

DOI:10.19651/j.cnki.emt.2108021

生成对抗网络扩充样本用于高光谱图像分类*

刘雪峰¹ 刘佳明¹ 付民²

(1. 青岛科技大学自动化与电子工程学院 青岛 266061; 2. 中国海洋大学信息科学与工程学院 青岛 266101)

摘要: 高光谱图像包含着丰富的地理位置信息和光谱信息,高光谱图像分类是遥感领域的一个基础而又重要的研究方向。然而,高光谱图像样本数量不足仍然是限制分类精度进一步提升的主要问题。生成对抗网络中生成器和判别器的不断地对抗学习,最终理想状态为,生成器生成的伪样本判别器无法判别,生成与真实样本非常相似的伪数据样本。通过生成对抗网络来依据原有的少量样本,生成新的伪样本,解决样本获取困难、样本数量不足的问题。实验在两个高光谱图像数据集上分别选取 200 个和 400 个样本点进行实验,在生成对抗网络中生成新的伪样本,进行分类训练。与 SVM、3DCNN 等分类方法在同样是样本不足的情况下比较下,分类整体的平均精度得到明显提升,实验证明所提出方法的分类表现优于其他分类方法。

关键词: 高光谱图像;深度学习;生成对抗网络;图像分类;卷积网络;样本扩充

中图分类号: TP751 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Adversarial network samples were generated for hyperspectral image classification

Liu Xuefeng¹ Liu Jiaming¹ Fu Min²(1. College of Automation & Electric Engineering, Qingdao University of Science & Technology, Qingdao 266061, China;
2. College of Information Science & Engineering, Ocean University of China, Qingdao 266101, China)

Abstract: Hyperspectral image contains rich geographical location information and spectral information. Hyperspectral image classification is a basic and important research direction in the field of remote sensing. However, the insufficient number of hyperspectral image samples is still the main problem that restricts the further improvement of classification accuracy. In generative adversarial network, generator and discriminator are constantly learning against each other. In the final ideal state, the pseudo sample discriminator generated by generator cannot be discriminated and pseudo data samples very similar to real samples are generated. This paper uses generative adversarial network to generate new pseudo-samples based on a small number of original samples, so as to solve the problems of sample acquisition difficulty and insufficient sample quantity. In the experiment, 200 and 400 sample points were selected from two hyperspectral image data sets, and new pseudo-samples were generated in the generative adversarial network for classification training. Compared with SVM, 3DCNN and other classification methods with insufficient samples, the average accuracy of the whole classification has been significantly improved. Experimental results show that the classification performance of the proposed method is better than that of other classification methods.

Keywords: hyperspectral image; deep learning; generating adversarial network; image classification; convolutional network; sample expansion

0 引言

高光谱图像处理一直是遥感领域的一个重要研究方向。高光谱成像设备对目标区域进行连续的几十上百个波段内连续成像,可以获取到目标区域光谱和空间信息。目

前,各国都在高光谱遥感技术上投入了大量的时间和精力进行研究。随着高光谱分辨率成像传感器的出现、应用和发展,高光谱图像数据的获取变得容易,应用领域得到了扩展,并逐步实现了从地面遥感发展到航空和航天遥感相结合的阶段。高光谱图像的使用也越来越受到重视,不再局

收稿日期:2021-10-08

* 基金项目:国家自然科学基金(61971253)项目资助

限于地质勘探、海洋检测、军事侦察等,也被应用于森林监测、环境研究、海水温度检测等领域^[1]。

高光谱图像处理中,地物分类是其重要的研究方向之一。正是由于高光谱图像蕴含更丰富的地物信息,使其在地物分类方面更具有优势。在传统方法上如决策树、随机森林、支持向量机等,对高光谱图像特征提取都是浅层的,得到的分类精度并不高。此外高光谱图像数据量大、复杂度高、类内差异明显、训练样本不够仍然是当前高光谱图像分类研究需要解决的问题。

近年来,深度学习蓬勃发展,为我们解决诸多问题。深度学习现今主要是依靠神经网络模型来提取数据特征,特别是面对数据量大、数据结构复杂的时候相比于传统的机器学习具有明显优势^[2-4]。在面对大量数据的处理时,卷积神经网络和循环神经网络模型需要大量的先验数据。而高光谱图像在获得时往往只是图片数据,并不包含物类的标签信息。标签的信息通常是由人工在后期添加上的,工作复杂繁琐,面对样本标定等工作时常是费时费力,时常会出现训练样本不足的情况。在面对样本不足的问题,由于高光谱图像数据结构特殊,不同高光谱图像之间关联性相差较大,甚至可能出现负迁移的情况,并不能稳定高效的解决样本不足问题。Goodfellow等^[5]生成对抗网络通过小样本的对抗学习,并不依赖大量的先验数据,可以有效缓解样本数量不足的问题,而受到各界的关注和使用。尽管GAN网络有着诸多优点,但是在使用过程中仍然有不稳定的特点,于是Radford等^[6]提出了半监督的深度卷积的生成对抗网络,大大增强了网络的稳定性。随后Odena等^[7]通过引入多分类器与种类标签信息,能够依据判别器实现多种物类的区分,训练好的生成器也可以生成多种类的假样本。在这一模型的基础上通过生成对抗网络通过内部学习样本特征,充分发挥样本优势,相比于迁移学习由于受到高光谱图像差异化的影响,生成对抗网络在特征提取和模型训练方面准确性更高。但在实际操作中模型崩溃、收敛、速度、质量等仍是目前需要解决的问题^[8]。基于上述问题本文在利用生成对抗网络扩充样本,通过对数据预处理,合理设计网络结构参数,实现了稳定解决高光谱图像分类中样本少、分类精度不稳定的问题,并在多个实验数据集上进行验证,具有良好的分类效果。

1 高光谱图像与生成对抗网络简介

1.1 高光谱图图像简介

高光谱遥感技术起源于20世纪80年代初,经过数十年的发展,现在的高光谱遥感技术已经达到了一定的水平,成为人们获取地表物类信息的重要方法之一。高光谱图像蕴含的丰富的光谱信息和地理信息,是人们在在地物分类和检测的重要依据。

人眼只能接受可见光范围内频段,无法捕捉到红外频段和紫外频段的信息,但是获取高光谱图像的设备所使用

的频段比较宽,获取的高光谱图像常常包括上百个波段,可以将紫外频带,近红外频带和可见光频带信息统统捕获。并且在同一像素上不同波段下的数据,串连一条光谱曲线,它让人们可以获得更多的地表物体的信息。因为每种物体在不同光谱下表现得信息通常不同,因此高光谱图像的光谱信息不同,也是在高光谱图像分类中区分不同物类的重要依据之一^[9]。高光谱图像在拍摄制作过程中,为了充分获取地物信息,在多波段成像,造成光谱信息复杂、部分波段的信息可能会存在冗余,如果对高光谱图的全部波段直接处理,计算量将会十分庞大,因此通常对高光谱图像进行降维处理^[10-14],主成分分析法可以充分保留原始数据的信息,因而被广泛使用。

1.2 生成对抗网络简介

近年来,深度学习是处理机器视觉等领域问题的热门方法。在先验知识不足的情况下,传统的深度学习模型在特征提取、解决问题方面,显得十分乏力^[15]。生成对抗网络作为现今深度学习的三大模型之一,并不依赖大量的先验知识,在解决少样本问题的方面具有重大意义。2014年Ian Goodfellow所提出的生成式对抗网络GAN,得到广泛关注,并衍生出一系列的GAN框架(如DCGAN、ACGAN、CycleGAN等)在解决诸多问题方面具有强势表现。

生成对抗网络中包含两个网络, G (Generator)和 D (Discriminator),其原理如图1所示。 G 是生成器,负责图片的生成,随机的噪声 Z 输入到生成器中,生成器将噪声转化成图片数据,记做 $G(z)$; D 是判别器,负责判别输入的图像的真伪。假设 X 是输入图片, $D(x)$ 代表 x 为真实图片的概率作为输出,如果 $D(x)$ 为1,则表示判别器判定输入图片为真,若 $D(x)$ 为0,则代表判别器判定输入图像为假。在训练过程中,生成网络 G 的目的是使自己生成的图片数据尽可能接近真实的样本数据,使判别器无法发现生成数据为假,而判别网络 D 的目标如实判别输出送过来的图片数据的真伪,对于生成数据判定其未假,真实数据判定其为真。最终,判别网络和生成网络了在不断竞争对抗过程中,各自提高,在不断训练中随着生成器生成的图片越来越逼真,判别器难以判别出输入图片的真伪,最终训练完成后,达到理想效果,生成网络可以用来生成图。其损失函数如式(1)所示。

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}(x)} [\log D(x)] + E_{z \sim P_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

其中将 D 为判别器, G 定义为生成器。首先需要训练判别器,让判别器能够识别真实数据在接下来的步骤中能够区分生成数据,GAN公式的前半部分如式(2)所示。

$$E_{x \sim P_{data}(x)} [\log D(x)] \quad (2)$$

其中, $E_{x \sim P_{data}(x)}$ 表示期望 X 服从 P_{data} 中的分布; x 表示真实数据, P_{data} 表示真实数据的分布。这一部分表示,判别器要尽可能地识别出真实数据,判别器的训练目的就

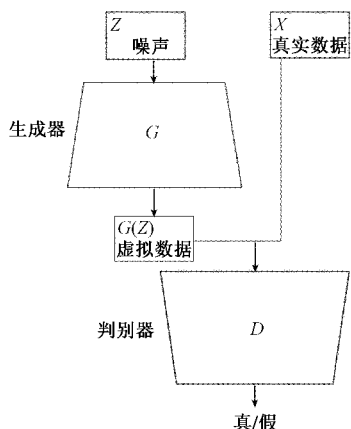


图 1 GAN 模型原理

是增大这一项,也就是说输入真实数据后,判别器应该输出的结果是 $D(x) \approx 1$ 。

GAN 公式的后半部分为:

$$E_{z \sim P_z(z)} [\log(1 - D(G(z)))] \quad (3)$$

其中, $E_{z \sim P_z(z)}$ 表示 Z 是服从 $P_z(Z)$ 分布中获取; Z 表示生成数据, P_z 表示生成数据中的分布。

对判别器而言,如果输入的是生成器数据,即 $D(G(z))$,判别器的目标就是最小化 $D(G(z))$ 即判别器希望 $D(G(z)) \approx 0$,也就是判别器希望 $\log(1 - D(G(z)))$ 最大化,但是对应于生成器来说,它的目标与判别器相反,生成器希望自己生成的数据被判别器打上高分,即希望 $D(G(z)) \approx 1$,也就是最小化 $\log(1 - D(G(z)))$ 。生成器只影响公式的后半部分,对前半部分没影响。

在 GAN 的训练过程中,一开始固定生成器 G 的参数训练判别器 D 。也就是最大化 $D(x)$ 和 $\log(1 - D(G(z)))$ 的值,从而达到最大化 $V(D, G)$ 的目的。当训练完判别器后就会固定判别器去训练生成器,因为此时判别器已经经过一轮的训练,所以生成器的目标就变成了在训练过判别器的情况下最小化 $\log(1 - D(G(z)))$ 来达到最小化 $V(D, G)$ 目的。

2 生成对抗网络与高光谱图像结合

2.1 ACGAN 模型原理

原理如图 2 所示,真实数据及对应标签被送入判别器,噪声和标签被送入生成器,其中的标签信息可以被判别器的生成器利用。其中生成器的生成标签 C 服从 P_c ,生成器的生成用 $X_{fake} = G(z)$ 表示,将带有相应标签的帧数数据和生成器生成的数据作为判别器的输入。损失函数包含两个部分,真假判别损失如式(4)所示,分类损失如式(5)所示。在训练过程中判别器要求式(6)去最大化而生成器要求式(7)去最大化。

真假判别损失:

$$L_s = E[\log P(S = real | x_{real})] + E[\log P(S = fake | x_{fake})] \quad (4)$$

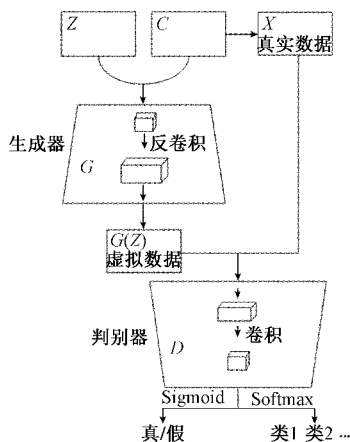


图 2 ACGAN 模型原理

分类损失:

$$L_c = E[\log P(C = c | x_{real})] + E[\log P(C = c | x_{fake})] \quad (5)$$

判别器的损失函数:

$$L_D = L_s + L_c \quad (6)$$

生成器的损失函数:

$$L_G = L_c - L_s \quad (7)$$

2.2 3DGAN 模型原理

3DGAN 的主要网络框架如图 3 所示,可以有效学习到高光谱图像的空间和光谱特征。由于高光谱图像蕴含波段太多,本实验中采用主成分分析法,选取数据的前 3 个和 10 个主成分,减少冗余信息,也可以保留空-间信息。在 3DGAN 中,生成器接受噪声作为输入,并将通过卷积将噪声转换成输入的真实数据的大小。然后判别器就收真实数据或者生成的伪样本作为输入,使用 Sigmoid 分类器给出真假结果,使用 Softmax 分类器给出分类结果。网络的第 1 层以噪声分布 z 作为输入,并作为卷积的起点,并在生成器和判别器中都使用了批处理。

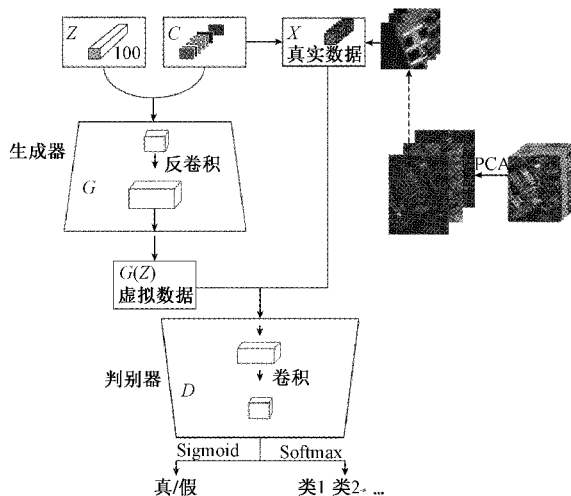


图 3 3DGAN 模型原理

这一网络不仅可以进行数据的分类,还可以输出对应的标签,实现样本扩充的功能。其中生成器和判别器的内部为多层的卷积网络。使用了 Sigmoid 和 Softmax 分类器,让判别器能够输出输入数据的真假和种类^[16]。该分类网络和 ACGAN 网络一样,首先在数据集中随机抽取若干个样本和对应的标签信息,以及生成器利用定义噪声生成的若干个样本,固定生成器,训练判别器,使之能区分真假以及种类;循环更新多次判别器之后,更新一次生成器,使生成器尽可能生成的数据更接近真实数据和标签,在多次迭代之后,判别器能够很好地判别出是否为真实样本,而生成器充分的学习了真是样本的分布规律,生成的数据与真实数据极为相似,使得最终判别器无法判断图片到底是来自真实的训练样本集还是生成器生成的样本,达到理想效果,完成训练。

2.3 生成分类样本

生成对抗网络中在博弈对抗中在多次迭代之后,训练后判别器也无法准确区分真假的图片,生成图片达到以假乱真的效果。此时整个对抗网络达到全局最优,此时的网络可以用来生成假样本,供参与分类训练。

在本实验中,将生成的假样本作为增加样本,单独作为一部分,扩充样本数量。将假样本和真样本送入训练网络中,增加训练样本的数量,解决样本不足的问题。假设原始数据集有 N 个类别,在网络训练期间,首先每个生成样本通过网络向前传递,并通过分类概率值获得一个标签。随后我们将假样本和对应获得的标签投入到网络中强化训练。此外,生成样本不属于任何类别的真样本。创建一个新的类标签(即 $N+1$),用来区分真样本和生成对应种类的生成样本,这样每个假样本都被赋予新标签($N+1$)。本文就是通过这样的方法来增加训练样本数量,解决在实际操作过程中样本不足的问题。

3 实验准备

3.1 数据集简介

本文采用两个不同环境而且广泛使用的数据集来验证所提出的实验方法。它们分别是 Indian Pines 和 Pavia University,如图 4 和 5 所示。




图 4 Indian Pines 数据集

数据集 1: Indian Pines, 图像大小为 $145 \times 145 \times 200$ 。原来包括 220 个波段,剔除 20 个不能被水反射的波段之后,保留剩下的 200 个波段。该数据总共有 21 025 个像




图 5 Pavia University 数据集

素,其中只有 10 249 个像素是地物像素,其余 10 776 个像素点为背景像素,在实际分类中,只需要对 16 类地物分类,其中包括燕麦、苜蓿、玉米、小麦等。

数据集 2: Pavia University, 图像大小为 $610 \times 340 \times 103$ 。原来包含 115 个波段。剔除 12 个受噪声影响的波段,保留剩下的 103 个波段作为数据集。共包含 207 400 个像素,其中背景像素 164 642 个,地物的像素总共只有 42 776 个。其中需要分类的地物像素共包含 9 类地物,包括树、沥青道路、树木、牧场、碎石等。

3.2 生成样本参与训练的 3DGAN

生成对抗网络由 1 个生成器和 1 个鉴别器组成,是 G 和 D 之间的两者极小极大博弈,在不断训练中达到一个动态的平衡,当鉴别器不能区分真实数据和合成的伪数据,可以得出 G 的生成能力具有优越的性能,整个对抗网络在理论上达到全局最优性。鉴别器可以作为一个分类器来获得分类结果。另一方面,来自生成器的合成假样本可以用于增加训练样本的数量。鉴别器模型是直接访问数据集中信息的模型。

在 3DGAN 网络中,有效地结合了空间和光谱信息,可以比单纯的利用空间或者光谱信息能够更好地提取信息,对高光谱图像保留 3 个主成分作为 3DGAN 的输入,网络结构如表 1 所示。判别器和生成器都是由 5 个卷积层和 4 个卷积层组成和适当的激活函数。判别器的最后是 1 个 Sigmoid 分类器和 1 个 Softmax 分类器,既可以区分样本的真伪,又可以输出样本种类。实验中以 Indian Pines 和 Pavia University 作为实验数据集,选取少量样本和标签作为先验知识,输入噪声为 $100 \times 1 \times 1$,生成器将其转换为合适大小的假样本,然后将样本送入判别器。也就是每个像素为中心的窗口邻域以及对应点的标签作为判别器的输入。本实验中选择批处理的大小为 64,学习率为 0.01,迭代次数为 800。

3.3 实验步骤

实验中对高光谱图像数据集进行预处理,并随即挑选一定数量的样本,作为训练数据集,进行实验训练,通过选取适当的参数,训练网络模型,最终实现网络能输出像样的假样本和标签,作为增加样本,解决样本过少的问题,最终

表 1 生成器和判别器的网络结构

网络	序号	卷积核	BN	步长	Pad-ding	激活函数
生成器	1	4×4×512	Y	1	0	ReLU
	2	4×4×256	Y	2	1	ReLU
	3	4×4×128	Y	2	1	ReLU
	4	4×4×3	N	2	1	ReLU
判别器	1	4×4×128	Y	2	1	LeakyReLU
	2	4×4×256	Y	2	1	LeakyReLU
	3	4×4×512	Y	2	1	LeakyReLU
	4	4×4×64	N	1	0	LeakyReLU
	5	64×nclass	N	—	—	LeakyReLU
		4×4×512	N	—	—	LeakyReLU

实现生成在少样本的情况下增加实验精度,具体步骤如下。

1) 高光谱图像数据进行预处理,用主成分分析的方法,选取 3 个和 10 个主成分分别进行实验,降低数据处理的复杂程度。

2) 选取少量样本, Indian Pines 和 Pavia University 真实样本分别 200 和 400, 并以其像素点为中心, 截取一个 32×32×3 窗口数据, 作为输入网络的样本数据。

3) 设计判别器与生成器, 生成器由 4 个卷积层组成, 能够实现将 1 组 100×1×1 噪声转换为 1 个 32×32×3 样本数据碎片; 判别器前 4 层为卷积层, 最后一层是 1 个 Sigmoid 分类器和 1 个 softmax 分类器。具体网络结构如表 1 所示。

4) 训练生成对抗网络: 首先初始化生成器和判别器的网络参数; 然后将选好的少量样本, 以及噪声送进网络; 先固定生成器, 训练判别器的判别能力, 使它能识别出真样本; 循环更新 10 次判别器之后更新一次生成器, 迭代次数设为 800。

5) 利用上一步已经训练好的生成器, 生成假样本, 作为训练数据集, 并将其投入分类网络中训练分类。

6) 输出分类精度与分类假彩图与其他方法对比。

4 实验结果及分析

在可视化实验中, 假样本是由 3DGAN 的生成器(即 G)生成的。图 6 所示为 3 个高光谱数据集上的一些选定的假样本。事实上, 很难区分假样本和真样本。从图 6 中可以看出, 在对抗训练结束时, 生成的样本从真实数据中获得越来越多的细节。




图 6 Pavia University 对应标签真实样本生成的假样本

在取得生成器和判别器达到良好的状态之后, 可以将生成器生成的假样本投入到模型中训练。为了验证模型的准确性, 使用 3DGAN 生成的伪样本作为训练数据输入, 假设原始数据由 N 类, 假设生成的样本被赋予标签 $N+1$ 类, 然后再将一起投入到 3DGAN 网络中, 选取适当的参数进行训练分类称其为 3DGAN, 通过实验得出, 加入假样本的数据训练之后, 分析分类实验结果, 分别与 SVM^[17] 与 3DCNN^[18, 19] 等方法做对比。实验中对于 Indian Pines 数据集的分类精度如表 2 所示。Indian Pines 数据集的分类假彩图如图 7 所示, Pavia University 数据集的分类精度如表 3 所示。Pavia University 数据集的分类假彩图如图 8 所示。

表 2 Indian Pines 分类精度结果

编号	名称	样本数量	SVM	3DCNN-3	3DCNN-10	3DGAN-3	3DGAN-10
1	苜蓿	46	15.99	14.55	22.30	30.15	48.76
2	非耕地-玉米地	1 428	40.11	86.43	86.45	81.04	81.54
3	幼苗玉米地	830	71.00	90.36	91.24	76.01	79.55
4	玉米	237	54.32	41.62	45.32	90.02	90.08
5	草地-牧场	483	68.31	85.63	86.01	67.49	70.14
6	草地-树木	730	90.22	93.00	93.21	93.41	94.04
7	草地-已修剪	28	97.5	12.14	11.48	40.65	66.70
8	干草-料堆	478	85.21	98.1	98.10	98.47	98.36
9	燕麦	20	14.90	11.02	12.44	21.05	50.00
10	非耕地-大豆地	972	75.10	78.50	79.95	75.01	76.60
11	幼苗-大豆地	2 455	81.33	96.05	97.46	91.26	91.55
12	大豆地-已修剪	593	32.11	89.24	90.17	84.19	87.84
13	小麦	205	88.47	98.00	98.20	77.21	78.92
14	木材	1 265	90.51	84.23	86.47	95.05	95.27
15	建筑-草-树木-机器	386	94.23	68.95	70.51	94.41	95.10
16	石钢塔	93	95.47	89.02	92.18	89.17	90.35
	OA/%		70.01	86.53	87.94	90.28	91.10
	AA/%		52.97	70.44	73.29	83.41	85.14
	K×100		64.62	84.16	86.53	87.45	88.70

表3 Pavia University 分类精度结果

编号	名称	样本数量	SVM	3DCNN-3	3DCNN-10	3DGAN-3	3DGAN-10
1	沥青	6 631	83.51	86.52	88.37	97.40	97.36
2	草甸	18 649	94.53	98.31	97.23	98.57	99.25
3	碎石	2 099	66.85	83.24	95.41	86.39	89.85
4	树木	3 064	92.36	82.52	92.48	91.04	97.11
5	金属板	1 345	80.15	85.41	96.01	99.49	99.63
6	裸地	5 029	72.62	90.58	96.22	93.85	95.24
7	柏油	1 330	61.70	83.78	98.48	98.65	99.05
8	砖	3 682	73.39	90.55	84.10	98.47	95.42
9	阴影	947	66.46	74.02	89.42	94.05	98.70
OA/%			84.45	91.20	93.14	95.78	97.02
AA/%			76.42	87.40	84.29	85.01	94.44
K×100			78.71	89.33	91.53	88.22	96.65




图7 Indian pines 分类假彩图




图8 Pavia University 分类假彩图

通过实验结果数据来看,3DGAN 的分类效果要有明显的提升,在整体的 OA 上相对于 SVM 有很大的优势,在 Indian Pines 数据集选取在少样本的情况下,与 3DGAN 的 OA 上分别提升 3.75%(3 维)和 3.16%(10 维);在 Pavia University 数据集选取在少样本的情况下,与 3DGAN 的 OA 上分别提升 4.58%(3 维)和 3.88%(10 维),但是人然后一些种类的分类精度依然很低如 Indian Pines 中的第 1 类苜蓿、第 9 类燕麦等,分析其原因可能是因为该两类样本在数据种类中所占的比例极低,参与训练的样本极少,使其特征很难被学习到。在某些分类中 SVM 的分类精度具有强势表现如 Pavia University 中的 Tree(树木)和 Indian pines 数据集中的第 7 类 Grass-pasture-mowed, 3DGAN 表现不佳,可能地表混合地物使其难以学习其数据特征。从实验结果可以看出 3DGAN 在大多数地物的分类上具有较高精度,整体上从 OA 和 AA 来看,3DGAN 分类精度来看具有一定的优势,基本达到了预期的效果。从分类结果图上来看在少样本的情况下 3DCNN 在图像的内部容易出现一定的错分情况,3DGAN 在物块边缘的分类上

容易进行错分,而来内部来说相对较好。

5 结 论

相比于传统的分类网络,3DGAN 在应对高光谱图像样本较少的情况下,分类精度方面取得了更高的精度。此本文框架被称为 3DGAN,结合了光谱和空间特征。与其他分类的方法(SVM、3DCNN)相比,这种体系结构在特征提取和图像分类方面表现出优异的能力。在提出的神经网络中,主成分分析用于降低输入的高维度,这对于稳定训练过程非常重要。由于深度模型中存在大量可学习的参数,深度神经网络存在过拟合问题,而 GAN 可以看作是一种正则化技术,可以缓解训练过程中的过拟合现象。此外,本文还展示了由 GAN 生成的输入图像窗口样本,有效弥补了高光谱图像训练样本少,样本难获取的问题。这些样本显著提高了分类性能。论证了生成对抗网络在高光谱图像分类方面的可行性和高效性。

参考文献

- [1] 李湘春,张峰,李宇,等.基于波段选择和空-谱组合核函数的高光谱图像目标检测[J].国外电子测量技术,2019,38(5):101-108.
- [2] 孙志军,薛磊,许阳明,等.深度学习研究综述[J].计算机应用研究,2012,29(8):2806-2810.
- [3] 常亮,邓小明,周明全,等.图像理解中的卷积神经网络[J].自动化学报,2016,42(9):1300-1312.
- [4] 张军阳,王慧丽,郭阳,等.深度学习相关研究综述[J].计算机应用研究,2018,35(7):1921-1928,1936.
- [5] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Advance in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [6] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep

- convolutional generative adversarial networks [J]. Computer Science, 2015, 47(8): 169-183.
- [7] ODENA A, OLAH C, SHLENS J. Conditional image synthesis with auxiliary classifier GANs[C]. Proceedings of the 34th International Conference on Machine Learning-Volume 70 JMLR.org, 2017: 2642-2651.
- [8] 王坤峰, 苟超, 段艳杰, 等. 生成式对抗网络 GAN 的研究进展与展望[J]. 自动化学报, 2017, 43(3): 321-332.
- [9] 童庆禧, 张兵, 张立福. 中国高光谱遥感的前沿进展[J]. 遥感学报, 2016, 20(5): 689-707.
- [10] 王敏, 陈金勇, 孙康, 等. 基于神经网络的高光谱图像异常目标检测方法[J]. 国外电子测量技术, 2019, 38(1): 96-101.
- [12] 张兵. 高光谱图像处理与信息提取前沿[J]. 遥感学报, 2016, 20(5): 1062-1090.
- [13] 李新国, 黄晓晴. 一种基于 DBN 的高光谱遥感图像分类方法[J]. 电子测量技术, 2016, 39(7): 81-86.
- [14] 李学亮, 王维. 基于 CNN 和 SIFT 特征的遥感图像变化检测[J]. 电子测量技术, 2019, 42(21): 87-91.
- [15] 李晓理, 张博, 王康, 等. 人工智能的发展及应用[J]. 北京工业大学学报, 2020, 46(6): 583-590.
- [16] 罗佳, 黄晋英. 生成式对抗网络研究综述[J]. 仪器仪表学报, 2019, 40(3): 74-84.
- [17] CHANG C C, LIN C J. LIBSVM: A library for support vector machines[J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 1-27.
- [18] ZHAO W, DU S. Spectral-spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach [J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(8): 4544-4554.
- [19] 曲景影, 孙显, 高鑫. 基于 CNN 模型的高分辨率遥感图像目标识别[J]. 国外电子测量技术, 2016, 35(8): 45-50.

作者简介

刘雪峰, 副教授, 博士, 主要研究方向为图像处理、模式识别等。

E-mail: nina. xf. liu@hotmail.com

刘佳明, 硕士生, 主要研究方向为图像处理等。

E-mail: liujiaming20201113@163.com

付民(通信作者), 副教授, 博士, 主要研究方向为高光谱图像传感器及去噪方法、水下通信系统等。

E-mail: fumin@ouc.edu.cn