

基于双通道 GAN 的高光谱图像分类算法

毕晓君¹, 周泽宇^{2*}

¹中央民族大学信息工程学院, 北京 100081;

²哈尔滨工程大学信息与通信工程学院, 黑龙江 哈尔滨 150001

摘要 针对现有高光谱图像生成式对抗网络(GAN)分类算法中存在不能充分提取光谱特征和空谱联合特征而导致高光谱图像分类精度降低的问题,提出一种基于双通道 GAN 的高光谱图像分类算法。通过搭建改进的一维 GAN 分类框架和二维 GAN 分类框架来分别提取完整的光谱特征和空间特征,并将光谱特征和空间特征进行非线性融合形成更为全面的空谱联合特征,最后将其送入到分类器中进行分类。对常用的高光谱图像数据集进行了分析验证,结果表明本文算法得到了最高的分类精度,验证了本文算法的有效性和先进性。

关键词 遥感; 高光谱图像; 分类; 空谱联合特征; 生成式对抗网络

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/AOS201939.1028002

Hyperspectral Image Classification Algorithm Based on Two-Channel Generative Adversarial Network

Bi Xiaojun¹, Zhou Zeyu^{2*}

¹Department of Information Engineering, Minzu University of China, Beijing 100081, China;

²College of Information and Communication Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China

Abstract The existing hyperspectral image generative adversarial network(GAN) classification algorithm cannot fully extract spectral and spatial-spectral features, which leads to the degradation of hyperspectral image classification accuracy. To resolve this issue, this study proposes a hyperspectral image classification algorithm based on a two-channel GAN. Improved one- and two-dimensional GAN classification frameworks are used to extract complete spectral and spatial-spectral features, respectively. Those features are nonlinearly fused to form a more comprehensive spatial-spectral features for classification. The experiments on two commonly used hyperspectral image datasets show that the proposed algorithm achieves the best classification accuracy; further, the results verify the effectiveness and advantages of the proposed algorithm.

Key words remote sensing; hyperspectral image; classification; spatial-spectral features; generative adversarial network

OCIS codes 280.4991; 100.4145; 100.2960

1 引 言

高光谱图像分类问题是高光谱遥感图像处理问题中的研究基础,它的主要目的是根据高光谱遥感图像中的光谱信息和空间信息将图像中的每个像元划分为不同的地物类别^[1]。高光谱图像分类技术被广泛应用于环境监测、矿产勘探、军事目标识别等领域,然而高光谱图像的高维特性、波段间的高度相关性、光谱混合等使得高光谱图像分类面临着巨大的

挑战。因此,高光谱图像分类问题越来越受到学者们的广泛关注^[2-4]。

近年来,深度学习在图像处理方面表现出的优势,让高光谱图像分类的研究学者们受到了启发^[5-9]。深度神经网络(DNN)的研究取得了重大进展,深度神经网络在图像、视频、语音、文本等领域都表现出优异的特征提取能力,目前已经成为计算机视觉、人工智能和机器学习等领域中最为热门的研究方向之一。尽管使用基于深度学习的方法在

收稿日期: 2019-02-22; 修回日期: 2019-04-10; 录用日期: 2019-06-21

基金项目: 国家自然科学基金(51779050)

* E-mail: zhouzeyu100@hrbeu.edu.cn

高光谱图像分类中取得了很大进展,但神经网络模型需要大量的训练样本来学习网络参数,而高光谱图像分类数据集训练样本有限,因此网络通常会面临过拟合的问题,这意味着网络在训练阶段表现很好,但是在测试阶段的效果很差^[10]。2014年,Goodfellow教授等^[11]提出了生成对抗网络(GAN),该网络可以在很大程度上缓解过拟合的现象,并在小样本训练中获得了很好的效果。2018年,Zhan等^[12]首次使用GAN来提取高光谱图像的光谱特征,在小样本数据训练问题中,该方法与神经网络相比获得了更好的分类效果,但是该方法的框架是固定的,应用于不同数据集时需要调整框架;此外,该方法没有考虑像元之间的空间相关性,分类精度仍有待提高。同年,Zhu等^[13]将深度卷积生成式对抗网络^[14](DCGAN)引入到高光谱图像分类中,并提出了基于光谱特征的一维生成式对抗网络(1D-GAN)和基于空谱联合特征的三维生成式对抗网络(3D-GAN)分类框架,得到了很好的分类效果,但是该方法由于生成器不能有效地模拟高维数据,所以在提取光谱特征和空谱联合特征时需要大幅度降维处理,这将损失较多的光谱特征和空谱联合特征。

为此,本文提出一种基于双通道GAN的高光谱图像分类算法。提出改进的一维GAN分类框架,用以提取全部光谱特征,提出改进的二维GAN分类框架,用以提取空间特征;然后结合上述两种框架提出双通道GAN分类框架,采用该框架对光谱特征和空间特征进行融合得到更为全面的空谱联合特征,将该联合特征送入到分类器中进行分类,以提升高光谱图像的分类精度。

2 理论基础知识

2.1 GAN

GAN是一种训练生成模型的新方法,也是训练分类器的有效方法。一般情况下,GAN分为两部分:生成器G和判别器D。生成器G用于捕获真实样本的潜在分布进而生成新的数据;判别器D本质上是一个二分类器,用来判别输入的样本是真实的还是虚假的。GAN中的信息传递是从产生假样本的生成器G到判别器D的前馈通道,其目的是为了评估生成器G的输出。GAN的框架结构如图1所示。

为了通过真实样本 x 学习生成器G的分布率 p_g ,假设真实样本的分布率为 $p(x)$,输入噪声的分布率为 $p(z)$ 。生成器G接收一个随机噪声 z 作为输入,并产生一个映射到数据空间的假样本 $G(z)$ 。




图1 GAN框架结构

Fig. 1 GAN framework structure

$D(x)$ 用于估计来自训练样本的 x 为真实样本的概率。在优化的过程中,为了使正确标签分给正确样本的概率最大,希望通过训练判别器D使得 $\log[D(x)]$ 最大化;与此同时,训练生成器G使得 $\log\{1-D[G(z)]\}$ 最小化。因此,本文进行优化的最终目的是求解判别器和生成器的最大最小化问题,其表达式为

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

式中 E 表示期望。从判别器D的角度来说,它希望能够尽可能地判断出真实样本和生成的假样本,也就是使 $D(x)$ 尽可能大而 $D[G(z)]$ 尽可能小,即使 $V(D, G)$ 尽可能大。而从生成器G的角度来说,它希望自己生成的假样本能够尽可能地接近真实样本,也就是希望 $D[G(z)]$ 尽可能大而 $D(x)$ 尽可能小,即使 $V(D, G)$ 尽可能小。因此,生成器G和判别器D这两个模型在训练过程中不断地相互对抗,最终达到全局最优。

2.2 DCGAN

DCGAN是对GAN结构的改进模型,它在GAN中引入了CNN的网络拓扑结构,并设置了一系列的限制使其可以进行稳定的训练,因此在很多情况下具备更好的稳定性^[15]。

DCGAN在原始GAN上做了以下几点改进:其一,在DCGAN中,将原始GAN所有的池化操作卷积操作来代替,其中判别器D中的池化层用卷积层来代替,而生成器G中的池化层则用反卷积层来替代,这使得生成器G能够学习它自己的空间上采样,而判别器D可以学习它自己的空间下采样;其二,DCGAN在除了生成器G的输出层和判别器D的输入层外的其他层使用批量标准化操作(BN)来稳定学习,有助于处理初始化不良导致的训练结果差的问题;其三,移除了更深层架构的全连接隐藏层,提升了收敛速度;其四,在生成器G的所有反卷积层上使用ReLU激活函数,只有输出层使用Tanh激活函数;其五,在判别器D的所有卷积层上使用

LeakyReLU 激活函数。

图 2 所示为 DCGAN 在 LSUN 数据集情境下的生成器 G 和判别器 D 的结构,其中 Conv 表示卷积,Deconv 表示反卷积。在生成器 G 的结构中,将

均匀分布的 100 维随机噪声 z 作为输入, z 通过投影和重塑之后通过 4 个反卷积层,最终输出 $64 \times 64 \times 3$ 大小的图像,而判别器 D 的结构操作则与生成器 G 的结构操作相反。

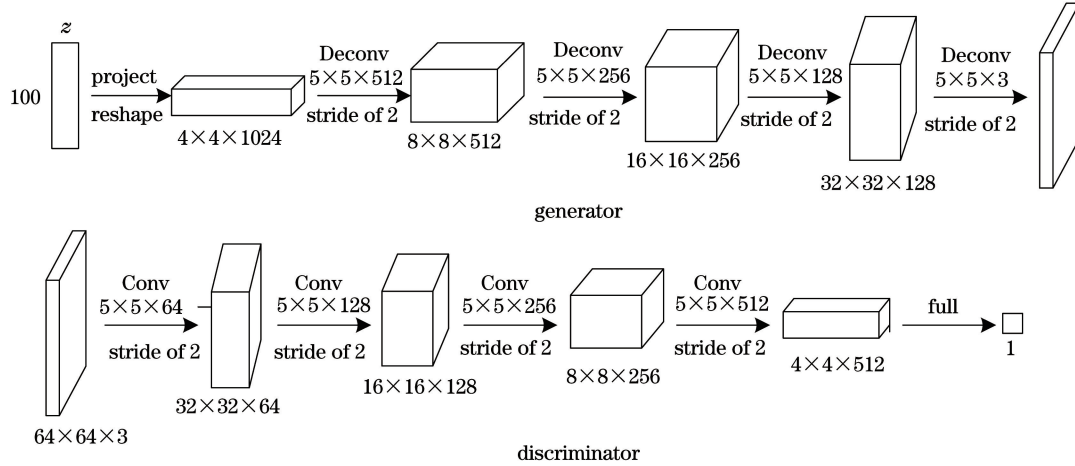


图 2 DCGAN 在 LSUN 数据集上的结构图

Fig. 2 Structural diagram of DCGAN on LSUN dataset

3 基于双通道 GAN 的高光谱图像分类算法的设计

3.1 高光谱图像 GAN 分类模型

高光谱图像 GAN 分类模型^[13]利用了 DCGAN 的框架,并借鉴了条件标签生成式对抗网络^[16](ACGAN)的思想,引入了 ACGAN 中的 softmax 分类器和目标函数,并将其目标函数加以修改来生成适合高光谱图像分类的目标函数。softmax 分类器在多分类中表现出很好的性能,其表达式为

$$f(x_i) = \frac{\exp x_i}{\sum_j \exp x_j}, \quad (2)$$

式中: $i=j=1,2,\dots,n$, n 为输入张量的维度; x_i 为输入张量第 i 维的元素; x_j 为输入张量第 j 维的元素。softmax 的主要目的是将输入张量的每个元素

缩放到 $(0,1)$ 区间且使其和为 1,从而通过不同幅度的概率值来进行多分类。

高光谱图像 GAN 分类模型考虑了真实数据样本的似然概率和正确标签的似然概率,其框架如图 3 所示。图中,噪声被送到生成器 G 中,生成器 G 生成的假数据样本和高光谱真实数据样本被送入到判别器 D 中,判别器 D 的输出被分别送入到 sigmoid 中判别真假和送入到 softmax 中对数据样本进行分类。

在高光谱图像 GAN 分类模型的训练过程中,将噪声 z 送入到生成器 G 中,因此生成器 G 的输出可以定义为

$$X_{\text{fake}} = G(z). \quad (3)$$

将真实训练数据样本和由 G 生成的假数据样本作为判别器 D 的输入。真实数据样本的概率分布 $P(S|X)$ 及类别标签上的概率分布 $P(C|X)$ 被

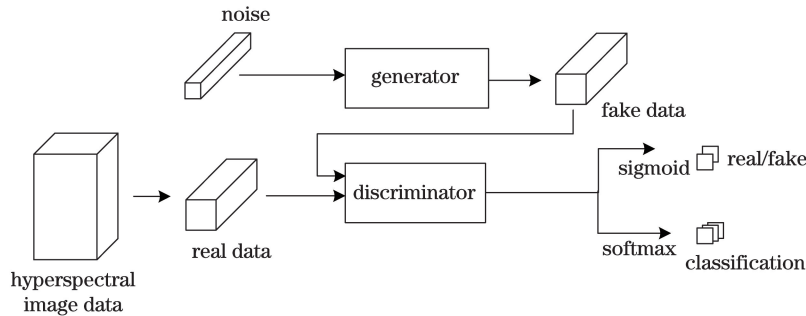


图 3 高光谱图像 GAN 分类框架

Fig. 3 GAN classification framework of hyperspectral image

送入判别器 D 中,其中 X 表示图像数据。因此,网络的目标函数包括两部分,即正确判别输入数据的对数似然函数 L_S 和正确判别标签类别的对数似然函数 L_C ,表达式为

$$\begin{cases} L_S = E[\log P(S = \text{real} | X_{\text{real}})] + \\ \quad E[\log P(S = \text{fake} | X_{\text{fake}})] \\ L_C = E[\log P(C = c | X_{\text{real}})] + \\ \quad E[\log P(C = c | X_{\text{fake}})] \end{cases}, \quad (4)$$

式中: X_{real} 为真实数据; C 为类别; c 为第 c 类; $S = \text{real}$ 表示当前数据被判别为真实数据, $S = \text{fake}$ 表示当前数据被判别为生成的假数据。

在高光谱图像 GAN 分类框架中,本文的目的是优化判别器 D 使 $L_S + L_C$ 最大,优化生成器 G 使 $L_C - L_S$ 最大。

文献[13]中提出的高光谱图像 GAN 分类模型取得了很好分类的结果,但是由于该方法不能有效地模拟高维数据,所以在提取光谱特征和空谱联合特征时需要降维处理,这将损失较多的光谱特征。为此,本文基于上述方法的思想,通过不断实验,一共设计了三个适用于高光谱图像分类问题的框架,即单独提取全部光谱特征的改进一维 GAN 分类框架、单独提取空间特征的改进二维 GAN 分类框架

和结合上述两个框架提取空谱联合特征的双通道 GAN 分类框架。

3.2 改进的一维 GAN 分类框架设计

改进的一维 GAN 分类框架借鉴了 1D-GAN^[13]的结构,在此基础上不断实验,更改了网络结构和参数,搭建了新的网络模型框架,以提取高光谱图像全部的光谱特征。该算法不需要对高光谱数据进行降维预处理,也无需随着高光谱图像数据维度的变化而改变网络结构,可以直接将高光谱图像数据送入到网络中,提取全部的光谱特征。由于高光谱图像数据的维度有几百维,信息高度冗余,生成器 G 可能难以模拟真实数据,为了使生成器 G 训练稳定且生成的数据能够更加贴近真实样本,本文使用了 DCGAN 的结构形式,在判别器 D 中应用了卷积层,在生成器 G 中应用了反卷积层,并加深了生成器 G 和判别器 D 的网络。

改进的一维 GAN 分类算法的框架和结构如表 1 和图 4 所示。生成器 G 中包含了 5 个反卷积层和一个全连接层,判别器 D 中包含了 7 个卷积层。其中 $a = n_{\text{nc}}/4$ (向下取整), n_{nc} 为高光谱图像的维度, n_{class} 表示图像中包含的地物类别数。生成器 G 中的全连接层是将生成器 G 中生成的假数据统一

表 1 改进的一维 GAN 分类框架

Table 1 Improved one-dimensional GAN classification framework

Networks	Layer	Operation	Kernel size	BN	Stride	Padding	Activation function
Generator	1	Deconv	$1 \times 1 \times 1024$	No	1	0	ReLU
	2	Deconv	$1 \times 1 \times 128 \times a$	Yes	1	0	ReLU
	3	Reshape	-	No	-	-	No
	4	Deconv	$4 \times 1 \times 256$	Yes	2	1	ReLU
	5	Deconv	$4 \times 1 \times 64$	Yes	2	1	ReLU
	6	Deconv	$1 \times 1 \times 1$	No	1	0	Tanh
	7	Full	$1 \times n_{\text{nc}}$	No	-	-	No
Discriminator	1	Conv	$3 \times 1 \times 32$	No	1	1	LeakyReLU
	2	Conv	$3 \times 1 \times 64$	No	1	0	LeakyReLU
	3	Conv	$3 \times 1 \times 128$	No	2	1	LeakyReLU
	4	Conv	$3 \times 1 \times 256$	No	1	0	LeakyReLU
	5	Conv	$3 \times 1 \times 128$	No	1	0	LeakyReLU
	6	Conv	$3 \times 1 \times 32$	No	2	1	LeakyReLU
	7	Reshape	-	No	-	-	No
	8	Conv	$1 \times 1 \times 1024$	No	1	0	No
	9	Softmax	$1024 \times n_{\text{class}}$	No	-	-	No
	Sigmoid	1024×2	No	-	-	No	

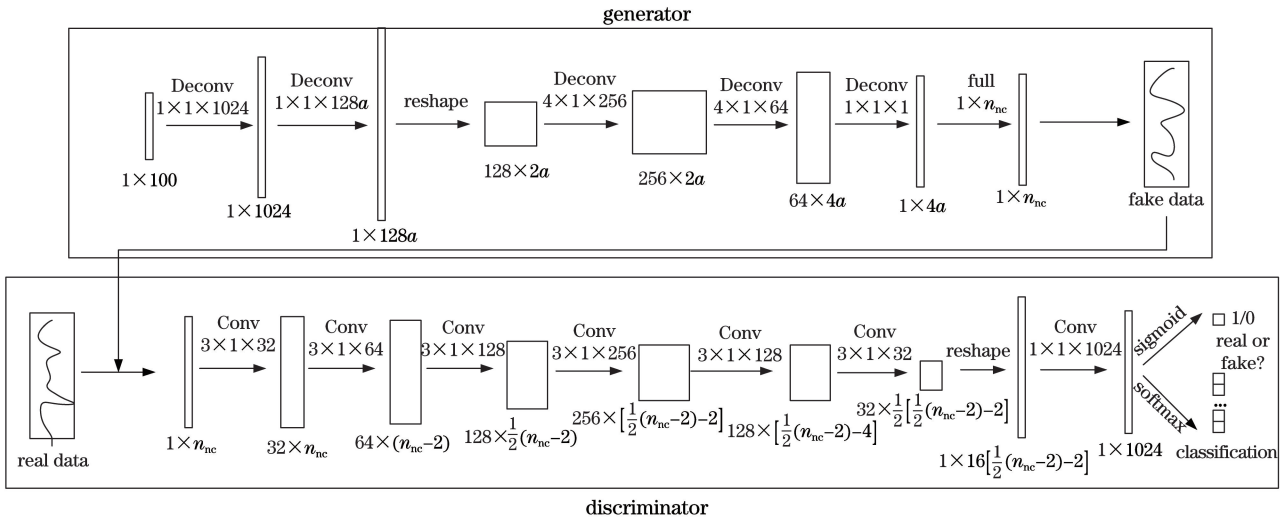


图 4 改进的一维 GAN 分类结构

Fig. 4 Improved one-dimensional GAN classification structure

成 $1 \times n_{nc}$ 大小的形式,这样可以保证无论高光谱图像数据的维度怎样变化,生成器 G 都能生成与其真实样本数据维度一致的假样本数据。在改进的一维 GAN 分类算法中,首先将 1×100 维的噪声作为输入送入生成器 G 中,通过 5 层反卷积操作和 1 层全连接操作,得到生成的 $1 \times n_{nc}$ 大小的假数据样本,再将真实数据样本与假数据样本送入到判别器 D 中,最后,通过 7 层卷积操作将得到的输出结果作为样本的光谱特征分别送入 sigmoid 二分类器中(判别真假)和 softmax 多分类器中(对样本进行分类)。

3.3 改进的二维 GAN 分类框架设计

改进的二维 GAN 分类框架在 DCGAN 框架的基础上重新进行了搭建,使其能够适用于高光谱图像分类问题,以便更好地提取高光谱图像的空

间特征,进而提高高光谱图像分类的精度。本文使用主成分分析(PCA)将高光谱图像降维成三维来提取高光谱图像的空间特征。

采用改进的二维 GAN 分类算法设计的框架和结构如图 5 和表 2 所示。生成器 G 包含了 5 个反卷积层,判别器 D 包含了 5 个卷积层。在改进的二维 GAN 分类算法中,首先将 1×100 维的噪声送入到生成器 G 中,经过 5 个反卷积层后生成假的样本数据,然后将生成的假数据与真实高光谱数据一同送入到判别器 D 中进行判别,最后,将假样本数据和真实样本数据通过判别器 D 中的 5 个卷积层后得到的输出结果作为样本的空间信息特征,将此特征分别送入 sigmoid 二分类器(进行判别)和 softmax 多分类器(进行分类)。

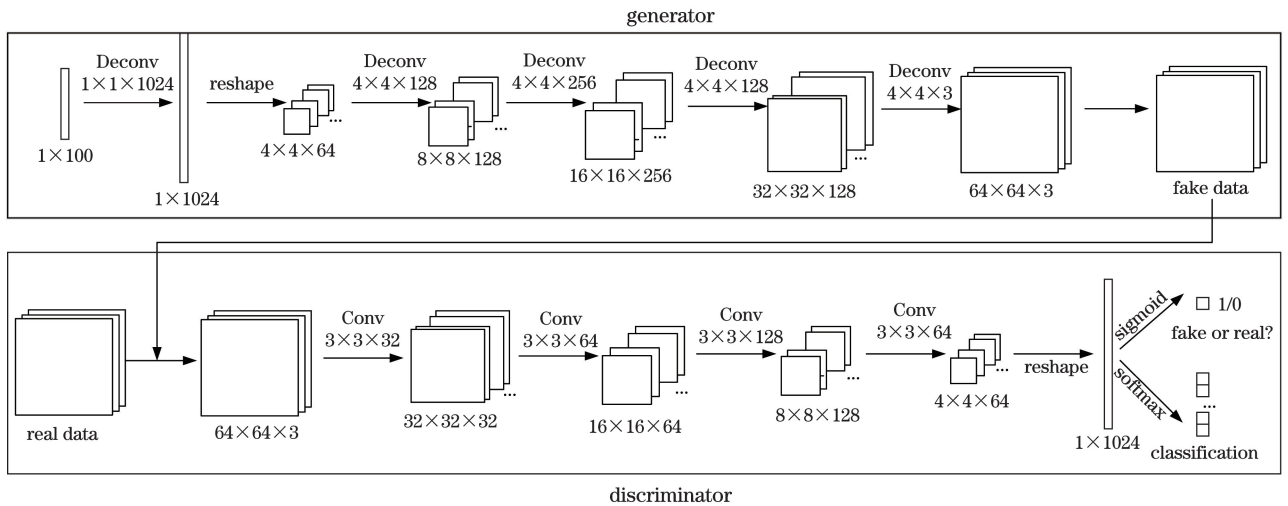


图 5 改进的二维 GAN 分类结构

Fig. 5 Improved two-dimensional GAN classification structure

表 2 改进的二维 GAN 分类框架

Table 2 Improved two-dimensional GAN classification framework

Networks	Layer	Operation	Kernel size	BN	Stride	Padding	Activation function
Generator	1	Deconv	$1 \times 1 \times 1024$	No	1	0	ReLU
	2	Reshape	-	No	-	-	No
	3	Deconv	$4 \times 4 \times 128$	Yes	2	1	ReLU
	4	Deconv	$4 \times 4 \times 256$	Yes	2	1	ReLU
	5	Deconv	$4 \times 4 \times 128$	Yes	2	1	ReLU
	6	Deconv	$4 \times 4 \times 3$	No	2	1	Tanh
Discriminator	1	Conv	$3 \times 3 \times 32$	No	2	1	LeakyReLU
	2	Conv	$3 \times 3 \times 64$	No	2	1	LeakyReLU
	3	Conv	$3 \times 3 \times 128$	No	2	1	LeakyReLU
	4	Conv	$3 \times 3 \times 64$	No	2	1	LeakyReLU
	5	Reshape	-	No	-	-	No
	6	Conv	$1 \times 1 \times 1024$	No	1	0	No
	7	Softmax	$1024 \times n_{\text{class}}$	No	-	-	No
		Sigmoid	1024×2	No	-	-	No

3.4 双通道 GAN 分类框架设计

高光谱图像不仅包含光谱特征也包含空间特征,基于空谱联合特征的分类方法往往比基于单特征的分类方法更为有效^[4]。因此,为了提取更为全面的光谱特征和空间特征,本文以上述两种模型框架为基础,引入空谱联合特征的思想,设计了如图 6 所示的双通道 GAN 分类框架。在这个框架中,首先通过训练改进的一维 GAN 分类框架提取到光谱特征 F_1 ,将光谱特征通过一个全连接层和一个 ReLU 非线性激活函数生成具有非线性的光谱特征

F_1^1 ,再通过训练改进的二维 GAN 分类框架提取到空间特征 F_2 ,将空间特征同样送入到一个全连接层和 ReLU 非线性激活函数中来获取具有非线性的空间特征 F_2^1 ,最后将得到的非线性光谱特征 F_1^1 和非线性空间特征 F_2^1 进行叠加生成光谱特征和空间特征融合的空谱联合特征 F_3 ,并将空谱联合特征 F_3 送入到 softmax 多分类器中进行分类,进而得到了最后的分类结果。空谱联合特征 F_3 的表达式为

$$F_3 = F_1^1 + F_2^1. \quad (5)$$

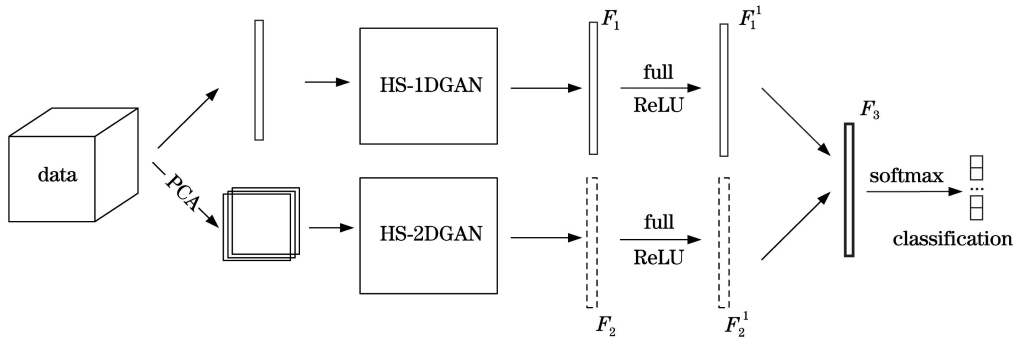


图 6 双通道 GAN 分类结构

Fig. 6 Two-channel GAN classification structure

4 实验仿真与分析

实验仿真采用的是常用于高光谱图像分类的两组数据集,Salinas 和 Indian pines 数据集,这两组数据集都是公开的高光谱基准数据,且包含相对准确的地物覆盖真值,它们的空间和光谱分辨率不同,可

以更加全面验证算法的有效性和稳定性,所有数据集将在后续章节中进行详细介绍。为了验证所提算法的有效性和先进性,对比算法采用的是高光谱图像分类算法中的深度卷积分类算法 1D-CNN^[13]、2D-CNN^[13]、3D-CNN^[6] 和目前效果最好的高光谱 GAN 分类算法 1D-GAN^[13] 和 3D-GAN^[13]。改进的

一维 GAN 分类框架(以下简称为 HS-1D-GAN)的 batchsize 设置为 100,生成器 G 和判别器 D 的迭代次数为 1000,学习率设置为 0.0002。改进的二维 GAN 分类框架(以下简称 HS-2D-GAN)的 batchsize 设置为 50,生成器 G 和判别器 D 迭代次数设置为 1000,学习率为 0.0002。双通道 GAN 分类框架(以下简称为 HS-TC-GAN)的 batchsize 设置为 50,生成器 G 和判别器 D 迭代次数设置为 1000,后接 softmax 分类器的迭代次数为 200,学习率设置为 0.0002。为了公平对比并验证所提算法在小样本量数据集上的有效性,在所有算法实验过程中,对每一个数据集都选取 500 个样本作为训练集,数据集中的其余样本作为测试集。其他对比算法中的参数都参照相应文献中给出的参数进行实验。在实验中,将测试所有本文提出算法的精度和性能。所有算法均独立运行 20 次,最终结果是 20 次实验结果的平均值。

本文采用常用于评价高光谱图像分类结果的三个精度评价指标来评估所提算法的性能,它们分别是总分类精度(OA)、平均分类精度(AA)和 Kappa 统计量^[17]。

混淆矩阵 C 是用于评价分类精度的基本指标,通过将真实地物标签与分类的结果相比较进行计算可得到 C ,再根据 C 计算出总分类精度、平均分类精度和 Kappa 统计量。

总分类精度表示全部测试数据集中被正确分类的样本个数与全部测试集中样本个数之比,其表达式为

$$OA = \frac{\sum_{i=1}^K C(i, i)}{N}, \quad (6)$$

式中:OA 表示总分类精度;K 表示类别数;N 表示样本总数; $\sum_{i=1}^K C(i, i)$ 为第 i 类被正确分类的总个数。

平均分类精度表示每一个类别分类精度的平均值,其表达式为

$$AA = \frac{\sum_{i=1}^K OA_{(i)}}{K}, \quad (7)$$

式中:AA 表示平均分类精度; $OA_{(i)}$ 表示第 i 类的总分类精度。

Kappa 系数表示的是一个预测的分类结果与真实结果吻合程度的指标,它在考虑样本被正确分类的同时,也考虑了各种漏分(某些样本没有被分到应属于的类别中)和错分(某类样本被错误地分到其他类别中)的情况,其计算式为

$$Kappa = \frac{N \sum_{i=1}^K C(i, i) - \sum_{i=1}^K C(i, +)C(+, i)}{N^2 - \sum_{i=1}^K C(i, +)C(+, i)}, \quad (8)$$

式中 $C(i, +)$ 和 $C(+, i)$ 分别表示第 i 行和第 i 列的总样本个数。

本文所有实验的硬件平台采用 Inter(R)Core (TM)i7-8700k CPU,3.70 GHz,内存 32 GB,GPU 为 GeForce GTX 1080Ti,软件平台采用 python 3.6.6 和 pytorch 0.4.0。

4.1 Salinas 数据集仿真实验

Salinas 数据集是 1998 年由 AVIRIS 从美国加州萨利纳斯山谷采集得到的,该数据波段为 $0.4 \sim 2.5 \mu\text{m}$,原始数据包含了 224 个波段,其空间分辨率为 3.7 m,每个波段的图像大小为 $512 \text{ pixel} \times 217 \text{ pixel}$,去除第 108~第 112、第 154~第 167 和第 224 个水吸收波段后,剩余 204 个可用的光谱波段。图 7 显示了 Salinas 高光谱伪彩色合成图和真实地物参考图,合成图由波段 54、31 和 21 合成,该数据集地物分布均匀且空间分辨率较高,覆盖地区为农作物种植区,一共有 16 个地物类别,其样本数如表 3 所示。

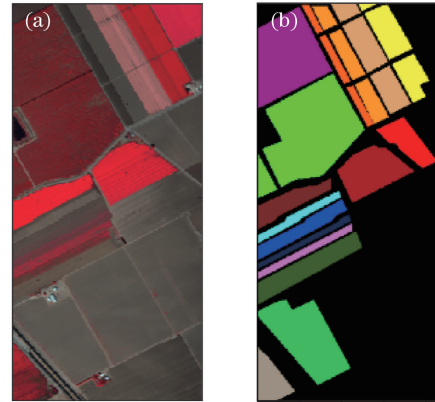


图 7 Salinas 数据集。(a) 伪彩色合成图;(b) 地物参考图
Fig. 7 Salinas dataset. (a) Pseudo color composite map; (b) feature reference map

表 4 给出了 1D-CNN、1D-GAN、2D-CNN、3D-CNN、3D-GAN 算法和本文提出的三种算法(HS-1D-GAN、HS-2D-GAN 和 HS-TC-GAN)在 Salinas 数据集上的分类性能比较。根据表 4 中的数据进行分析,在基于光谱特征的分类算法中,HS-1D-GAN 算法与 1D-CNN、1D-GAN 算法相比较,得到的三种指标的分类精度最高,与对比算法中表现最好的 1D-GAN 算法相比,OA、AA 和 Kappa 系数分别

表 3 Salinas 数据集样本表
Table 3 Salinas dataset sample table

















No.	Color	Class	Sample number
1		Brocoli_green_weeds_1	1977
2		Brocoli_green_weeds_2	3726
3		Fallow	1976
4		Fallow_rough_plow	1394
5		Fallow_smooth	2678
6		Stubble	3959
7		Celery	3579
8		Grapes_untrained	11213
9		Soil_vinyard_develop	6197
10		Corn_senesced_green_weeds	3249
11		Lettuce_romaine_4wk	1058
12		Lettuce_romaine_5wk	1908
13		Lettuce_romaine_6wk	909
14		Lettuce_romaine_7wk	1061
15		Vinyard_untrained	7164
16		Vinyard_vertical_trellis	1737
		Total	53785

表 4 8 种算法在 Salinas 数据集上的分类性能比较

Table 4 Comparison of classification performances of eight algorithms on Salinas dataset

Index	1D-CNN	1D-GAN	HS-1D-GAN	2D-CNN	HS-2D-GAN	3D-CNN	3D-GAN	HS-TC-GAN
OA / %	86.12	86.88	90.22	87.84	97.15	92.04	93.38	99.67
AA / %	89.63	92.24	94.05	89.86	96.96	94.54	95.20	99.45
Kappa / %	84.48	85.39	89.10	86.44	96.82	91.13	92.63	99.63
Train time / s	8.96	19.67	120.99	94.61	195.60	211.90	350.49	385.27
Test time / s	0.51	0.54	2.87	3.95	2.43	4.00	3.48	5.11
Total time / s	9.47	20.21	123.86	98.56	198.03	215.90	353.97	390.38

在 Salinas 数据集实验中,将算法的训练时间、测试时间和总时间作对比,在比较基于 GAN 的分类算法和基于 CNN 的分类算法时,由于 GAN 需要生成器 G 和判别器 D 两个网络一起训练,网络相较 CNN 复杂,所需参数量更多,所以在基于深度学习的算法中,CNN 的训练时间较短。在基于 GAN 的各类算法中,由于卷积核的选取,网络层数搭建的深度及分别提取光谱特征、空间特征和空谱联合特征所需计算量不同等因素,各类 GAN 的训练时间也有所不同,其中 HS-TC-GAN 算法由于有两个通道,相当于两个 GAN 网络框架,且需要提取空谱联

提升了 3.34%、1.81% 和 3.71%。在基于空间特征的分类算法中,HS-2D-GAN 算法与 2D-CNN 算法相比较,OA、AA 和 Kappa 系数分别提升了 9.31%、7.10% 和 10.38%。在基于空谱联合特征的分类算法中,HS-TC-GAN 算法与 3D-CNN 和 3D-GAN 算法相比较,分类精度也最高,与对比算法中表现最好的 3D-GAN 算法相比,OA、AA 和 Kappa 系数分别提升了 6.29%、4.25% 和 7.00%。这证明了在 Salinas 数据集中,基于 GAN 分类算法在使用小样本数据进行训练时,能获得比基于 CNN 分类算法更高的分类精度;并且与现有的 GAN 分类算法相比,本文提出的算法表现出更高的分类性能,验证了本文提出的算法的有效性。单独比较本文提出的 HS-1D-GAN、HS-2D-GAN 和 HS-TC-GAN 分类算法时,HS-TC-GAN 算法的分类精度最高,与 HS-1D-GAN 算法相比,OA、AA 和 Kappa 系数分别提高了 9.45%、5.40% 和 10.53%,与 HS-2D-GAN 算法相比,OA、AA 和 Kappa 系数分别提高了 2.52%、2.49% 和 2.81%。这说明在 Salinas 数据实验中,基于空谱联合特征的双通道 GAN 分类框架的算法与单独使用光谱特征的分类算法和单独使用空间特征的分类算法相比,能够更为有效地提升分类精度。

合特征,因此,其训练时间最长,在基于深度学习的算法中测试时间也最长;而 1D-CNN 算法的网络结构最为简单,仅需对光谱特征进行处理,所以在基于深度学习的分类算法中训练时间最短,在所有算法中测试时间最短。

图 8 给出了 8 种算法在 Salinas 数据集上的图像分类结果。从视觉直观来看,在基于光谱特征的分类算法中,HS-1D-GAN 算法与 1D-CNN、1D-GAN 算法相比较,HS-1D-GAN 算法中同种地物错分的情况要更少。在基于空间特征的分类算法中,HS-2D-GAN 算法与 2D-CNN 算法相比较,

HS-2D-GAN 算法的分类视觉效果更好一些,如左上角紫色对应地物的分类,HS-2D-GAN 算法显然比 2D-CNN 算法更为准确,紫色区域的分类效果更好。在基于空谱联合特征的分类算法中,HS-TC-GAN 算法与 3D-CNN 和 3D-GAN 算法相比较,HS-TC-GAN 算法的分类结果几乎接近了真实地物参考图,而 3D-CNN 和 3D-GAN 算法仍存在

明显的错分情况。比较本文提出的 HS-1D-GAN、HS-2D-GAN 和 HS-TC-GAN 分类算法可知,HS-TC-GAN 分类算法的分类结果具有最好的视觉效果,说明在 Salinas 数据实验中,基于空谱联合特征的双通道 GAN 分类方法的效果要比单独利用光谱特征和单独利用空间特征的分类效果更好。




图 8 Salinas 数据集上 8 种算法的分类结果。(a) 真实地物参考图; (b) 1D-CNN; (c) 1D-GAN; (d) HS-1D-GAN; (e) 2D-CNN; (f) HS-2D-GAN; (g) 3D-CNN; (h) 3D-GAN; (i) HS-TC-GAN

Fig. 8 Classification results of the eight algorithms on the Salinas dataset. (a) Real feature reference map; (b) 1D-CNN; (c) 1D-GAN; (d) HS-1D-GAN; (e) 2D-CNN; (f) HS-2D-GAN; (g) 3D-CNN; (h) 3D-GAN; (i) HS-TC-GAN

4.2 Indian pines 数据集仿真实验

Indian pines 数据集由 AVIRIS 于 1992 年采集于美国印第安州西北部普渡大学农场,该数据集波段为 $0.4 \sim 2.5 \mu\text{m}$,其原始数据包含了 220 个通道,空间分辨率为 20 m,图像大小为 $145 \text{ pixel} \times 145 \text{ pixel}$ 。去除第 104~第 108,第 150~第 163 及第 220 个水吸收波段后,剩余 200 个可用波段。图 9 显示了该高光谱的伪彩色合成图和真实地物参考图,该合成图是由波段 50、27 及 17 合成的。该数据集共有 16 类地物,表 5 为 Indian pines 数据集样本表。




图 9 Indian pines 数据集。(a) 伪彩色合成图; (b) 地物参考图

Fig. 9 Indian pines dataset. (a) Pseudo color composite map; (b) feature reference map

表 5 Indian pines 数据集样本表
Table 5 Indian pines dataset sample table
















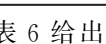
No.	Color	Class	Sample number
1		Alfalfa	46
2		Corn-notill	1428
3		Corn-min	830
4		Corn	237
5		Grass-pasture	483
6		Grass-trees	730
7		Grass-pasture-mowed	28
8		Hay-windrowed	478
9		Oats	20
10		Soybean-notill	972
11		Soybean-mintill	2455
12		Soybean-clean	593
13		Wheat	205
14		Woods	1265
15		Buildings-Grass-Trees	386
16		Stone-Steel-Towers	93
Total			10249

表 6 给出了 1D-CNN、1D-GAN、2D-CNN、3D-CNN、3D-GAN 算法和本文提出的三种算法在 Indian pines 数据集上的分类性能比较。根据表 6

表 6 8 种算法在 Indian pines 数据集上的分类性能比较

Table 6 Comparison of classification performances of eight algorithms on Indian pines dataset

Index	1D-CNN	1D-GAN	HS-1D-GAN	2D-CNN	HS-2D-GAN	3D-CNN	3D-GAN	HS-TC-GAN
OA / %	62.55	63.92	68.90	92.38	94.36	92.50	93.34	99.74
AA / %	53.29	55.94	60.28	84.87	91.12	89.78	86.80	97.52
Kappa / %	56.51	58.41	64.29	91.29	93.57	91.44	92.39	99.70
Train time / s	9.06	19.46	122.06	92.36	194.33	201.48	333.63	386.05
Test time / s	0.13	0.13	1.96	0.84	0.55	0.93	0.72	2.07
Total time / s	9.19	19.59	124.02	93.20	194.88	202.41	334.39	388.12

图 10 给出了本文 3 种算法和其他 5 种对比算法在 Indian pines 数据集上的图像分类结果。在基于光谱特征的分类算法中, HS-1D-GAN 算法与 1D-CNN、1D-GAN 算法得到的分类图像相比, 三种算法的错分都很严重, 但是仔细观察得到的分类图像(如图像的左上角)可知, HS-1D-GAN 算法的分类结果更贴近真实地物分类结果。在基于空间特征

中的数据进行分析, 在基于光谱特征的分类算法中, HS-1D-GAN 算法与 1D-CNN、1D-GAN 算法相比较, HS-1D-GAN 算法获得了最高的分类精度(与 1D-GAN 相比, OA、AA 和 Kappa 系数分别提升了 4.98%、4.34% 和 5.88%)。在基于空间特征的分类算法中, HS-2D-GAN 算法与 2D-CNN 算法相比较, HS-2D-GAN 算法的 OA、AA 和 Kappa 系数分别提升了 1.98%、6.25% 和 2.28%。在基于空谱联合特征的分类算法中, HS-TC-GAN 算法与 3D-CNN 和 3D-GAN 算法相比, HS-TC-GAN 算法的分类精度最高(与 3D-GAN 算法相比, OA、AA 和 Kappa 系数分别提升了 6.40%、10.72% 和 7.31%)。这证明了在 Indian pines 数据集中, 基于 GAN 分类算法在小训练样本的情况下也获得了比基于 CNN 分类算法更高的分类精度, 并且本文提出的算法与现有的 1D-GAN、3D-GAN 算法相比同样获得了更高的分类精度。单独比较 HS-1D-GAN、HS-2D-GAN 和 HS-TC-GAN 分类算法后, HS-TC-GAN 算法获得了最好的分类结果, HS-TC-GAN 算法比 HS-1D-GAN 算法的 OA、AA 和 Kappa 系数分别提高了 30.84%、37.24% 和 35.41%, HS-TC-GAN 算法比 HS-2D-GAN 算法的 OA、AA 和 Kappa 系数分别提高了 5.38%、6.40% 和 6.13%。在 Indian pines 数据集上比较各类算法的训练时间、测试时间和总时间后, 1D-CNN 算法的测试时间、训练时间和总时间最短。

比 2D-CNN 算法的分类结果更贴近于真实地物图像。在基于空谱联合特征的分类算法中, 与 3D-CNN 和 3D-GAN 算法相比, HS-TC-GAN 算法的分类结果几乎与真实地物图像一致, 仅有少数几个错分的点, 而 3D-CNN 和 3D-GAN 两种算法虽然与真实地物较为相近, 但是可以明显地看出错分的情况较多。同样, 单独比较本文提出的三种分类算法后, HS-TC-GAN 分类算法的分类结果从视觉




图 10 Indian pines 数据集上 8 种算法的分类结果。(a) 真实地物参考图；(b) 1D-CNN；(c) 1D-GAN；(d) HS-1D-GAN；(e) 2D-CNN；(f) HS-2D-GAN；(g) 3D-CNN；(h) 3D-GAN；(i) HS-TC-GAN

Fig. 10 Classification results of the eight algorithms on the Indian pines dataset. (a) Real feature reference map; (b) 1D-CNN; (c) 1D-GAN; (d) HS-1D-GAN; (e) 2D-CNN; (f) HS-2D-GAN; (g) 3D-CNN; (h) 3D-GAN; (i) HS-TC-GAN

角度观察是最好的,这说明在对 Indian pines 数据进行实验时,利用空谱联合特征的结果有助于提升分类精度和视觉效果。

5 结 论

针对现有高光谱图像 GAN 分类算法提取光谱特征和空谱联合特征不全面而导致的分类精度不高的问题,提出了基于双通道 GAN 的高光谱图像分类算法。首先,提出了改进的一维 GAN 分类框架和改进的二维 GAN 分类框架,并采用这两个框架分别提取高光谱图像全部的光谱特征和空间特征;其次,结合上述两种框架搭建双通道 GAN 分类框架,采用该框架将得到的光谱特征和空间特征进行

融合,并利用得到的空谱联合特征进行高光谱图像分类。实验结果表明,与其他算法相比,本文算法获得了最高的分类精度,证明了本文算法对小样本训练有效的同时,也说明了本文算法对光谱特征和空谱联合特征的提取较现有的高光谱图像 GAN 分类算法更为全面,高光谱图像的分类精度大幅度提升,验证了本文算法的先进性和有效性。

参 考 文 献

- [1] Cui Y, Xu K, Lu Z J, *et al.* Combination strategy of active learning for hyperspectral images classification [J]. *Journal on Communications*, 2018, 39 (4): 2018067.

- 崔颖, 徐凯, 陆忠军, 等. 主动学习策略融合算法在高光谱图像分类中的应用[J]. 通信学报, 2018, 39(4): 2018067.
- [2] Dong A G, Li J X, Zhang B, *et al.* Hyperspectral image classification algorithm based on spectral clustering and sparse representation[J]. Acta Optica Sinica, 2017, 37(8): 0828005.
董安国, 李佳逊, 张蓓, 等. 基于谱聚类和稀疏表示的高光谱图像分类算法[J]. 光学学报, 2017, 37(8): 0828005.
- [3] Hou B H, Yao M L, Wang R, *et al.* Spatial-spectral semi-supervised local discriminant analysis for hyperspectral image classification[J]. Acta Optica Sinica, 2017, 37(7): 0728002.
侯榜焕, 姚敏立, 王榕, 等. 面向高光谱图像分类的空谱半监督局部判别分析[J]. 光学学报, 2017, 37(7): 0728002.
- [4] Yu C Y, Zhao M, Song M P, *et al.* Hyperspectral image classification method based on targets constraint and spectral-spatial iteration[J]. Acta Optica Sinica, 2018, 38(6): 0628003.
于纯妍, 赵猛, 宋梅萍, 等. 基于目标约束与谱空迭代的高光谱图像分类方法[J]. 光学学报, 2018, 38(6): 0628003.
- [5] Chen Y S, Jiang H L, Li C Y, *et al.* Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(10): 6232-6251.
- [6] Li Y, Zhang H K, Shen Q. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network[J]. Remote Sensing, 2017, 9(1): 67.
- [7] Wu H, Prasad S. Convolutional recurrent neural networks for hyperspectral data classification[J]. Remote Sensing, 2017, 9(3): 298.
- [8] Zhao W Z, Du S H. 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.
- [9] Aptoula E, Ozdemir M C, Yanikoglu B. Deep learning with attribute profiles for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(12): 1970-1974.
- [10] Zhang H K, Li Y, Jiang Y N. Deep learning for hyperspectral imagery classification: the state of the art and prospects[J]. Acta Automatica Sinica, 2018, 44(6): 961-977.
张号逵, 李映, 姜晔楠. 深度学习在高光谱图像分类领域的研究现状与展望[J]. 自动化学报, 2018, 44(6): 961-977.
- [11] Goodfellow I J, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial nets[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems, December 8-13, 2014, Montreal, Canada. Cambridge, MA, USA: MIT Press, 2014, 2: 2672-2680.
- [12] Zhan Y, Hu D, Wang Y T, *et al.* Semisupervised hyperspectral image classification based on generative adversarial networks[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(2): 212-216.
- [13] 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.
- [14] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks[J/OL]. (2016-01-07)[2019-02-10]. <https://arxiv.org/abs/1511.06434>.
- [15] Yang S S. Research on conditional generative adversarial networks model based on VAE[D]. Changchun: Jilin University, 2018: 26-29.
杨韶晟. 基于VAE的条件生成式对抗网络模型研究[D]. 长春: 吉林大学, 2018: 26-29.
- [16] Odena A, Olah C, Shlens J. Conditional image synthesis with auxiliary classifier GANs[C]//Proceedings of the 34th International Conference on Machine Learning, August 6-11, 2017, Sydney, Australis. Massachusetts: JMLR. org, 2017: 2642-2651.
- [17] Ma X R. Hyperspectral imagery classification based on deep learning [D]. Dalian: Dalian University of Technology, 2017: 30-31.
马晓瑞. 基于深度学习的高光谱影像分类方法研究[D]. 大连: 大连理工大学, 2017: 30-31.