑到同类图像拥有相似的语义信息,在特性信息难以区分类别时,则可以通过共性信息辅助辨别。基于此本文提出在单一图像来源使用共性与特性信息融合的方法来增强遥感图像分类识别的精度。

2 提取与分析

2.1 注意力集中特征图

遥感模式识别中,单幅图像往往包含着大量信息,但在实际识别应用中只需要关注于某些信息。注意力机制则是从大量信息中有筛选出少量重要信息,并聚焦到这些重要信息上,忽略大多不重要的信息提高抗噪能力,增强分类精度。

神经网络中较浅层中的通道学习颜色和边缘等简单特征,而较深层中的通道学习较复杂特征。而一层中由不同的通道对应不同的特征,通过观察卷积层中的哪些区域在图像上激活,并将其与原始图像中的相应区域进行比较,以研究注意力集中的特征区域。

为了更好地显示图像注意力集中区域,使用下式对激活区域归一化处理缩放所有激活值

$$X_c = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \times (\text{max-min}) + \min \quad (4)$$

其中, X_c 为归一化后的数据, X 为原始数据, X_{\max} , X_{\min} 分别为原始数据集的最大值和最小值, $[min, max]$ 为归一化后数据范围, 这里取 $[0, 1]$ 以使最小激活值为 0, 最大激活值为 1。

如图 4 所示, 色像素表示强的正激活区域, 黑色像素表示强的负激活区域。主要为灰色的通道未对输入图像进行强烈激活。将图 4(b) 与 (c) 相叠加后, 即为注意力集中区域图 4(d)。由于强的正激活区域为白色像素, 即注意力集中的特有区域已被删除, 由此图提取的为共性信息。

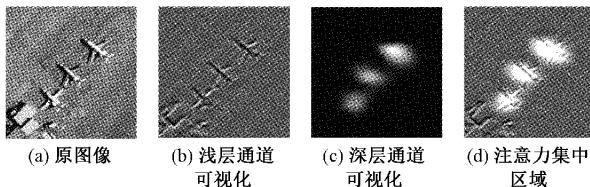


图 4 原图及其特征图图例

2.2 卷积网络选取

GoogLeNet 是谷歌推出的基于 Inception 模块的深度神经网络模型, 在 2014 年的 ImageNet 竞赛中夺得了冠军。如表 1 所示为不同的卷积网络在 UC Merced 数据集上的测试准确率比较, 其中 Inception-Resnet-v2 与 Densenet201 均可达到 99% 以上但由于网络深度过深导致运行时间太久不利于实际的应用, 故本文采用的卷积网络为时间与精度均适合的 GoogLeNet 网络。

2.3 特征提取与分析

经卷积网络所提取的特征是最能反映图像的特性信息, 但由于遥感场景类内差距大, 同一类别图像的特性信

表 1 不同的网络在 UC Merced 数据集上的比较

网络	深度	参数量 (单位: 百万)	运行时间/s	分类精度/%
Alexnet	8	61.0	642.21	94.83
Vgg-16	16	138	2 397.59	97.11
SqueezeNet	18	1.24	728.71	94.09
Resnet18	18	11.7	681.32	96.26
GoogLeNet	22	7.0	1 364.35	97.62
InceptionV3	48	23.9	4 015.31	96.65
Inception-Resnet-V2	164	55.9	12 895.73	99.52
Densenet201	201	20.0	12 643.63	99.49

息往往差距也较大, 所以仅仅依赖于特性信息难以对图像精确分类。而注意力集中特征图上强的正激活区域像素值为 0, 利用 LBP 方法提取的纹理特征可视为同类图片的共性信息。特性信息与共性信息相融合可以提高遥感场景图像的识别精度。如表 2 所示, 在不同的训练比例下, 融合特性与共性的识别精度均高于单一特征。相关算法流程如图 5 所示。

表 2 不同的训练比例在 UC Merced 数据集上的比较

训练比例	GoogLeNet	LBP	本文方法	%
50	94.76	44.25	95.51	
60	95.60	45.49	96.79	
70	96.67	46.97	97.63	
80	97.32	48.57	98.80	

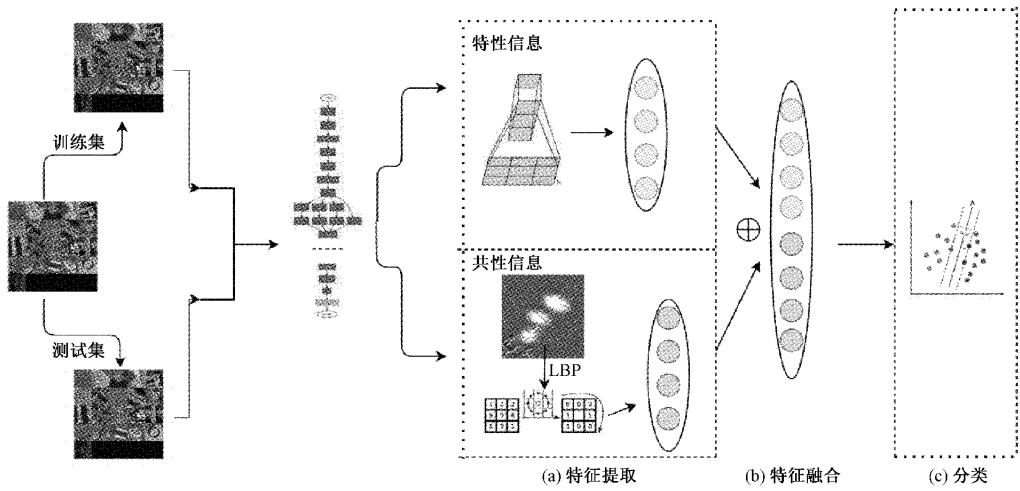


图 5 算法流程

3 实验结果及分析

3.1 实验数据集

为验证本文结构模型的有效性, 选用 2 个公开的大规

模遥感图像数据集 UC Merced^[8] 和 AID^[9] 如图 6, 对其进行测试并与其它算法对比。

遥感场景数据集 UC Merced 由 UC Merced 计算机视觉实验室于 2010 年发布, 此数据集包含 21 个场景类别, 每

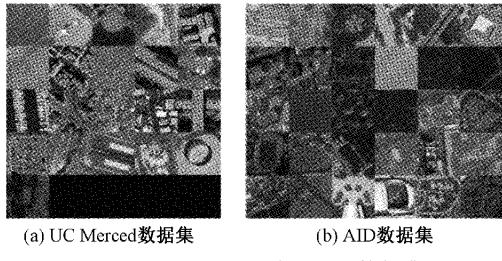


图 6 UC Merced 与 AID 数据集

类有 100 张图片, 图片大小为 256 像素 \times 256 像素, 图像空间分辨率为 1 英尺(0.3 m)。UC Merced 数据集中图像的角度、方向、光照等各不相同, 增加了分类的难度。

AID 数据集是由华中科技大学和武汉大学联合创建的大规模遥感图像数据集, 该数据集共有 10 000 张图像, 共有 30 个场景类别, 不同场景类型的图像数量从 220~420 不等, 每张图像尺寸为 600 像素 \times 600 像素, 图像空间分辨率为 2~3 英尺(0.5~8.0 m), 图像由不同国家、地区、时间、季节以及成像条件各不相同, 增加了分类的难度。

3.2 实验平台及评价指标

1) 实验平台

CPU: E5-1650 V2 GPU: NVIDIA GeForce GTX 1660S 内存 DDR3 32 G

卷积网络相关参数设置如下: 优化器: sgdm; 最大训练回合数: 10; 初始学习率: 3×10^{-4} ; 学习率策略: 学习率不变; Batchsize: 10。

2) 评价指标

在遥感场景图像分类研究中有两个常用的评价指标即总体精度 OA (overall accuracy) 与混淆矩阵 CM (confusion matrix)。总体精度可体现出准确识别图像的数量占总体图像的比重, 是评价本文所提方法是否有效的重要指标, 而混淆矩阵 CM 可以清晰直观地反映真实类与预测类的关系, 便于对分类结果分析研究, 其中总体分类

精度计算方法如式(5)所示。

$$acc(f; D) = \frac{1}{N} \sum_{i=1}^M \prod_{j=1}^M (f(x_i) = y_j) \quad (5)$$

其中, $f(x_i)$ 是预测概率分布, y_i 是真实概率分布, D 是训练集, N 是样本的数量。

3.3 实验结果对比与分析

表 3 是本文方法与近几年具有代表性的十种方法所做的实验对比。为保证实验一致性 UC Merced 数据集上所有实验训练集测试集比例均为 8:2。由表 3 可知, 基于手工特征提取方法(如空间金字塔匹配等), 分类效果普遍差于利用深度网络提取特征的方法(如 ResNet-50 等), 因为手工特征提取方法提取的图像特征难以表达图像更深层次的语义信息。而本文方法在提取图像深层次的语义信息作为特性信息外, 还充分考虑到同类遥感场景图像有着相同的共性信息也可以辅助分类。所以利用融合的信息分类准确率比其它方法有很大的提升。

表 3 不同的方法在 UC Merced 数据集上的比较

模型方法	分类精度
BOVW ^[8]	76.81% \pm 0.41%
BOVW+SCK ^[8]	77.71% \pm 0.63%
空间金字塔匹配 ^[10]	77.70% \pm 0.90%
中层视觉词典学习 ^[11]	82.72% \pm 1.18%
MNCC ^[12]	88.26% \pm 1.81%
稀疏编码+中层特征 ^[13]	89.82% \pm 1.67%
MS_DCNN ^[14]	91.34% \pm 1.29%
CaffeNet ^[15]	93.42% \pm 0.52%
ResNet-50 ^[16]	95.43% \pm 0.85%
VGG-VD19 ^[17]	97.67% \pm 0.62%
本文方法	98.45% \pm 0.45%

UC Merced 数据集混淆矩阵如图 7, 从中可以发现建筑, 中等住宅, 路口这三类存在混淆, 即分类错误现象, 原

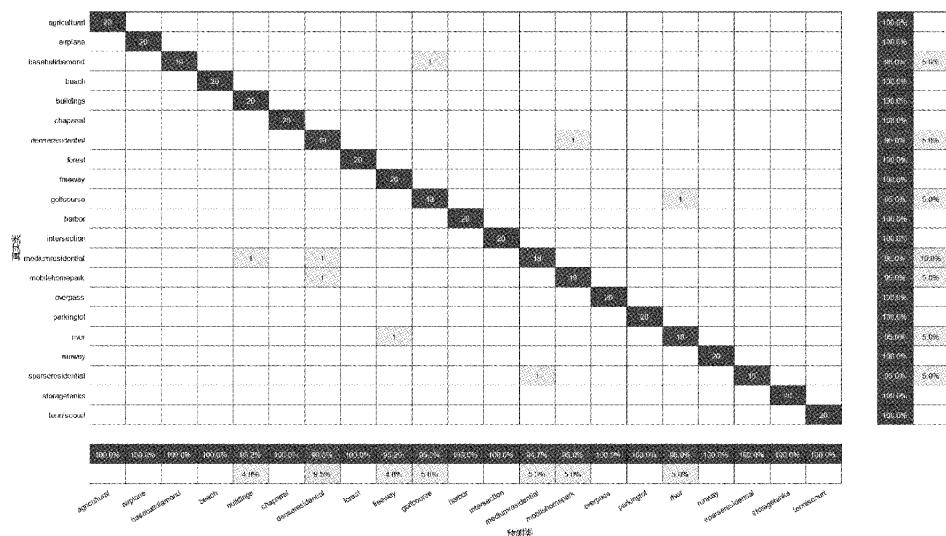


图 7 在 UC Merced 数据集分类的混淆矩阵

因是这三类图像均含有大量的矩形结构,类间差距小。其它的错误集中在密集住宅与房车停车场这两类,由于房车停车场为方便进出与管理,均设有固定停车位,大量房车停泊后所形成的空中几何直观与密集住宅极其相似造成分类错误如图 8 所示。

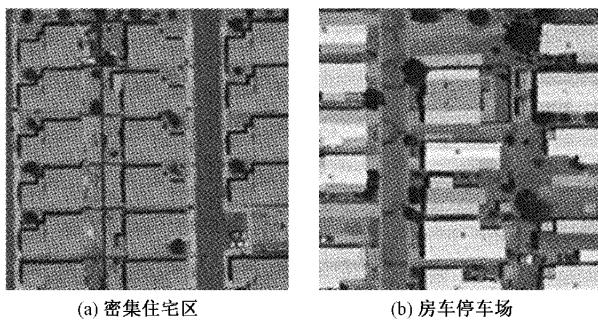


图 8 密集住宅区与移动房车停车场对比

为确保方法在遥感场景识别中的适用性,在 AID 数据集上进行实验。实验中训练集与测试集为 5:5,相关参数设置与 UC Merced 设置相同。GoogLeNet 网络中识别率

为 89.50%,而使用共性与特性融合的分类方法后识别率达到 90.18%。为验证该方法于卷积网络的广泛适用性采用不同的卷积网络进行实验。当选取 Resnet101 网络对 AID 数据集进行分类,其准确率为 95.68%,而使用本文提出的共性+特性信息方法准确率可达 96.06%,较现有方法相比均有所提升详如表 4,混淆矩阵如图 9,详细分析不再赘述。

表 4 不同的方法在 AID 数据集上的比较

模型方法	分类精度
VGG16 ^[9]	89.64%±0.30%
CaffeNet ^[9]	89.53%±0.31%
GoogLeNet ^[9]	86.39%±0.55%
Fusion-by-add ^[18]	91.87%±0.36%
MCNN ^[19]	91.80%±0.22%
ARCNet ^[20]	93.10%±0.55%
Finetune_ResNet50 ^[21]	89.22%±0.34%
ResNet_LGFFE ^[21]	94.46%±0.48%
本文方法	95.66%±0.32%

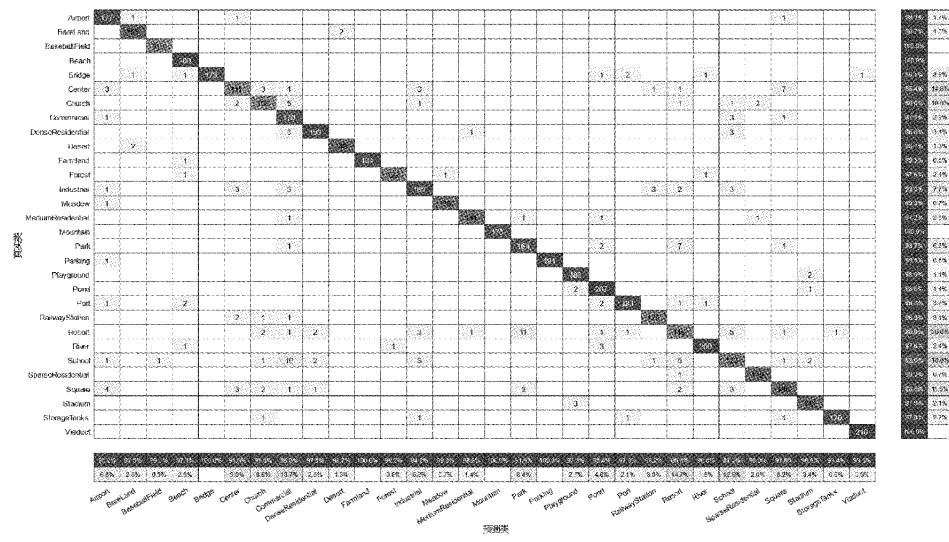


图 9 在 AID 数据集分类的混淆矩阵

4 结 论

对于遥感场景图像类内差距大,仅仅依靠特性信息分类的准确率不高,而现有遥感场景图像分类方法忽视了同一类别所具有的相同的共性信息也可以辅助图像识别,针对此本文提出一种基于共性与特性信息融合的遥感场景图像分类方法,实验结果表明所提出的融合共性信息与特性信息的方法可以有效地提升遥感场景分类的精度,且在其他数据集与卷积网络上的实验也证明了该方法的适用性。

这篇文章的相关代码,模型及数据链接为:
<https://github.com/Gao-Xiang-01/Remote-sensing-scene-classification>

image-classification

参 考 文 献

- [1] 韩彬彬,张月婷,潘宗序,等. 基于稠密金字塔网络的遥感影像建筑物提取[J]. 国外电子测量技术,2020,39(5):5-10.
- [2] 石梵,王超,申祎,等. 基于稀疏词典的高分遥感影像震后建筑物检测[J]. 仪器仪表学报,2020,41(7):205-213.
- [3] 高原,陈爱斌,周国雄,等. 基于 OctConv 的 DCNN 在遥感图像场景分类中的应用[J]. 电子测量与仪器学报,2020,34(1):61-67.
- [4] 唐建宇,唐春晖. 基于旋转框和注意力机制的遥感图

- 像目标检测算法[J]. 电子测量技术, 2021, 44(13): 114-120.
- [5] 刘爽, 许依琳, 张重. 稠密融合卷积神经网络的多模态地基云状分类[J]. 电子测量技术, 2021, 44(20): 157-161.
- [6] LU Y, WU Y, LIU B, et al. Cross-modality person re-identification with shared-specific feature transfer [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 13379-13389.
- [7] QIN Q, HU W, LIU B. Feature projection for improved text classification [C]. Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 2020: 8161-8171.
- [8] YANG Y, NEWSAM S. Bag-of-visual-words and spatial extensions for land-use classification [C]. Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems, 2010: 270-279.
- [9] XIA G S, HU J, HU F, et al. AID: A benchmark data set for performance evaluation of aerial scene classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7): 3965-3981.
- [10] LU F, HUANG J. Beyond bag of latent topics: Spatial pyramid matching for scene category recognition[J]. Frontiers of Information Technology & Electronic Engineering, 2015, 16(10): 817-828.
- [11] ZHANG F, DU B, ZHANG L. Saliency-guided unsupervised feature learning for scene classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 53(4): 2175-2184.
- [12] 刘扬, 付征叶, 郑逢斌. 基于神经认知计算模型的高分辨率遥感图像场景分类[J]. 系统工程与电子技术, 2015, 37(11): 2623-2633.
- [13] LI E, DU P, SAMAT A, et al. Mid-level feature representation via sparse autoencoder for remotely sensed scene classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 10(3): 1068-1081.
- [14] 许夙晖, 慕晓冬, 赵鹏, 等. 利用多尺度特征与深度网络对遥感影像进行场景分类[J]. 测绘学报, 2016, 45(7): 834-840.
- [15] PENATTI O A B, NOGUEIRA K, DOS SANTOS J A. Do deep features generalize from everyday objects to remote sensing and aerial scenes domains? [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2015: 44-51.
- [16] ZHOU Z, ZHENG Y, YE H, et al. Satellite image scene classification via convnet with context aggregation [C]. Pacific Rim Conference on Multimedia. Springer, Cham, 2018: 329-339.
- [17] LI E, XIA J, DU P, et al. Integrating multilayer features of convolutional neural networks for remote sensing scene classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(10): 5653-5665.
- [18] CHAIB S, LIU H, GU Y, et al. Deep feature fusion for VHR remote sensing scene classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(8): 4775-4784.
- [19] YUAN Y, FANG J, LU X, et al. Remote sensing image scene classification using rearranged local features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 57(3): 1779-1792.
- [20] WANG Q, LIU S, CHANUSSOT J, et al. Scene classification with recurrent attention of VHR remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 57(2): 1155-1167.
- [21] LV Y, ZHANG X, XIONG W, et al. An end-to-end local-global-fusion feature extraction network for remote sensing image scene classification[J]. Remote Sensing, 2019, 11(24): 3006.

作者简介

高翔,硕士,主要研究方向为机器学习、模式识别,多模态。

E-mail:gaoxiangnuc01@163.com

王李祺,硕士,主要研究方向为机器学习、数字图像处理与模式识别。

E-mail:1023252901@qq.com

魏志晴,硕士,主要研究方向为机器学习,图像处理。

E-mail:865257854@qq.com

白艳萍,教授,博士生导师,主要研究方向为现代优化理论与方法、神经网络算法及应用研究。

E-mail:baiyp666@163.com