

利用残差生成对抗网络的高光谱图像分类

陈明*, 席祥云, 王洋

上海海洋大学信息学院, 上海 201306

摘要 针对高光谱图像分类过程中存在的标记样本需求量大和分类精度要求高等问题,提出了一种利用残差生成对抗网络(GAN)的高光谱图像分类方法。该方法以生成对抗网络为基础,使用包含上采样层和卷积层构成的8层残差网络替换生成器的反卷积层网络结构,提高数据的生成能力,使用34层残差卷积网络替换判别器的卷积层网络结构,提高特征提取能力。以Pavia University、Salinas及Indian Pines数据集为实验数据,将所提方法与GAN、CAE-SVM、2DCNN、3DCNN、ResNet进行了比较。实验结果表明,所提方法在总体分类精度、平均分类精度和Kappa系数上均有显著提高,其中总体分类精度在Indian Pines数据集上达到了98.84%,较对比方法分别提高了2.99个百分点、22.03个百分点、12.91个百分点、4.99个百分点、1.79个百分点。所提方法在网络中加入残差结构,增强了浅层网络与深层网络的信息交流,可提取高光谱图像的深层次特征,提高了高光谱图像分类的精度。

关键词 图像处理; 高光谱图像; 分类; 深度学习; 生成对抗网络; 残差结构

中图分类号 TP751; TP183

文献标志码 A

DOI: 10.3788/LOP202259.2210008

Hyperspectral Image Classification Based on Residual Generative Adversarial Network

Chen Ming*, Xi Xiangyun, Wang Yang

Department of Information, Shanghai Ocean University, Shanghai 201306, China

Abstract A hyperspectral image classification method based on residual generative adversarial network (GAN) is proposed to address the problems of high demand for labeled samples and high classification accuracy in the process of hyperspectral image classification. The method is based on GAN and includes: replacing the deconvolution layer network structure of the generator with an eight-layer residual network composed of an upsampling layer and a convolution layer to improve data generation ability; improving feature extraction ability, the discriminator's convolutional layer network structure is replaced with a thirty-four-layer residual convolutional network. The experiment compares the datasets from Indian Pines, Pavia University, and Salinas. The proposed method is compared to GAN, CAE-SVM, 2DCNN, 3DCNN, and ResNet. The results demonstrate that the proposed method improves overall classification accuracy, average classification accuracy, and Kappa coefficient significantly. Among them, the overall classification accuracy reached 98.84% on the Indian Pines dataset, which is 2.99 percentage points, 22.03 percentage points, 12.91 percentage points, 4.99 percentage points, and 1.79 percentage points higher than the comparison methods. In summary, adding a residual structure to the network improves information exchange between the shallow and deep networks, extracts deep features of the hyperspectral image, and improves hyperspectral image classification accuracy.

Key words image processing; hyperspectral image; classification; deep learning; generative adversarial network; residual structure

1 引言

随着高光谱成像系统的发展,高光谱图像被广泛应用于矿业、天文学、农业和环境科学等不同领域^[1-4]。高光谱图像分类是高光谱图像处理和应用的组成

部分,但维度高、信息冗余、同物异谱和同谱异物等现象对高光谱图像分类提出了挑战。

目前,已有较多经典算法应用于图像的分类,如K-近邻算法、决策树、朴素贝叶斯和支持向量机(SVM)等^[5-8]。同时很多学者针对高光谱图像的特征,

收稿日期: 2021-08-02; 修回日期: 2021-09-07; 录用日期: 2021-10-19

基金项目: 江苏现代农业产业关键技术创新(CX(20)2028)

通信作者: *mchen@shou.edu.cn

提出了不同的分类方法:文献[9]先通过主成分分析法(PCA)进行数据降维,再使用3个滤波器进行空间卷积,最后使用SVM进行分类;文献[10]提出了一种基于递归滤波(RF)和K-nearest neighbor(KNN)算法的高光谱图像分类方法;文献[11]将local binary patterns(LBP)图像特征提取和K最近邻分类器相结合对图像进行分类。这些算法具有明确的数学原理,实现过程简单,在量度较小的数据样本上表现优秀。

以卷积神经网络(CNN)^[12]为代表的深度学习方法在图像分类方面表现出色。文献[13]提出了一种融合三维(3D)光谱空间深度神经网络的高光谱分类方法,该方法使用选定频段的不同组别来提取频谱空间特征以提高分类精度。文献[14]提出了一种使用递归神经网络(RNN)的高光谱数据分类方法,该方法将高光谱像素作为信息序列进行分析并通过网络推理识别其他信息类别。文献[15]提出了一种半监督自适应加权特征融合生成对抗网络(GAN),该网络通过轻量级的自适应特征加权组件进行特征融合,并引入了无标签数据来解决样本数量少的问题。文献[16]设计了一个双重注意模块(DAM)来减少不均匀像素的损坏数量,并使用由密集卷积块(DCB)组成的密集残差子网络从DAM的输出特征图中提取更具辨别力的特征。文献[17]提出了一种基于改进的DenseNet联合空谱注意力机制(M3DDSSNet)的方法,该方法对三维密集连接网络进行改进,将模型中的三维卷积块分解成空间维和光谱维的采样卷积,并在空间维度上引入空间注意力机制,在光谱维度上引入通道注意力机制,减少模型训练参数,从而提取具有判别力的空谱联合特征。卷积神经网络的每一层分别提取不同层次的特征信息,网络越深提取到的不同层次的信息会越多,不同层次间的层次信息的组合也会越多。但随着网络的不断加深,网络的性能逐渐降低,即网络深度增加导致网络难以训练,发生网络退化问题。而深度学习中的残差网络(ResNet)^[18]可通过浅层网络加上恒等映射层,增加网络的深度来降低误差。

为了通过有限的样本数据来增加网络的泛化性,

抑制网络在深度增加情况下的网络退化现象,本文对文献[19-20]中所提的GAN和ResNet进行改进,提出了一种利用残差GAN的高光谱图像分类方法。该方法以GAN为基础,使用8层残差网络替换生成器的反卷积层网络结构,提高数据的生成能力,使用34层残差卷积网络替换判别器的卷积层网络结构,提高特征提取能力。

2 基本原理

GAN^[21]是一种通过网络对抗提升性能的方法,是所提方法的基础。GAN包括生成器 G 和判别器 D :在训练过程中,生成器尽量生成真实的数据,交给判别器分类;判别器尽量区分生成器生成的数据与真实数据,在交替训练中达到最终平衡^[22]。

2.1 生成对抗网络

生成器模型接收随机噪声生成虚拟样本。判别器模型接收真实样本和虚拟样本,并判别样本的真伪。对于最后输出的结果,两个模型交替进行优化,直到网络达到均衡状态。

生成器模型可生成各种数据分布,在迭代训练中不断降低损失以减小生成分布与真实分布的差异:

$$G = \arg \min_G \text{Div}(P_G, P_{\text{Data}}), \quad (1)$$

式中:Div即散度,是一种量化两种概率分布之间差异的方式,计算的是数据的原始分布 P_{Data} 与近似分布 P_G 的概率对数差的期望值。通过不断改变预估分布的参数,得到不同散度的值,在特定变化范围内,散度取最小值时对应的参数即为最优参数。

判别器模型接收真实分布与生成分布,将判定为真实分布抽取的样本标注为真,判定为生成分布抽取的样本标注为假:

$$D = \arg \max_D V(G, D). \quad (2)$$

即最大化生成分布判断为假的概率。针对高光谱图像分类的GAN将噪声向量与给定类别标签输入生成器中生成虚拟样本,与真实样本一起输入判别器并判断输入样本的真伪,通过多分类器将判别为真的样本进行多分类。GAN分类工作框架如图1所示。

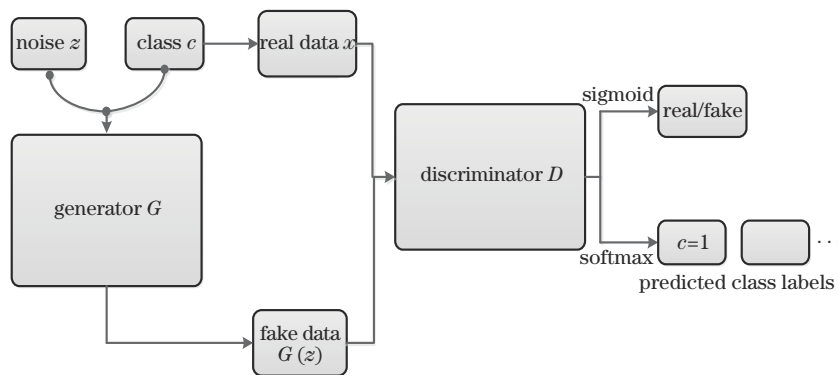


图1 生成对抗网络的高光谱图像分类框架

Fig. 1 Framework of GAN for hyperspectral image classification

2.2 残差结构

残差网络由残差单元构成,残差单元的原理是将神经网络单元输入与输出相加再进行激活。同等层次的残差网络较普通网络收敛更快,在网络加深情况下可缓解网络的退化现象。

图 2 为残差单元的结构图,单元内的输入和输出维度一致,将单元拟合的函数 H 拆分为两部分:

$$z^l = H(a^{l-1}) = a^{l-1} + F(a^{l-1}), \quad (3)$$

式中: z^l 为单元输出; a^{l-1} 为单元输入; F 为残差函数。在网络深层,通过训练使得 $H(a^{l-1}) \rightarrow a^{l-1}$, 等价于令残差部分 $F(a^{l-1}) \rightarrow 0$ 。在网络反向传播时,错误信息可不经任何中间权重矩阵变换直接传播到低层,缓解梯度弥散问题。




图 2 残差单元结构

Fig. 2 Structure of residual unit

2.3 激活函数

激活函数是在神经网络层中运行的函数,其作用是对输入进行非线性转换。激活函数可使神经网络进

行梯度和误差的反向传播,以更新权重和偏移^[23]。与线性激活函数相比,修正线性单元(ReLu)激活函数克服了梯度消失、训练速度慢等问题。

所提方法在网络层中使用带参数修正线性单元(PRelu)激活函数。当输入 x 为负时,PRelu 激活函数有一个小斜率,可避免 ReLU 激活函数为 0 的问题。当输入为正时,PRelu 激活函数与 ReLU 激活函数保持一致。PRelu 激活函数的表达式为

$$f(x) = \begin{cases} x, & x > 0 \\ \lambda x, & x \leq 0 \end{cases}, \quad (4)$$

式中: λ 代表了负值部分的斜率,由实验数据设定,是一个超参数。

2.4 Dropout 过拟合抑制方法

当网络模型变复杂时,需训练的参数会随之增加。若训练样本过少,则易出现过拟合现象:模型在训练数据上损失函数较小,预测准确率较高;但在测试数据上损失函数比较大,预测准确率较低。Dropout^[24]可通过阻止特征检测器的共同作用来提高神经网络的性能。所提利用残差生成对抗网络的高光谱图像分类方法在判别器的全连接层后使用 Dropout,通过随机丢弃数据的部分特征的方法来降低过拟合概率。

3 残差生成对抗网络的高光谱图像分类

所提利用残差生成对抗网络的高光谱图像分类方法流程如图 3 所示,包括残差结构生成器和残差结构判别器。

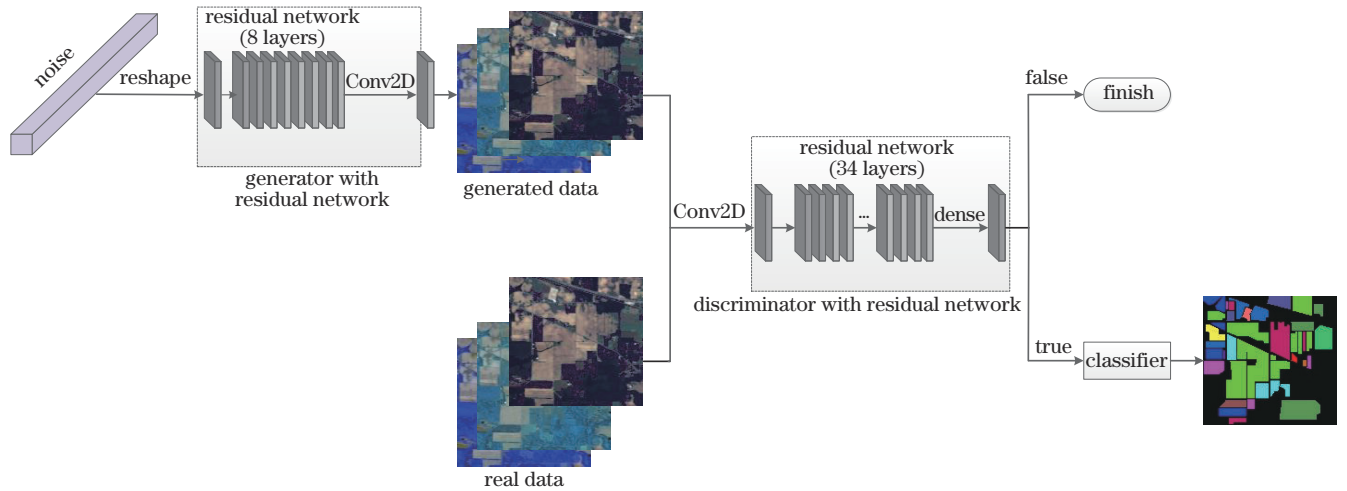


图 3 利用残差生成对抗网络的高光谱图像分类方法流程图

Fig. 3 Flowchart of hyperspectral image classification method using residual generative adversarial network

3.1 残差结构生成器模型

所提方法使用上采样层加卷积层^[25]的操作,通过加入残差结构,使生成器在训练中更快地提取样本数据的空谱信息,提高生成样本与真实样本的相似度,达到扩充样本数量的目的。图 4 为应用在生成器中的残

差块结构,所提方法使用 4 个残差块来代替生成器的反卷积层。

残差生成器网络结构如图 5 所示,包括 1 个 Dense 层、1 个 Reshape 层、4 个残差块结构和 1 个卷积层。

生成器接收具有高斯分布的 100 维随机噪声向量

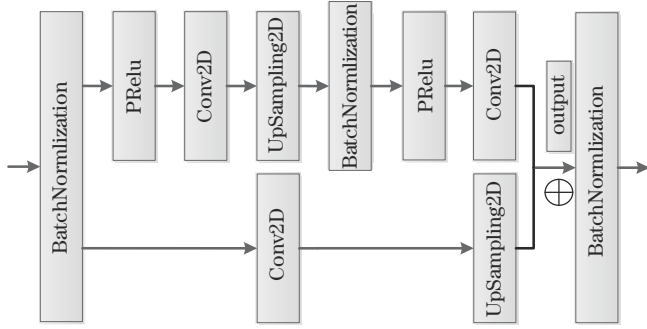


图 4 生成器残差块结构

Fig. 4 Structure for residual block of generator

作为输入,通过Dense层映射为 $4 \times 4 \times 256$ 的特征,并Reshape为 $(4, 4, 256)$ 的形状,然后通过4个输入形状分别为 $(4, 4, 256)$ 、 $(8, 8, 256)$ 、 $(16, 16, 256)$ 、 $(32, 32, 256)$ 的残差块结构处理,最后通过卷积核个数为3、卷积核形状为 $(3, 3)$ 的卷积层进行卷积操作输出生成的虚拟高光谱样本。

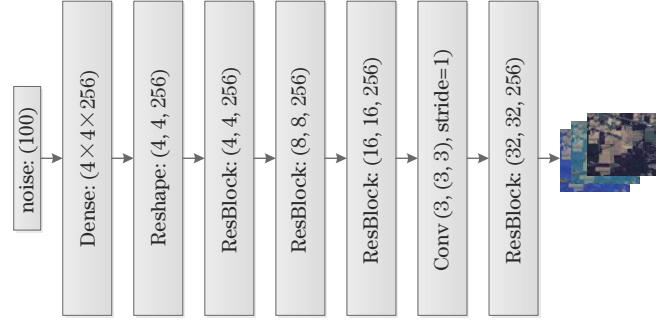


图 5 生成器网络结构

Fig. 5 Network structure of generator

3.2 残差结构判别器模型

所提方法在判别器中使用2种残差块结构,分别为无卷积残差块结构和带卷积残差块结构,如图6所示。在输入与输出数据形状相同的网络层使用无卷积残差块结构,在输入与输出数据形状不同的网络层则使用带卷积残差块结构。




图 6 判别器残差块结构。(a)带卷积残差块结构;(b)无卷积残差块结构

Fig. 6 Structure for residual block of discriminator. (a) Block structure with convolution residuals; (b) Block structure without convolution residuals

在利用生成对抗网络进行图像分类任务时,判别器要同时承担两个任务,即判别样本真伪和对样本进行分类。所提方法采用34层的深度残差网络来进行样本的判别与分类,在输出层分别使用sigmoid函数和softmax函数进行数据真伪判别和分类工作。

34层残差判别器网络结构如图7所示,高光谱数

据通过Padding尺寸为 $(3, 3)$ 的零填充(ZeroPadding),经过卷积核为64个、卷积核尺寸为 $(3, 3)$ 的卷积层,进行池化尺寸为 $(3, 3)$ 的最大池化(MaxPooling)操作,再通过17个输入参数为卷积核个数与卷积核尺寸的判别器残差块,然后经过池化尺寸为 $(2, 2)$ 的平均池化(AveragePooling)操作,最后使用Dropout操作再通过Dense层输出分类结果。

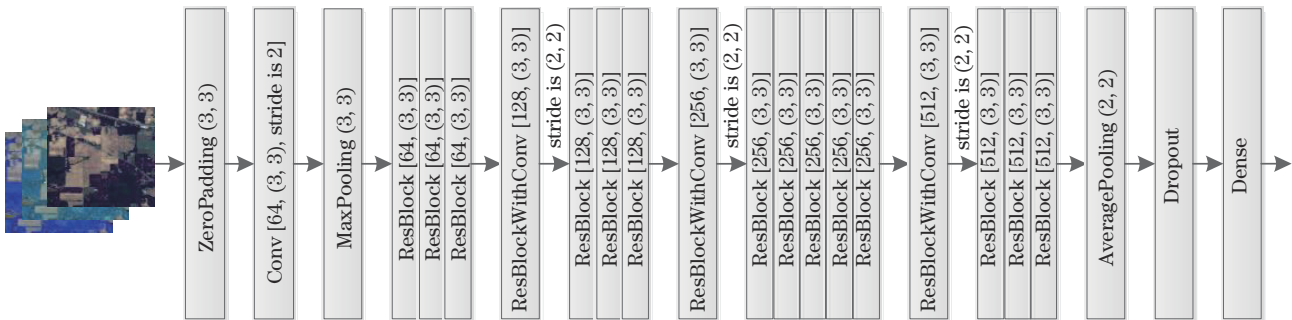


图 7 判别器网络结构

Fig. 7 Network structure of discriminator

4 实验结果与分析

设计了消融实验与对比实验:利用消融实验对所提方法的有效性进行分析;利用对比实验将所提方法与 CAE-SVM、2DCNN、3DCNN 和 ResNet 等方法进行优劣性比较。以总体分类精度(OA)、平均分类精度(AA)和 Kappa 系数^[26]为评价指标对各方法的性能进行评价。

实验在 PyCharm2020 上运行, CPU 为 Intel(R) Core(TM) i9-10900K @3.70 GHz, 显卡为 NVIDIA GeForce RTX 3090。

4.1 实验数据集

在 Pavia University (PU)、Salinas (SA) 及 Indian Pines(IP)等 3 个数据集上进行实验,各数据集选取每类样本的 10% 作为训练集。

Pavia University 数据集是帕维亚大学的高光谱数据,波长范围为 0.43~0.86 μm ,共有 115 个波段,空间分辨率为 1.3 m,地物类别包括 9 种。图 8 为 Pavia University 数据集的伪彩色图像及地面基准图。表 1 为 Pavia University 数据集类别及样本数。




图 8 Pavia University 数据集。(a)伪彩色图像;(b)地面基准图
Fig. 8 Pavia University dataset. (a) Pseudo color image;
(b) ground datum map

表 1 Pavia University 数据集类别及样本数

Table 1 Categories and number of Pavia University hyperspectral dataset

Class	Name	Color	Sample
1	Asphalt	Grey	6631
2	Meadows	Green	18649
3	Gravel	Cyan	2099
4	Trees	Dark Green	3064
5	Painted metal sheets	Pink	1345
6	Bare Soil	Brown	5029
7	Bitumen	Purple	1330
8	Self-Blocking Bricks	Orange	3682
9	Shadows	Yellow	947

Salinas 数据集是美国加利福尼亚州的 Salinas 山谷所成的像,空间分辨率达到了 3.7 m,地物类别有 16 种,共有 224 个波段。删除其中噪声高和水吸收多的波段,将波段的数量减少到 204 个。图 9 为 Salinas 数据集的伪彩色图像及地面基准图。表 2 为 Salinas 数据集类别及样本数。




图 9 Salinas 数据集。(a)伪彩色图像;(b)地面基准图
Fig. 9 Salinas dataset. (a) Pseudo color image;
(b) ground datum map

表 2 Salinas 数据集类别及样本数

Table 2 Categories and number of Salinas hyperspectral dataset

Class	Name	Color	Sample
1	Brocoli_green_weeds_1	Red	2009
2	Brocoli_green_weeds_2	Light Green	3726
3	Fallow	Blue	1976
4	Fallow_rough_plow	Yellow	1394
5	Fallow_smooth	Purple	2678
6	Stubble	Light Blue	3959
7	Celery	Orange	3579
8	Grapes_untrained	Green	11271
9	Soil_vinyard_develop	Dark Blue	6203
10	Corn_senesced_green_weeds	Pink	3278
11	Lettuce_romaine_4wk	Light Green	1068
12	Lettuce_romaine_5wk	Blue	1927
13	Lettuce_romaine_6wk	Brown	916
14	Lettuce_romaine_7wk	Green	1070
15	Vinyard_untrained	Dark Blue	7268
16	Vinyard_vertical_trellis	Red	1807

Indian Pines 数据集是在印第安纳州西北部的印度松测试点上由 AVIRIS 传感器采集到的,波长范围为 0.4~2.5 μm ,由 145×145 个像素点和 224 个波段组成,空间分辨率为 20 m,地物类别包括 16 种。删除其中噪声高和水吸收多的波段,将波段的数量减少到 200 个。图 10 为 Indian Pines 数据集的伪彩色图像及地面基准图。表 3 为 Indian Pines 数据集类别及样本数。




图 10 Indian Pines 数据集。(a) 伪彩色图像; (b) 地面基准图
Fig. 10 Indian Pines dataset. (a) Pseudo color image; (b) ground datum map

4.2 实验对比方法介绍

将所提方法与 CAE-SVM、2DCNN、3DCNN 和 ResNet 等方法进行分析比较。CAE-SVM 方法在 SVM^[27] 的基础上使用了压缩自编码器(CAE), 通过雅可比矩阵提取样本数据在各个方向的特征, 实现数据降维, 提高对输入数据中的扰动的鲁棒性, 降低输入数据的噪声。2DCNN^[28] 方法通过二维卷积核在图像上移动计算, 卷积核的通道数要与数据的通道数相等, 图像信息通过卷积核转化为特征图以提取空间特征, 并连接池化层与全连接层对特征图进行处理, 最后通过分类器来完成分类任务。3DCNN^[29] 方法是深度学习领域的方法, 利用主成分分析对输入的数据进行降维预处理, 将输入模型的像素分割成小的重叠的三维卷积块, 在分割的小块上基于中心像素形成地面标签, 利用三维核函数进行卷积处理, 形成连续的三维特征图, 保留空谱特征来进行分类任务。ResNet^[30] 方法以卷积神经网络为基础, 结合高光谱图像数据特

表 3 Indian Pines 数据集类别及样本数

Table 3 Categories and number of Indian Pines dataset

Class	Name	Color	Sample
1	Alfalfa		46
2	Corn-notill		1428
3	Corn-mintill		830
4	Corn		237
5	Grass-pasture		483
6	Grass-trees		730
7	Grass-pasture-mowed		28
8	Hay-windrowed		478
9	Oats		20
10	Soybean-notill		972
11	Soybean-mintill		2455
12	Soybean-clean		593
13	Wheat		205
14	Woods		1265
15	Buildings-Grass-Trees-Drives		386
16	Stone-Steel-Towers		93

点, 通过残差结构构建深度卷积神经网络, 避免梯度消失问题, 将数据误差尽可能完整地由浅层网络传输到深层网络, 以便于训练来降低损失, 提高分类的精度。

4.3 消融实验结果与分析

为了验证所提方法所做改进的有效性, 将所提方法与 GAN 方法、加入残差生成器的 GAN 方法、加入残差判别器的 GAN 方法进行消融实验对比。表 4 为消融实验的分类结果。

表 4 消融实验分类结果对比

Table 4 Comparison of classification results of ablation experiments

unit: %

Index	GAN			GAN with residual generator			GAN with residual discriminator			Proposed method		
	IP	PU	SA	IP	PU	SA	IP	PU	SA	IP	PU	SA
OA	95.85	96.59	96.57	96.52	97.11	97.53	97.21	97.34	97.93	98.84	99.00	99.09
AA	94.10	94.42	98.02	98.50	95.77	98.69	96.38	96.25	98.77	98.48	98.74	99.45
K	95.27	95.47	96.18	96.03	96.16	97.25	96.82	96.46	97.69	98.69	98.67	98.98

从表 4 可以看出: 所提方法在 3 个数据集上均表现出最佳的性能指标, 分类结果的 OA、AA、Kappa 系数均达到了 98% 以上; 加入残差生成器的 GAN 方法与 GAN 方法相比, 在 3 个数据集上的 OA 分别提升了 0.67 个百分点、0.52 个百分点、0.96 个百分点, AA 分别提升了 3.92 个百分点、1.35 个百分点、0.67 个百分点, 即残差生成器可提升 GAN 方法的样本扩充质量; 加入残差判别器的 GAN 方法与 GAN 方法相比, 在 3 个数据集上的 OA 分别提升了 1.36 个百分点、0.75 个百分点、1.36 个百分点, AA 分别提升了 2.28 个百分

点、1.83 个百分点、0.75 个百分点, 即残差判别器可提升 GAN 方法的样本分类性能。综上所述, 在 GAN 方法的生成器与判别器中加入残差结构, 可提高样本扩充质量和样本分类性能。

4.4 对比实验结果

将所提方法与 CAE-SVM、2DCNN、3DCNN 及 ResNet 方法进行了比较。采用的数据集及对数据集所做的预处理均相同。图 11~13 为各方法在不同数据集上的分类结果图, 表 5~7 为各方法在不同数据集上的分类精度。




图 11 Indian Pines 数据集分类图对比。(a) CAE-SVM;(b) 2DCNN;(c) 3DCNN;(d) ResNet;(e) 所提方法

Fig. 11 Hyperspectral image classification result map of Indian Pines dataset. (a) CAE-SVM; (b) 2DCNN; (c) 3DCNN; (d) ResNet; (e) proposed method




图 12 Pavia University 数据集分类图对比。(a) CAE-SVM;(b) 2DCNN;(c) 3DCNN;(d) ResNet;(e) 所提方法

Fig. 12 Hyperspectral image classification result map of Pavia University dataset. (a) CAE-SVM; (b) 2DCNN; (c) 3DCNN; (d) ResNet; (e) proposed method




图 13 Salinas 数据集分类图对比。(a) CAE-SVM;(b) 2DCNN;(c) 3DCNN;(d) ResNet;(e) 所提方法

Fig.13 Hyperspectral image classification result map of Salinas dataset. (a) CAE-SVM; (b) 2DCNN; (c) 3DCNN; (d) ResNet; (e) proposed method

表 5 Indian Pines 数据集分类精度对比

Table 5 Comparison of classification accuracy of Indian Pines hyperspectral dataset unit: %

Index	CAE-SVM	2DCNN	3DCNN	ResNet	Proposed method
OA	76.81	85.93	93.85	97.05	98.84
AA	75.52	87.23	94.13	96.78	98.48
K	75.28	84.30	92.77	96.63	98.69

表 6 Pavia University 数据集分类精度对比

Table 6 Comparison of classification accuracy of Pavia University hyperspectral dataset unit: %

Index	CAE-SVM	2DCNN	3DCNN	ResNet	Proposed
OA	84.28	90.81	95.69	97.24	99.00
AA	70.85	86.25	94.23	96.39	98.74
K	78.67	87.71	94.29	96.35	98.67

表 7 Salinas 数据集分类精度对比
Table 7 Comparison of classification accuracy of Salinas hyperspectral dataset unit: %

Index	CAE-SVM	2DCNN	3DCNN	ResNet	Proposed
OA	84.34	91.22	95.41	97.20	99.09
AA	79.97	93.02	96.07	98.31	99.45
K	82.52	90.22	94.15	96.91	98.98

4.5 对比实验结果分析

从表 5~7 可以看出:所提方法在 3 个数据集上的 OA、AA 和 Kappa 系数均在 99% 左右,较对比方法提升明显,尤其在小样本数据集 Indian Pines 上的泛化性能强,其 OA 达到 98.84%,比 CAE-SVM、2DCNN、3DCNN 和 ResNet 方法分别高出 22.03 个百分点、12.91 个百分点、4.99 个百分点、1.79 个百分点,AA 达到 98.48%,较对比方法分别高出 22.96 个百分点、11.25 个百分点、4.35 个百分点、1.70 个百分点;CAE-SVM 方法以非线性映射为理论基础,对数据进行最大化分类边际,在处理多个类别混合的数据区域时的能力有所欠缺,在 3 个数据集上的 OA、AA 和 Kappa 系数均未超过 85%;2DCNN 方法利用到高光谱图像的空间信息,但未能结合光谱信息进行分类,在 3 个数据集上的 OA、AA 和 Kappa 系数均为 90% 左右,其中在 Indian Pines 数据集上的指标低于 90%;3DCNN 方法通过 3 个卷积核对数据进行多维特征提取,在 3 个数据集上的 OA 达到了 93.85%、95.69%、95.41%,AA 达到了 94.13%、94.23%、96.07%,较 2DCNN 有明显提高,但其网络深度加深会导致网络退化;ResNet 方法在卷积神经网络的基础上加入了残差结构,可通过深层网络和浅层网络信息交流,保证反向传播时的梯度,有利于加深网络结构,在 3 个数据集上的 OA、AA 和 Kappa 系数均达到 96% 以上,但整体分类效果受样本数量的限制。

从图 11~13 可以看出,所提方法较对比方法分类结果图轮廓清晰,且在地物交错区域可准确识别样本的空谱信息,分类效果好。CAE-SVM、2DCNN 方法在 3 个数据集上存在大面积错分及椒盐现象,噪声较多。3DCNN、ResNet 方法改善了此现象,但在地物情况复杂的部分,由于光谱信息混杂,3DCNN 和 ResNet 方法无法准确分类,错分现象依然存在。

实验结果表明,与 CAE-SVM、2DCNN、3DCNN 和 ResNet 相比,所提方法在提高模型复杂度的情况下,增强了对小样本数据集的泛化能力,缓解了过拟合现象,并且在数据集样本较大的时候能维持健壮性,在分类精度上均优于对比方法。

4 结 论

针对高光谱图像分类过程中存在的标记样本需求

量大和分类精度要求高等问题,提出了一种利用生成对抗网络和残差结构的高光谱图像分类方法,将改进的残差块结构分别加入生成器与判别器中以增强网络结构,通过生成器训练生成数据,将真实样本与生成样本混合来训练判别器,完成分类任务。该方法与其他方法相比在不同数据集上的分类结果均有提高。在之后的研究中将选用更多的数据集来验证所提方法的性能。

参 考 文 献

- [1] Liu L, Feng J L, Han L, et al. Mineral mapping using spaceborne Tiangong-1 hyperspectral imagery and ASTER data: a case study of alteration detection in support of regional geological survey at Jintanzi-Malianquan area, Beishan, Gansu Province, China[J]. Geological Journal, 2018, 53: 372-383.
- [2] Lu B, Dao P, Liu J G, et al. Recent advances of hyperspectral imaging technology and applications in agriculture[J]. Remote Sensing, 2020, 12(16): 2659.
- [3] Courbot J B, Mazet V, Monfrini E, et al. Extended faint source detection in astronomical hyperspectral images[J]. Signal Processing, 2017, 135: 274-283.
- [4] Cristóbal J, Graham P, Prakash A, et al. Airborne hyperspectral data acquisition and processing in the Arctic: a pilot study using the hypspx imaging spectrometer for wetland mapping[J]. Remote Sensing, 2021, 13(6): 1178.
- [5] Bo C J, Lu H C, Wang D. Spectral-spatial K-Nearest Neighbor approach for hyperspectral image classification [J]. Multimedia Tools and Applications, 2018, 77(9): 10419-10436.
- [6] Xu S Y, Liu S Z, Wang H, et al. A hyperspectral image classification approach based on feature fusion and multi-layered gradient boosting decision trees[J]. Entropy, 2020, 23(1): 20.
- [7] 贺金鑫, 陈圣波, 王阳, 等. 一种基于朴素贝叶斯分类模型的高光谱矿物精确识别方法[J]. 光谱学与光谱分析, 2014, 34(2): 505-509.
He J X, Chen S B, Wang Y, et al. An accurate approach to hyperspectral mineral identification based on naive Bayesian classification model[J]. Spectroscopy and Spectral Analysis, 2014, 34(2): 505-509.
- [8] Chen Y N, Thaipisutikul T, Han C C, et al. Feature line embedding based on support vector machine for hyperspectral image classification[J]. Remote Sensing, 2021, 13(1): 130.
- [9] Chen G Y. Multiscale filter-based hyperspectral image classification with PCA and SVM[J]. Journal of Electrical Engineering, 2021, 72(1): 40-45.
- [10] 涂兵, 张晓飞, 张国云, 等. 递归滤波与 KNN 的高光谱遥感图像分类方法[J]. 国土资源遥感, 2019, 31(1): 22-32.
Tu B, Zhang X F, Zhang G Y, et al. Hyperspectral image classification via recursive filtering and KNN[J]. Remote Sensing for Land & Resources, 2019, 31(1): 22-32.

- [11] 刘嘉敏, 郑超, 张丽梅, 等. 基于图像重构特征融合的高光谱图像分类方法[J]. 中国激光, 2021, 48(9): 0910001. Liu J M, Zheng C, Zhang L M, et al. Hyperspectral image classification method based on image reconstruction feature fusion[J]. Chinese Journal of Lasers, 2021, 48(9): 0910001.
- [12] Vaddi R, Manoharan P. Hyperspectral image classification using CNN with spectral and spatial features integration [J]. Infrared Physics & Technology, 2020, 107: 103296.
- [13] Sellami A, Ben Abbes A, Barra V, et al. Fused 3-D spectral-spatial deep neural networks and spectral clustering for hyperspectral image classification[J]. Pattern Recognition Letters, 2020, 138: 594-600.
- [14] Venkatesan R, Prabu S. Hyperspectral image features classification using deep learning recurrent neural networks[J]. Journal of Medical Systems, 2019, 43 (7): 216.
- [15] Liang H B, Bao W X, Shen X F. Adaptive weighting feature fusion approach based on generative adversarial network for hyperspectral image classification[J]. Remote Sensing, 2021, 13(2): 198.
- [16] 王欣, 樊彦国. 基于改进DenseNet和空谱注意力机制的高光谱图像分类[J]. 激光与光电子学进展, 2022, 59 (2): 0210014. Wang X, Fan Y G. Hyperspectral image classification based on modified DenseNet and spatial spectrum attention mechanism[J]. Laser & Optoelectronics Progress, 2022, 59(2): 0210014.
- [17] 张祥东, 王腾军, 朱劭俊, 等. 基于扩张卷积注意力神经网络的高光谱图像分类[J]. 光学学报, 2021, 41(3): 0310001. Zhang X D, Wang T J, Zhu S J, et al. Hyperspectral image classification based on dilated convolutional attention neural network[J]. Acta Optica Sinica, 2021, 41 (3): 0310001.
- [18] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [19] Zhu L, Chen Y S, Ghamisi P, et al. Generative adversarial networks for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(9): 5046-5063.
- [20] Shao Y, Lan J H, Liang Y Z, et al. Residual networks with multi-attention mechanism for hyperspectral image classification[J]. Arabian Journal of Geosciences, 2021, 14(4): 1-19.
- [21] Li H C, Wang W Y, Ye S H, et al. A mixture generative adversarial network with category multi-classifier for hyperspectral image classification[J]. Remote Sensing Letters, 2020, 11(11): 983-992.
- [22] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial network[EB/OL]. (2014-06-10) [2021-02-05]. <https://arxiv.org/abs/1406.2661>.
- [23] Shyamala D M, Sagar A, Thapa K, et al. Activation layers implication of CNN sequential models for facial expression recognition[J]. IOP Conference Series: Materials Science and Engineering, 2021, 1074(1): 012030.
- [24] Srivastava N, Hinton G E, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [25] 彭亚丽, 张鲁, 张钰, 等. 基于深度反卷积神经网络的图像超分辨率算法[J]. 软件学报, 2018, 29(4): 926-934. Peng Y L, Zhang L, Zhang Y, et al. Deep deconvolution neural network for image super-resolution[J]. Journal of Software, 2018, 29(4): 926-934.
- [26] Ahmad M, Mazzara M, Distefano S. Regularized CNN feature hierarchy for hyperspectral image classification[J]. Remote Sensing, 2021, 13(12): 2275.
- [27] Tarabalka Y, Fauvel M, Chanussot J, et al. SVM- and MRF-based method for accurate classification of hyperspectral images[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 7(4): 736-740.
- [28] Li J J, Cui R X, Li B, et al. Hyperspectral image super-resolution with 1D - 2D attentional convolutional neural network[J]. Remote Sensing, 2019, 11(23): 2859.
- [29] 王燕, 梁琦. 快速3D-CNN结合深度可分卷积对高光谱图像分类[J/OL]. 计算机科学与探索: 1-12 [2021-06-02]. <http://kns.cnki.net/kcms/detail/11.5602.TP.20210429.1136.004.html>. Wang Y, Liang Q. Fast 3D-cnn combined with depth separable convolution for hyperspectral image classification [J/OL]. Journal of Frontiers of Computer Science and Technology: 1-12[2021-06-02]. <http://kns.cnki.net/kcms/detail/11.5602.TP.20210429.1136.004.html>.
- [30] Meng Z, Zhao F, Liang M M, et al. Deep residual involution network for hyperspectral image classification [J]. Remote Sensing, 2021, 13(16): 3055.