

DOI: 10.11830/ISSN.1000-5013.201710006



# 采用 ACGAN 及多特征融合的高光谱遥感图像分类

刘群, 陈锻生

(华侨大学 计算机科学与技术学院, 福建 厦门 361021)

**摘要:** 为解决标记样本缺乏、提升分类精度及增强模型容错性等问题,提出一种基于辅助分类器生成对抗网络(ACGAN)的分类方法. 首先,将预训练的 ACGAN 模型作为光谱特征提取器,采用局部二值模式(LBP)算法提取图像的纹理特征;然后,融合光谱特征和纹理特征,由卷积神经网络(CNN)进行分类. 在 2 个广泛使用的数据集上进行实验,结果表明:相较于其他方法,文中方法可显著提高分类精度.

**关键词:** 高光谱图像分类; 生成对抗网络; 局部二值模式; 卷积神经网络

**中图分类号:** TP 391      **文献标志码:** A      **文章编号:** 1000-5013(2019)01-0113-08

## Classification of Hyperspectral Remote Sensing Images Using ACGAN and Fusion of Multifeature

LIU Qun, CHEN Duansheng

(College of Computer Science and Technology, Huaqiao University, Xiamen 361021, China)

**Abstract:** In order to solve the problem for lack of labeled samples, improve the classification accuracy and enhance the fault tolerance of the model, a hyperspectral sensing image classification method based on auxiliary classifier generative adversarial network (ACGAN) is proposed. Firstly, the pre-trained ACGAN model is treated as a spectral feature extractor, and the texture features of the image are extracted by local binary pattern (LBP) algorithm. Then, the spectral features and texture features are merged and classified by convolutional neural network (CNN). Experiments on two widely used datasets show that compared with other methods, the proposed method can significantly improve the classification accuracy.

**Keywords:** hyperspectral image classification; generative adversarial networks; local binary pattern; convolutional neural networks

由于高光谱遥感图像维数高、数据量大,为降低计算复杂度,解决高光谱图像分类中常见的 Hughes 现象,一系列基于降维的分类方法应运而生. 降维的方式包括波段选择<sup>[1-5]</sup>和特征提取<sup>[6-7]</sup>. Data 等<sup>[8]</sup>提出一种无监督波段提取方法,利用基于密度的空间聚类技术和核主成分分析(KPCA)转换原始数据,进行波段选择. 由于有监督分类通常需要大量的标记样本,而样本不足将导致分类精度受限等问题. 于是,可采用主动学习和手动标记. 手动标记成本高、难度大、存在混合像元. 因此,一般采用主动学习的方法. 孙宁等<sup>[9]</sup>提出一种结合主动学习和滤波器的分类方法,分类效果较好. 高光谱遥感图像的另一个特点是波段间冗余大,特征包含更多的不确定性. 对此,一般采取对数据进行预处理或特征融合的方式提升分类精度. 王巧玉等<sup>[10]</sup>提出一种结合波段选择和保边去噪滤波的分类方法,用堆栈降噪自

**收稿日期:** 2017-10-17

**通信作者:** 陈锻生(1959-),男,教授,博士,主要从事数字图像处理与模式识别的研究. E-mail: dschen@hqu.edu.cn.

**基金项目:** 国家自然科学基金面上资助项目(61370006);福建省科技计划重点资助项目(2015H0025)

编码器和 softmax 分类器构成的深度学习网络进行分类,该方法分类精度较高,但需要的训练样本数较多,应用性较差.针对以上问题,本文提出一种基于辅助分类器生成对抗网络(ACGAN)的高光谱遥感图像分类方法,利用生成对抗的思想,在模型训练过程中,使用少量标记样本,学习地物的光谱特征.

# 1 基于 ACGAN 的特征融合高光谱图像分类

## 1.1 基于 ACGAN 的高光谱图像分类

Goodfellow 等<sup>[11]</sup>在 2014 年提出生成对抗网络,模型包含生成器 G 和判别器 D.判别器的任务是判断给定的样本是否真实;而生成器的任务是接收一个随机噪声向量  $Z$  作为输入,输出与真实样本相似的伪样本.生成器试图欺骗判别器,而判别器尽量让自己不被欺骗.经过交替优化训练,2 个模型都能得到提升,最终达到纳什平衡.此时,生成器和判别器都学习到样本的分布.将生成对抗网络(GAN)应用到高光谱遥感分类中,可以有效弥补样本不足的问题.模型训练中并非单纯地拟合样本,而是学习样本的光谱特征.

He 等<sup>[12]</sup>提出一种基于 GAN 的半监督学习高光谱遥感图像分类,其在 3 个数据集上的分类结果显示该方法的有效性,但分类精度达不到实用要求. Lin 等<sup>[13]</sup>提出一种多层特征匹配生成对抗网络方法,获得优于稀疏编码的多特征融合方法和基于谱聚类改进的无监督特征学习算法的分类效果.在高光谱遥感图像分类问题中,地物类别一般有十多个.因此,判别器不仅要判断给定输入样本的真实性,还应判断输入样本的类别.故 ACGAN<sup>[14]</sup>更适合分析此类问题. ACGAN 在生成器的输入端为每个噪声数据指定一个类别标签  $C$ ,以引导生成类条件样本,类条件合成能够提升生成的样本质量,并扩展损失函数.判别器 D 的输入是真实样本  $X_{real}$  或生成器生成的伪样本  $X_{fake}$ ,输出是给定样本的真假性及该样本属于某个类别的概率. ACGAN 模型结构,如图 1 所示.

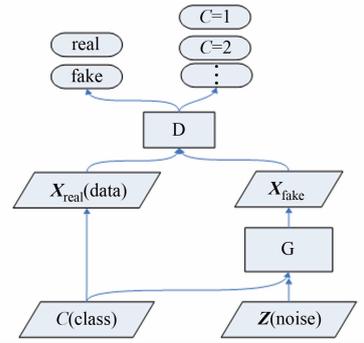


图 1 ACGAN 模型结构

Fig. 1 ACGAN model structure

生成器可表达为  $X_{fake} = G(c, z)$ . 判别器中,通过一个 softmax 分类器给出样本  $X$  属于  $K$  个相互独立的类别的概率.生成器和判别器的结构,如图 2 所示.

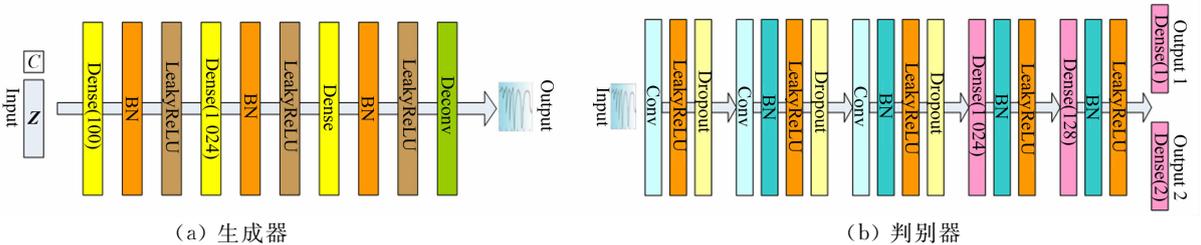


图 2 生成器和判别器网络结构图

Fig. 2 Structure of generator network and discriminator network

生成器输入的噪声向量  $Z$  为 40, 2 个全连接层分别包含 1 024 和 128 个单元.将大小为 128 的中间层数据送入 2 个激活函数分别为 sigmoid 和 softmax 的全连接层,得到样本的真假性输出和类别概率输出.除了第 1 个卷积层和最后 2 个全连接层,其他卷积层和全连接层均添加批规范化(Batch-Normalization)层和修正线性单元的特殊版本(LeakyReLU)层.一次迭代过程包括:1) 学习生成伪样本;2) 训练一次判别器;3) 训练整个 ACGAN 网络.目标函数包含正确图像源的对数似然  $L_s$  和正确类别的对数似然  $L_c$ ,即

$$L_s = E[\lg P(S = \text{real} | X_{real})] + E[\lg P(S = \text{fake} | X_{fake})],$$

$$L_c = E[\lg P(C = c | X_{real})] + E[\lg P(C = c | X_{fake})].$$

上式中:训练判别器 D 阶段最大化为  $(L_s + L_c)$ ,训练生成器 G 阶段最大化为  $(L_c - L_s)$ .在 ACGAN 中,使用的是 Adam 优化算法,可以降低收敛到局部最优的风险.

在用 ACGAN 模型对高光谱图像进行分类中,模型只用到图像的光谱信息.但原始光谱信息包含

噪声,不利于直接分类. 预训练的 ACGAN 模型中的生成器和判别器都学习了各类地物光谱的内在特征. 因此,将 ACGAN 模型中的判别器 D 作为光谱特征提取器,利用纹理特征提取局部二值模式(LBP)在空间上提取特征,将光谱特征和空间特征拼接后,利用卷积神经网络分类,提升分类精度.

### 1.2 旋转不变的局部二值模式

LBP 最早由 Pietikainen 等<sup>[15]</sup>提出,作为描述图像局部纹理特征. 原始的 LBP 定义在  $3 \text{ px} \times 3 \text{ px}$  的窗口内,以窗口的中心像素为阈值,与相邻 8 个像素相比较. 若相邻像素值不小于中心像素,则该位置被标记为 1;否则,被标记为 0. 将标记的二进制码转化成十进制数,得到 LBP 值. 由于拍摄时间、角度和地物本身的分布,高光谱图像内的地物特征具有旋转性. 因此,采用具有旋转不变性的 LBP,即将标记出的二进制码按位旋转,取最小值作为中心像素的 LBP 值. 局部二值模式示意图,如图 3 所示. 图 3 中: Pattern=00011111; LBP=1+2+4+8+16=31. 由于 LBP 是逐像素计算的,因此,在高光谱图像的每一个波段上都可以计算出一个与原图同样大小的纹理特征图. 选取信息熵最大的  $N$  个波段,计算出  $N$  个纹理特征图,即对每个像素的地物而言,拥有一个长度为  $N$  的纹理特征向量.

### 1.3 空谱特征融合的高光谱图像分类

将样本的原始光谱信息输入预训练的 ACGAN 模型的判别网络 D 中,取网络的中间层特征数据作为样本光谱特征. 具体实验时,选取判别器第 2 个全连接层的输出作为样本的光谱特征,大小为 128(节 1.1). 同时,计算高光谱图像数据集中每个波段的信息熵,信息熵越大,表明该波段包含的信息量越多. 选取信息熵最大的前 7 个波段. 在被选波段上计算纹理特征图,由此,每个像素点所在样本将获得长度为 7 的纹理特征向量. 将每个样本的光谱特征和纹理特征拼接融合(融合后特征向量长度为  $128+7=135$ )作为样本的光谱空间特征,接着用卷积神经网络进行训练和分类. 文中提出的基于 ACGAN 的空谱特征融合高光谱遥感图像分类框架 ACGAN-LBP-CNN,如图 4 所示.

CNN 分类器由 3 个卷积层(卷积核个数分别为 32,64 和 128,窗口大小为  $11 \times 1$ ),3 个全连接层(神经元数分别为 1 024,128 和  $K$ )组成. 除了第 1 个卷积层和最后 1 个全连接层,其他卷积层和全连接层均添加了 BatchNormalization 层和 LeakyReLU 层.

## 2 实验结果与分析

### 2.1 实验数据及评价标准

实验数据选取 Pavia University 和 Indian Pines 2 个高光谱数据集. Pavia University 数据集的图像大小为  $610 \text{ px} \times 610 \text{ px}$ ,包含 103 个光谱波段,去除图像中的一些无用像素. 实验使用的图像大小为  $610 \text{ px} \times 340 \text{ px} \times 103 \text{ px}$ ,包含 9 个地物类别,其单波段灰度图和地物实况分布,如图 5(a)所示. Pavia University 数据集的地物类别、每类的样本数目及实验中训练与测试样本的数目,如表 1 所示.

Indian Pines 数据集原始数据包含 224 个波段,图像大小为  $145 \text{ px} \times 145 \text{ px}$ . 去除 4 个严重受损的波段和 20 个水吸收波段后,剩余 200 个波段. 数据集可从网站(<http://www.ehu.es/ccwintco/index.php?title=Hyperspectral-Remote-Sensing-Scenes#Indian-Pines>)中获取. 数据集包含 16 类地物,其单波段灰度图和地物实况分布,如图 5(b)所示. Indian Pines 数据集的地物类别、每类的样本数目,以及实验中训练与测试样本的数目,如表 2 所示.

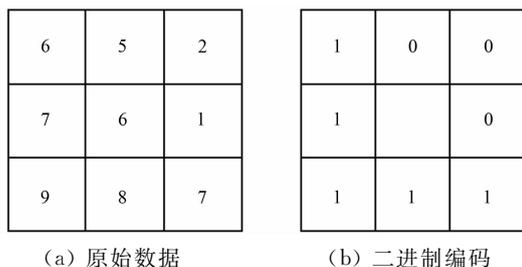


图 3 局部二值模式示意图

Fig. 3 Schematic diagram of local binary pattern

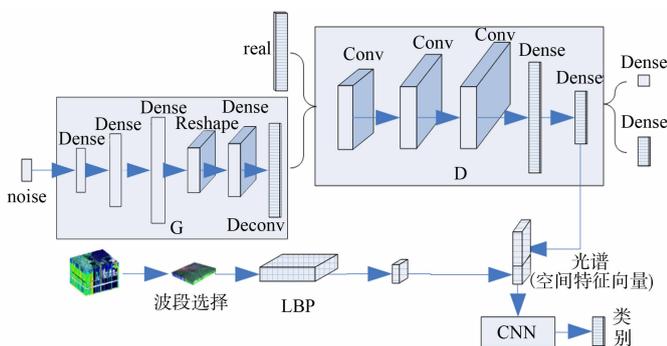


图 4 ACGAN-LBP-CNN 分类系统框架

Fig. 4 ACGAN-LBP-CNN classification system framework

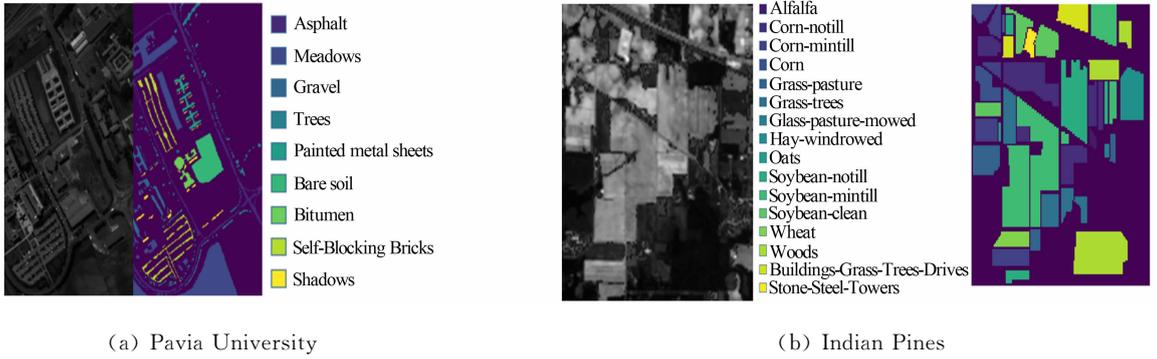


图5 单波段灰度图及地物实况分布

Fig. 5 Grayscale image and ground truth maps for single wavelength

由表2可知:Indian Pines 数据集中,1,4,7,9,13,15 和 16 类地物的样本数比较少,在同一训练样本率下,这几类地物的分类精度不稳定且明显低于其他类别,对整体分类精度影响较大。

对训练样本数与总体分类精度间的关系研究发现<sup>[16]</sup>:基于特征基元分类训练样本选取的数量为6~8倍波段数目时,分类精度可以达到较高的水平,并进入一个平稳阶段;而基于像元分类训练样本选取数量在24~30倍时,分类精度才能达到较高的水平.在文献[11]中,只保留样本数较多的8个类别且每个类别选取200个样本作为训练集.一般认为,样本数目为波段数2~4倍时,分类效果较好<sup>[17]</sup>.文献[18-19]随机选择一半的样本作为训练样本。

表1 Pavia University 数据集训练和测试样本数

Tab. 1 Number of train and test samples about Pavia University data

编号	类别名	总样本数	训练样本数	测试样本数
1	Asphalt	6 631	663	5 968
2	Meadows	18 649	1 864	16 785
3	Gravel	2 099	209	1 890
4	Trees	3 064	306	2 758
5	Painted metal sheets	1 345	134	1 211
6	Bare soil	5 029	502	4 527
7	Bitumen	1 330	133	1 197
8	Self-Blocking Bricks	3 682	368	3 314
9	Shadows	947	94	853
合计		42 776	4 273	38 503

表2 Indian Pines 数据集训练和测试样本数

Tab. 2 Number of train and test samples about Indian Pines data

编号	类别名	总样本数	训练样本数	测试样本数	编号	类别名	总样本数	训练样本数	测试样本数
1	Alfalfa	46	4	42	10	Soybean-notill	972	97	875
2	Corn-notill	1 428	142	1 286	11	Soybean-mintill	2 455	245	2 210
3	Corn-mintill	830	83	747	12	Soybean-clean	593	59	534
4	Corn	237	23	214	13	Wheat	205	20	185
5	Grass-pasture	483	48	435	14	Woods	1 265	126	1 139
6	Grass-trees	730	73	657	15	Buildings-Grass-Trees-Drives	386	38	348
7	Grass-pasture-mowed	28	2	26	16	Stone-Steel-Towers	93	9	84
8	Hay-windrowed	478	47	431	合计		10 249	1 018	9 231
9	Oats	20	2	18					

分类完成后,得到整幅图像每个像元的类别预测结果.一般采用混淆矩阵、总体分类精度(OA)、各类精度(CA)、平均分类精度(AA)及 Kappa 系数等评价标准衡量模型的性能.将高光谱图像分类结果与地物真实标记图进行对比,可得到混淆矩阵.各类精度和总体分类精度均可通过混淆矩阵求出.平均分类精度表示所有类别分类精度的平均值,即各个类别的 CA 值的总和除以类别个数. Kappa 系数是评价一致性和信度的一种重要指标. Monseru 等<sup>[20]</sup>认为当 Kappa 系数大于 0.75 时,分类器的分类性能良好;而当 Kappa 系数小于 0.40 时,性能较差。

## 2.2 实验结果分析

块大小和训练样本率对模型分类精度的影响,如图6所示.图6中:Indian Pines 数据集设置的样本率为 0.10,块大小为 70;Pavia University 数据集设置的样本率为 0.10,块大小为 200。

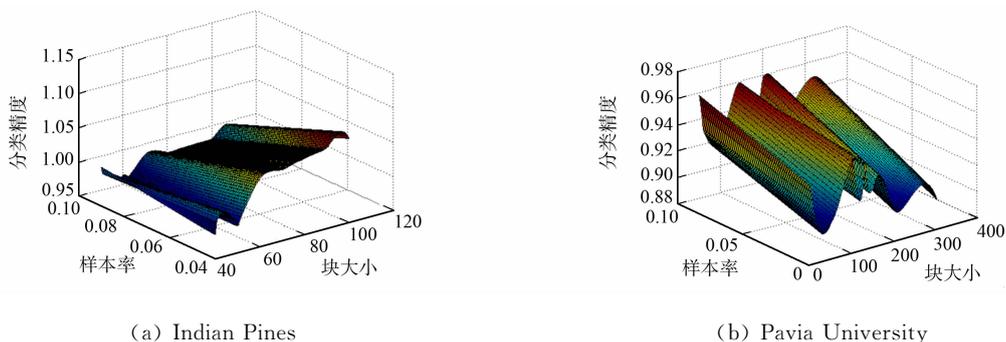
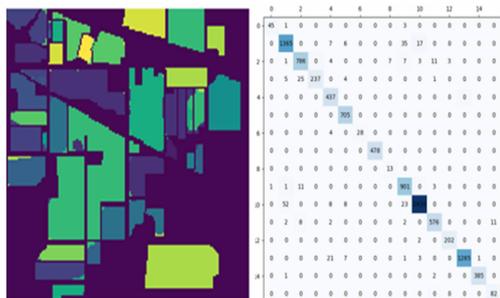


图 6 块大小和训练样本率与分类精度的关系

Fig. 6 Relationship between batch-size and training sample rate and classification accuracy

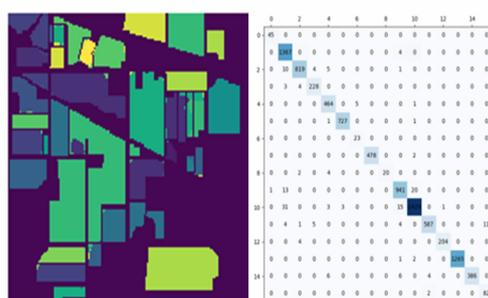
实验中, ACGAN 模型某次的分类结果及其混淆矩阵, 如图 7 所示. 由图 7 可知: 整体分类精度为 0.969, 平均分类精度为 0.947, Kappa 系数为 0.965; 采用 ACGAN 模型对高光谱图像进行分类可获得较高分类精度, 且所需的标记样本数较少. 需要注意的是, 在训练样本率为 0.10 的情况下, 第 1, 7 和 9 类样本的分类精度不高, 原因是这 3 类地物样本数太少, 模型还不能全面且稳定地学习到该类地物光谱的内在特征. 基于以上考虑, 在保留少量样本类别且其他类别的训练样本率保持 0.10 的情况下, 仅将 1, 7 和 9 这 3 类的训练样本数由原来的 4, 2, 2 个全部增加到 5 个. 增加 7 个训练样本后的分类结果及其混淆矩阵, 如图 8 所示. 由图 8 可知: 整体分类精度为 0.982 0, 平均分类精度为 0.967 9, Kappa 系数为 0.979 5; 在极少地增加少样本类别的训练样本数的情况下, 整体分类精度显著提升.



(a) 分类结果 (b) 混淆矩阵

图 7 Indian Pines 分类结果图

Fig. 7 Classification result of Indian Pines



(a) 分类结果 (b) 混淆矩阵

图 8 微调训练数据后的 Indian Pines 分类结果图

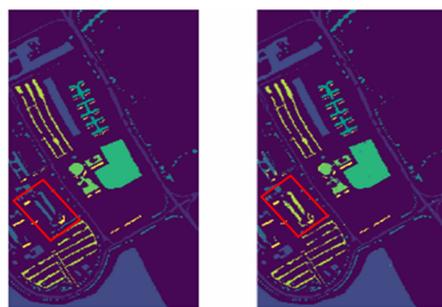
Fig. 8 Classification result of Indian Pines after fine adjusting the training samples

在 Pavia University 数据集下, 模型训练 500 次, 分类精度可达 0.962 5, 其分类效果, 如图 9 所示. 由图 9 可知: 对于大样本数据集, ACGAN 的分类性能依然较好, 但第 3 类沙砾大部分误分成第 8 类地砖 (图 9 中方框区域), 这是由于高光谱图像异物同谱和同物异谱的现象造成的.

由以上实验可知: ACGAN 模型对样本特征的学习能力较强, 极少地增加训练样本也能获得精度的明显提升. 这表明 ACGAN 在高光谱遥感图像上及其他分类领域上具有可行性, 并且可以获得较好的分类效果.

### 2.3 光谱空间特征分类实验结果分析

Indian Pines 数据集分类结果及精度对比, 如图 10 和表 3 所示. 由图 10 和表 3 可知: ACGAN-LBP-CNN 分类法中, 用 CNN 进行光谱空间特征分类时, 训练次数仅需 50 次, 且训练样本率可降低至 0.05 (将 1, 7, 9, 16 这 4 类的训练样本数增至 5 个), 即训练集个数为 517, 测试集个数为 9 732. 由于训练次数和训练集的减小, 模型的运算量也减小, 运行时间随之明显降低. 采用 10 次实验为一组的统计结果发现, OA 的平均值达到 0.979 8, 相比 ACGAN 分类法提升



(a) 地物实况 (b) 分类结果

图 9 Pavia University 数据集分类的效果

Fig. 9 Classification result of Pavia University

3.52%。由图 10 可知:ACGAN 模型在不进行空间滤波的情况下,也可获得比半监督的 3DBF-GANs 更好的分类精度;将 ACGAN 作为纹理特征提取器并使用 CNN 进行分类,优于直接使用原始光谱数据进行分类;纹理特征的加入,可提升分类精度。



图 10 Indian Pines 数据集分类结果

Fig. 10 Classification result of Indian Pines data

表 3 不同分类方法精度对比

Tab. 3 Comparison of accuracy in different classification methods

分类方法	Indian Pines			Pavia University		
	OA	AA	Kappa 系数	OA	AA	Kappa 系数
3DBF-GANs	0.756 2	0.810 5	0.722 3	0.779 4	0.813 6	0.713 2
ACGAN	0.952 7	0.956 2	0.945 9	0.962 5	0.917 0	0.950 1
ACGAN-CNN	0.978 6	0.966 7	0.975 6	0.985 8	0.975 3	0.981 2
ACGAN-LBP-CNN	0.990 6	0.987 4	0.989 3	0.988 3	0.982 4	0.984 4

Pavia University 数据集分类结果,如表 3 和图 11 所示。由图 11(b),(c)可知:将 ACGAN 用作特征提取器,对提取的光谱特征分类减少了异物同谱导致的误分。

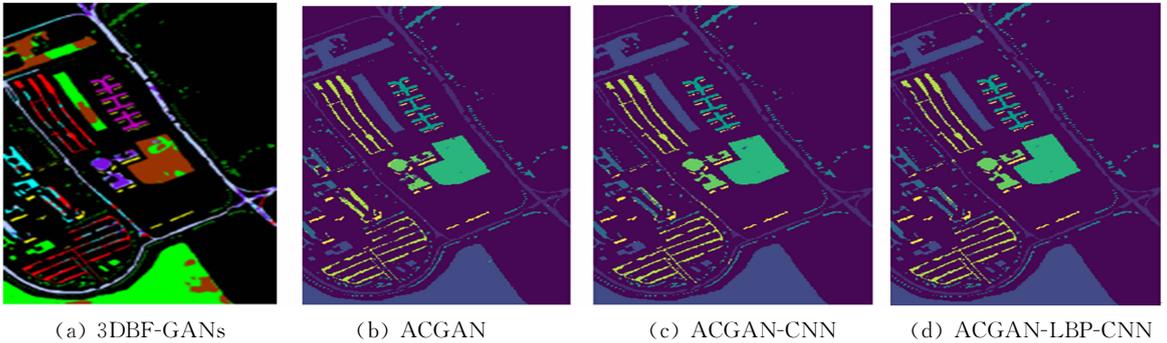


图 11 Pavia University 数据集分类结果

Fig. 11 Classification result of Pavia University

## 2.4 与其他分类方法对比分析

在 2 个数据集上,对 ACGAN, ACGAN-CNN, ACGAN-LBP-CNN, Pixel-CNN, SVM 5 种分类方法进行实验对比分析。在 Indian Pines 数据集上,还对比了全部类别(16 类)与只保留样本数大于波段数 2 倍的类别(9 类)这 2 种数据的分类结果。Pavia University 数据集上的分类结果及精度对比,如表 4 和图 12 所示。由表 4 可知:对提取的光谱特征进行分类比直接使用原始光谱数据效果更好;而 ACGAN-LBP-CNN 方法,整体分类达到 0.989 7,说明光谱纹理特征的融合分类效果远

表 4 Pavia University 分类结果精度对比

Tab. 4 Accuracy comparison of classification results at Pavia University

分类方法	OA	AA	Kappa 系数
ACGAN	0.962 5	0.917 0	0.950 1
ACGAN-CNN	0.988 4	0.979 5	0.984 6
Pixel-CNN	0.990 6	0.983 5	0.987 5
SVM	0.986 4	0.979 0	0.982 0
ACGAN-LBP-CNN	0.989 7	0.982 8	0.986 4

优于单一特征的分类效果;另外,Pavia University 数据集下的 Pixel-CNN 也能获得较高水平的分类精度,这说明文中方法更适合用于多类别,且标记样本数较少的分类任务,对数据集较大的分类任务还需

进一步优化.

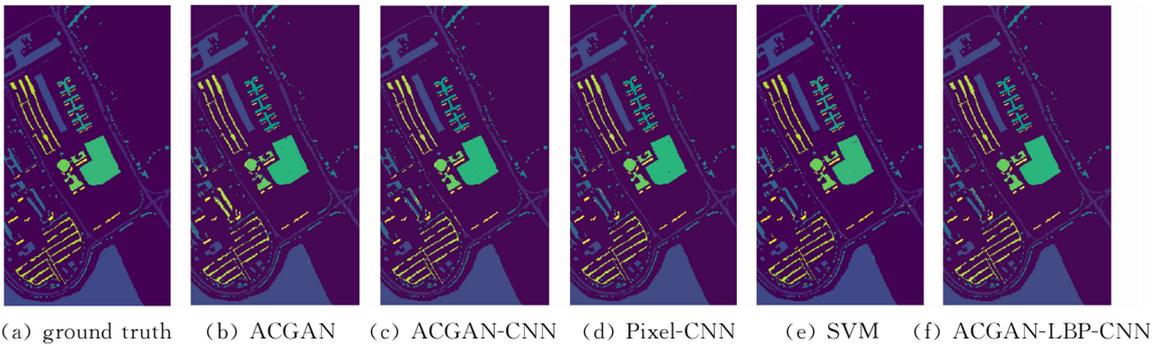


图 12 Pavia University 数据集不同分类算法结果

Fig. 12 Different classification algorithm result of Pavia University

Indian Pines 数据集上, 不同方法的分类结果及分类精度对比, 如图 13 和表 5 所示. 表 5 中: 该组实验数据保留全部 16 类样本, 共 10 249 个样本, 517 个训练样本; Indian Pines 数据集在只保留样本数大于波段数 2 倍的 9 类样本上, 该组实验共 9 234 个样本, 训练样本率为 0.05, 训练集大小为 457. 由表 5 可知: 数据集类别数越多, 分类越困难, 分类越低. 在小样本和多类别的 Indian Pines 数据集上, Pixel-CNN 的分类精度较低, 只达到 0.956 9; 而文中 ACGAN-LBP-CNN 方法对小样本的数据集有很高的分类精度, 达到 0.990 0 以上. 这有力地证明 ACGAN 强大的学习能力及在多分类问题上的潜能.

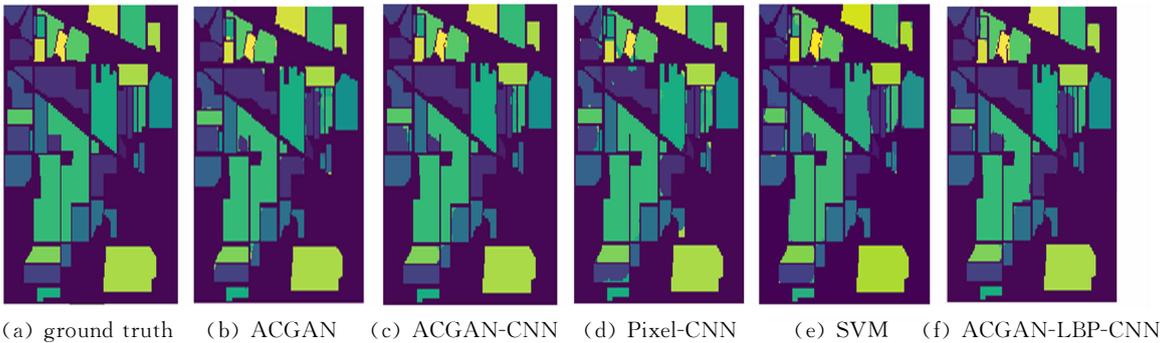


图 13 Indian Pines 16 类样本分类结果

Fig. 13 Classification result of Indian Pines for 16 classes

表 5 样本分类结果精度对比

Tab. 5 Accuracy comparison of sample classification results

分类方法	16 类 Indian Pines 样本			9 类 Indian Pines 样本		
	OA	AA	Kappa 系数	OA	AA	Kappa 系数
ACGAN	0.982 0	0.967 9	0.979 5	0.984 6	0.986 1	0.981 9
ACGAN-CNN	0.989 7	0.988 3	0.988 2	0.988 3	0.990 2	0.986 3
Pixel-CNN	0.956 9	0.961 2	0.950 8	0.962 1	0.960 0	0.955 5
SVM	0.968 4	0.966 9	0.964 0	0.965 9	0.955 9	0.959 9
ACGAN-LBP-CNN	0.990 6	0.987 4	0.989 3	0.993 5	0.995 2	0.992 4

### 3 结束语

针对高光谱遥感图像分类问题, 提出基于 ACGAN 的光谱纹理特征融合的 ACGAN-LBP-CNN 方法. 创新地采用生成式的 ACGAN 模型解决高光谱图像的物分类问题, 该模型具有较强的学习能力, 所需的标记样本少, 特别适合小样本、多类别的问题. 为进一步提升分类精度, 提出利用预训练的 ACGAN 模型的判别器, 提取样本的光谱特征. 实验结果表明: 提出的 ACGAN-LBP-CNN 方法对小样本和多类别的高光谱图像分类问题有较高的分类准确率, 且不需要进行去噪和波段选择等预处理, 简化了方案流程; 同时也证明了 ACGAN 模型在高光谱图像分类等问题上具有良好的可行性, 相比原始 GAN, ACGAN 生成的样本质量更好, 分类精度更高.

## 参考文献:

- [1] 刘雪松,葛亮,王斌,等.基于最大信息量的高光谱遥感图像无监督波段选择方法[J].红外与毫米波学报,2012,31(2):166-170.
- [2] 吴培强,张杰,马毅,等.基于地物光谱可分性的 CHRIS 高光谱影像波段选择及其分类应用[J].海洋科学,2015,39(2):20-24. DOI:10.11759/hyhx20141011007.
- [3] 许明明,张良培,杜博,等.基于类别可分性的高光谱图像波段选择[J].计算机科学,2015,42(4):274-275.
- [4] MARTÍNEZ-USÓMARTINEZ-USO A,PLA F,SOTOCA J M,*et al.* Clustering-based hyperspectral band selection using information measures[J]. IEEE Transactions on Geoscience and Remote Sensing,2007,45(12):4158-4171. DOI:10.1109/TGRS.2007.904951.
- [5] 施蓓琦,刘春,孙伟伟,等.应用稀疏非负矩阵分解聚类实现高光谱影像波段的优化选择[J].测绘学报,2013,42(3):351-358.
- [6] 张连蓬.基于投影寻踪和非线性主曲线的高光谱遥感图像特征提取及分类研究[D].青岛:山东科技大学,2003.
- [7] 吴波,周小成,高海燕.面向混合像元分解的光谱维小波特征提取[J].华侨大学学报(自然科学版),2008,29(1):156-160. DOI:10.11830/ISSN.1000-5013.2008.01.0156.
- [8] DATTA A,GHOSH S,GHOSH A. Unsupervised band extraction for hyperspectral images using clustering and kernel principal component analysis[J]. International Journal of Remote Sensing,2017,38(3):850-873.
- [9] 孙宁,邓承志,汪胜前.基于滤波后处理的主动学习高光谱遥感图像分类[J].南昌工程学院学报,2015(1):7-11. DOI:10.3969/j.issn.1006-4869.2015.01.002.
- [10] 王巧玉,陈锻生.结合波段选择和保边去噪滤波的高光谱遥感图像分类[J].小型微型计算机系统,2017,38(5):1098-1102. DOI:10.3969/j.issn.1000-1220.2017.05.036.
- [11] GOODFELLOW I J,POUGET-ABADIE J,MIRZA M,*et al.* Generative adversarial networks[J]. Advances in Neural Information Processing Systems,2014,3:2672-2680.
- [12] HE Zhi,LIU Han,WANG Yiwen,*et al.* Generative adversarial networks-based semi-supervised learning for hyperspectral image classification[J]. Remote Sensing,2017,9(10):1042. DOI:10.3390/rs9101042.
- [13] LIN Daoyu,FU Kun,WANG Yang,*et al.* MARTA GANs: Unsupervised representation learning for remote sensing image classification[J]. IEEE Geoscience and Remote Sensing Letters,2017,14(11):2092-2096.
- [14] ARINALDI A,FANANY M I. Generating single subject activity videos as a sequence of actions using 3D convolutional generative adversarial networks[C]// International Conference on Artificial General Intelligence. Berlin: Springer,2017:133-142.
- [15] PIETIKAEINEN M,OJALA T,NISULA J,*et al.* Experiments with two industrial problems using texture classification based on feature distributions[J]. Proc Spie,1994,2354:197-204. DOI:10.1117/12.189087.
- [16] 王春来,张森原,崔璐,等.训练样本数量选择和总体分类精度的关系研究[J].河南城建学院学报,2015(3):51-55. DOI:10.14140/j.cnki.hncjxb.2015.03.012.
- [17] WU Bo,CHEN Chongcheng,KECHADI T M,*et al.* A comparative evaluation of filter-based feature selection methods for hyper-spectral band selection[J]. International Journal of Remote Sensing,2013,34(22):7974-7990.
- [18] 樊利恒,吕俊伟,于振涛,等.基于核映射多光谱特征融合的高光谱遥感图像分类法[J].光子学报,2014,43(6):87-92. DOI:10.3788/gzxb20144306.0630001.
- [19] 李祖传,马建文,张睿,等.利用 SVM-CRF 进行高光谱遥感数据分类[J].武汉大学学报(信息科学版),2011,36(3):306-310. DOI:10.13203/j.whugis2011.03.009.
- [20] MONSERU R A,LEEMANSB R. Comparing global vegetation maps with the Kappa statistic[J]. Ecological Modelling,1992,62(4):275-293. DOI:10.1016/0304-3800(92)90003-W.

(编辑:李宝川 责任编辑:陈志贤 英文审校:吴逢铁)