

# 基于 Wasserstein 距离与生成对抗网络的高光谱图像分类<sup>①</sup>



晏远翔<sup>1</sup>, 曹 国<sup>1</sup>, 张友强<sup>2</sup>

<sup>1</sup>(南京理工大学 计算机科学与工程学院, 南京 210094)

<sup>2</sup>(南京邮电大学 物联网学院, 南京 210003)

通信作者: 曹 国, E-mail: caoguo@njust.edu.cn

**摘 要:** 近年来, 基于生成对抗网络的高光谱图像分类方法取得了很大进展. 它们虽可以缓解训练样本数量有限的问题, 但是容易受到训练数据不平衡的影响, 并且存在模式崩溃问题. 针对这些问题, 提出了一种用于高光谱图像分类的 SPCA-AD-WGAN 模型. 首先, 为了解决训练数据不平衡导致分类精度降低的问题, 添加了单独的分类器, 与判别器分开训练. 其次, 将 Wasserstein 距离引入网络, 以缓解 GAN 模型崩溃的问题; 在两个 HSI 数据集上的实验结果表明, SPCA-AD-WGAN 具有更好的分类性能.

**关键词:** 高光谱图像; 生成对抗网络; 分类

引用格式: 晏远翔, 曹国, 张友强. 基于 Wasserstein 距离与生成对抗网络的高光谱图像分类. 计算机系统应用, 2024, 33(2): 13-22. <http://www.c-s-a.org.cn/1003-3254/9388.html>

## Hyperspectral Image Classification Based on Wasserstein Distance and GAN

YAN Yuan-Xiang<sup>1</sup>, CAO Guo<sup>1</sup>, ZHANG You-Qiang<sup>2</sup>

<sup>1</sup>(School of Computer Science and Engineering, Nanjing University of Technology, Nanjing 210094, China)

<sup>2</sup>(School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

**Abstract:** In recent years, significant progress has been made in the classification of hyperspectral images (HSI) based on generative adversarial nets (GAN). Although they can alleviate the problem of limited training sample size, they are easily affected by imbalanced training data and have the problem of pattern collapse. To this end, a SPCA-AD-WGAN model for HSI classification is proposed. Firstly, to address the issue of reduced classification accuracy caused by imbalanced training data, the study adds a separate classifier and trains it separately from the discriminator. Secondly, it introduces the Wasserstein distance into the network to alleviate the GAN model collapse. The experimental results on two HSI datasets indicate that SPCA-AD-WGAN has better classification performance.

**Key words:** hyperspectral image; generative adversarial network (GAN); classification

高光谱图像 (hyperspectral image, HSI) 是一种具有数百个连续光谱波段的高维图像, 既包含空间信息, 又包含丰富的光谱信息. HSI 具有识别弱信息和定量检测的优点. 随着高分辨率成像技术的不断发展, 高光谱遥感已成为 21 世纪遥感领域的重要研究方向之一. 目前, 高光谱遥感已应用于环境与灾害探测、精准农

业、地质勘探、地球资源调查<sup>[1]</sup>等领域.

近年来, 深度学习在各个领域取得了显著的成绩, 由于其能够提取高级语义特征, 因此成为高光谱图像分析的新趋势<sup>[2]</sup>. 实践证明, 深度模型能够在计算机视觉和自然语言处理任务中有效地提取不变量和判别特征. 在这些蓬勃发展的技术的启发下, 人们设计了深度

① 基金项目: 国家自然科学基金 (62201282); 江苏省自然科学基金 (BK20231456)

收稿时间: 2023-07-18; 修改时间: 2023-08-21; 采用时间: 2023-09-26; csa 在线出版时间: 2023-12-18

CNKI 网络首发时间: 2023-12-19

模型来对高光谱图像进行分类。Chen 等人<sup>[3]</sup>首次提出了一种基于深度学习的 HSI 分类方法, 并采用了一种堆叠自编码器 (SAE) 作为分类器。文献[4]中引入了深度置信网络 (DBN) 进行光谱空间信息探测。Pan 等人<sup>[5]</sup>提出了一种考虑 HSI 物理特性的顶点成分分析网络 (VCANet)。当训练样本有限时, VCANet 能够利用鉴别特征。

近年来, 卷积神经网络 (CNN) 广泛应用于图像处理和模式识别等方面。卷积神经网络在 HSI 分类中得到了广泛的应用。CNN 利用区域连接提取上下文特征, 并表现出了出色的分类性能。在文献[6]中, Zhang 等人通过一维 CNN 提取光谱特征, 通过二维 CNN 挖掘空间特征。然后结合光谱特征和空间特征进行分类。肖志云等人<sup>[7]</sup>通过改进传统的高光谱 3D 卷积方式, 获得“空谱”结合的特征, 并结合树形 Parzen 估计算法实现更高精度的分类。在文献[8]中, Gabor 滤波器与卷积滤波器相结合, 缓解了 CNN 训练中的过拟合问题。受 inception 模块<sup>[9]</sup>的启发, Gong 等人<sup>[10]</sup>提出了一种具有多尺度卷积的 CNN。多尺度滤波器组丰富了深度模型的表示能力。王雷全等人<sup>[11]</sup>利用 DenseNet 结合 3DCNN 有效地提取图像的光谱特征和空间特征。针对传统分类模型存在空间光谱特征提取不充分、计算量大的问题, 巩传江等人<sup>[12]</sup>提出了基于小波卷积网络的高光谱图像分类方法。吴鸿昊等人<sup>[13]</sup>通过基于不同尺度的双通道 3 维卷积实现更高精度的分类。

基于 CNN 的 HSI 分类方法已经取得了巨大的进展。然而, 这些分类方法的性能在很大程度上取决于训练样本的数量。通常, 从 HSI 中收集大量的训练样本是一项具有挑战性的任务。这个问题可以通过数据增强来缓解。裁剪、水平翻转、生成模型是典型的数据增强技术。近年来, 生成模型受到了广泛的关注, 因为它能够生成高质量的样本来缓解过拟合问题。Goodfellow 等人<sup>[14]</sup>设计了生成对抗网络 (GAN), 它由一个生成器和一个判别器组成。生成器捕获数据分布, 而判别器判断样本是来自生成器还是来自训练数据。生成器可以被认为是一种正则化方法, 可以在很大程度上有效地缓解过拟合问题。

研究人员努力设计基于 GAN 的模型, 以缓解高质量样本有限的问题。Zhan 等人<sup>[15]</sup>提出了一种基于 1D-GAN 的半监督框架。之后, Zhu 等人<sup>[16]</sup>提出了一种 3D-GAN 用于 HSI 分类。在考虑空间信息的基础上, 在判

别器中采用了 Softmax 分类器进行辅助分类。Feng 等人<sup>[17]</sup>提出了一种用于 HSI 分类的多类别 GAN。在多类别 GAN 中设计了两个生成器来生成高光谱图像补丁, 并设计了一个判别器来输出多类别概率。Zhong 等人<sup>[18]</sup>将 GAN 和条件随机场 (CRF) 集成在一起, 其中密集的 CRF 对 GAN 的判别器施加图约束, 以细化分类结果。

尽管这些基于 GAN 的模型取得了令人满意的效果, 但是, 高光谱图像分类仍然存在两个急需解决的缺陷。

第 1 个挑战是训练数据的不平衡。当可用的训练样本在不同类别之间分布不均匀时, 分类的准确性可能会下降。然而, 不平衡的训练数据问题是 HSI 的基本问题, 因为在特定场景中存在不同大小的对象<sup>[19]</sup>。在 Zhu 等人<sup>[16]</sup>的工作中, 使用辅助分类器 GAN (ACGAN)<sup>[20]</sup>进行 HSI 分类。在 ACGAN 中, 判别器有两个输出: 一个是区分真假样本, 另一个是对样本进行分类。ACGAN 能够产生特定类别的样本。在实际应用中, 在生成少数类样本时, 可以观察到判别器的两个损失函数存在缺陷。出现这种现象的原因是, 当少数类样本被传递给判别器时, 它们很可能被分配到假标签。因此, 判别器试图将假标签与少数类样本相关联。此时, 生成器生成看起来真实但不代表少数类的样本。生成的样本质量变差, 从而影响分类性能。

另一个关键问题是模式崩溃。生成器通过只产生来自相同数据模式的数据来欺骗判别器<sup>[21]</sup>。它导致产生了一个只能在数据空间的狭窄范围内生成样本的生成器, 因此, 生成的样本过于相似, 模型无法学习到真实的数据分布, 模型很难学习到完整的数据分布。模型崩溃可以被认为是判别器反馈的过拟合的结果。

本文针对以上问题做了相关研究, 主要工作如下。

(1) 提出了一种改进的基于 GAN 网络的 HSI 图像分类方法, 该方法将 Wasserstein 距离引入 ADGAN 网络, 用以缓解训练数据的不平衡以及模型崩溃的问题。

(2) 运用 SPCA 方法对高光谱数据进行降维, 进而提高对高光谱图像的分类精度。

(3) 本文 GAN 网络中设计了独立的分类器用于提升分类性能, 并通过大量实验证明了本文方法的有效性。

## 1 相关工作

在原始 GAN 网络中, 判别器只判断输入样本的真假, 不适合多类图像分类。Wang 等人<sup>[22]</sup>提出了 ADGAN

(adaptive drop block enhanced GANs). 在 ADGAN 中, 判别器  $D$  是一个 Softmax 分类器, 可以输出多种类别的标签概率.

ADGAN 框架如图 1 所示. 通过 PCA<sup>[23]</sup> 将输入 HSI 的光谱波段数减少到 3 个分量, 这可以极大地降低计算复杂度, 有助于训练一个健壮的生成器  $G$ . 生成器  $G$  的输入包括噪声  $z$  和类别标签  $c$ , 输出匹配所需类别标签的图像块; 判别器  $D$  接收到来自真实数据中图像

块  $X_{\text{real}}$  和生成器生成的假图像块  $X_{\text{fake}}=G(z)$ . 与 ACGAN 不同, 判别器  $D$  只有一个单一的输出, 即返回特定的类别  $c$  或假标签. 为此, 训练判别器  $D$  以使以下的对数似然值最大化, 如下所示:

$$L_D = E[\log P(C = c|X_{\text{real}})] + E[\log P(C = \text{fake}|X_{\text{fake}})] \quad (1)$$

其中,  $C$  表示判别器  $D$  的输出,  $X_{\text{real}}$  和  $X_{\text{fake}}$  分别代表来自真实数据的图像与生成的图像.

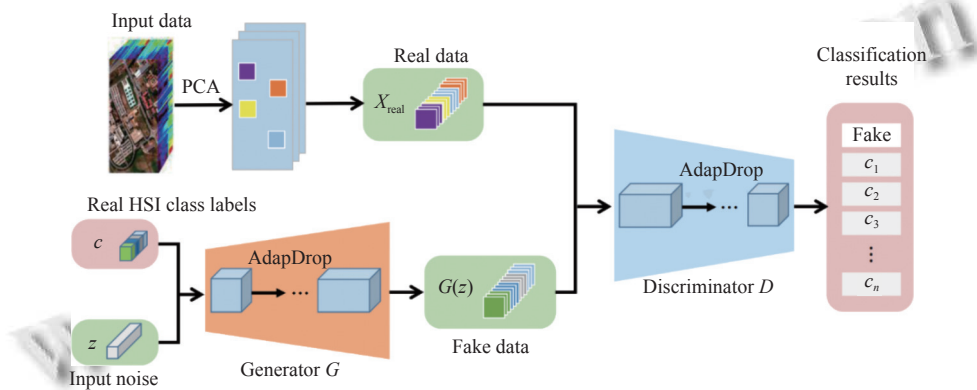


图 1 ADGAN 结构图<sup>[22]</sup>

对生成器  $G$  进行训练, 使以下的对数似然值最大化, 如下所示:

$$L_G = E[\log P(C = c|X_{\text{fake}})] \quad (2)$$

## 2 提出的 SPCA-AD-WGAN 方法

### 2.1 SPCA-AD-WGAN 总体框架

如何利用有限数据样本的丰富特征来提高分类精度是 HSI 分类研究的一个热点. 为了更好地利用 HSI 的丰富特征, 同时利用 Wasserstein 距离来缓解 GAN 网络中存在的模式崩溃问题, 本文在 ADGAN 方法的基础上进行了改进, 提出了新的 SPCA-AD-WGAN 方法用于 HSI 分类, 框架如图 2 所示.

由于高光谱图像包含数百个波段, 波段之间存在大量冗余, 生成器难以模拟真实数据, 无法获得具有鲁棒性的生成器. 因此, 本文首先通过 SPCA 方法对输入的 HSI 图像进行降维, 降低计算复杂度, 提取更多的低维有效数据来训练网络. 同时, 本文将 ADGAN 网络中, 判别器判断图像真假与为图像分类标签的任务分开进行. 判别器  $D$  只负责判断图像的真假; 使用单独的辅助分类器  $C$ , 用于分辨图像类别. 这样, 判别器与分类器分别完成两个不同的任务. 生成器  $G$  与判别器

$D$  之间通过基于 Wasserstein 距离的 GAN 网络进行训练. 网络通过引入 Wasserstein 距离来缓解模式崩溃问题; 同时判别器的训练结果也会作用于分类器的训练过程, 帮助分类器提高分类精度. 判别器与分类器将结果反馈给生成器. 生成器继续生成图像, 直到判别器不能再区分它为止; 同时, 分类器对图像类别的判断精度也在不断提高. 然后, 通过循环训练网络, 就可以获得理想的 HSI 分类精度.

### 2.2 AD-WGAN 框架

在 ADGAN 网络中, 判别器  $D$  用来给输入的图像块分配标签. 当图像是来源于训练集的真实图像时, 判别器希望输出符合原标签的类别信息; 当图像是生成器  $G$  生成的假图像时, 判别器希望将假图像的标签信息与单独添加的类别——“fake”类别联系在一起. 对于 GAN 网络可能产生的模式崩溃现象, ADGAN 网络使用了自适应的 DropBlock 方法来缓解这一问题. 然而 DropBlock 方法本身存在一定的不足: DropBlock 方法会丢弃特征图中连续区域的单元, 从而可能会丢失一些重要的特征信息. 因此, 虽然 DropBlock 方法可以在一定程度上缓解模式崩溃问题, 但是某些特征信息的丢失也会可能影响网络对高光谱图像的分类精度. 本文希望从网络结构的角上缓解模式崩溃问题: 将

Wasserstein GAN 对于原始 GAN 网络损失函数的更新引入 ADGAN 网络, 并且设立单独的判别器用以改善

原始网络训练不稳定以及模式崩溃的问题, 进而提高对高光谱图像的分类精度。

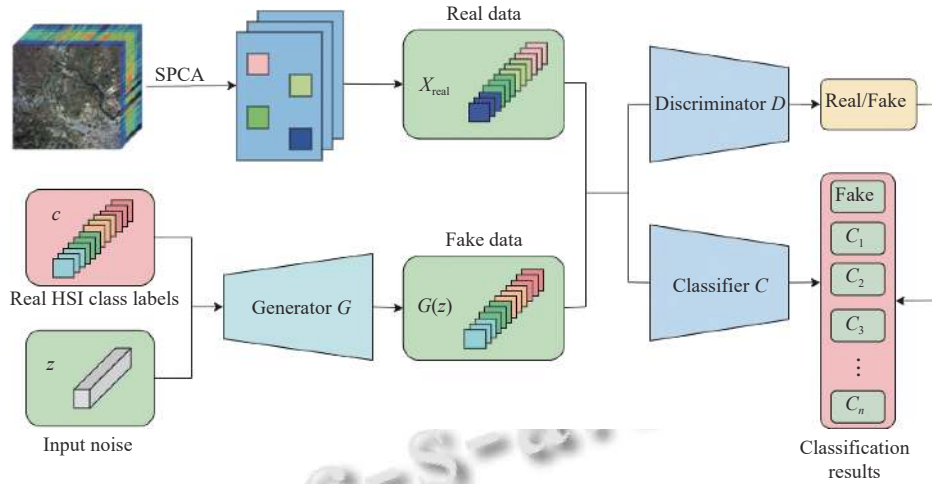


图2 SPCA-AD-WGAN 结构图

在原始的 GAN 网络中, 当判别器被训练到最优时, 其表达式如下:

$$D^*(x) = \frac{P_r(x)}{P_r(x) + P_g(x)} \quad (3)$$

其中,  $P_r(x)$  代表真实数据的分布,  $P_g(x)$  代表生成的数据的分布. 将式 (3) 代入 GAN 网络的目标函数, 并结合 JS 散度的表达式, 即可得到最优判别器下的 GAN 网络目标函数:

$$2JS(P_r||P_g) - \log 2 \quad (4)$$

即当判别器训练到最优时, 原始 GAN 网络定义的生成器 loss 等价变换为最小化真实分布  $P_r$  与生成分布  $P_g$  之间的 JS 散度. 然而当生成器产生的样本分布与真实样本分布有重叠部分较小或二者没有重叠部分时, JS 散度会等于一个恒定值. 在这种情况下判别器会出现饱和状态, 即所有生成的样本都被判别为假样本. 在这种情况下, 生成器无法得到有效的反馈信号, 导致生成器无法学习到真实分布的信息, 从而陷入模式崩溃的状态. Wasserstein GAN 网络通过将 Wasserstein 距离代替 JS 散度, 在样本分布与真实样本分布有重叠部分较小或二者没有重叠部分时仍然可以判断两个分布之间的差异. 本文通过使用 Wasserstein 距离的方式来缓解模式崩溃问题. 在得到近似最优判别器  $D$  的前提下, 优化生成器  $G$  减小 Wasserstein 距离, 可以有效缩短生成图像的分布与真实图像分布之间的距离. 改进之后的目标函数如式 (5):

$$\min_G \max_D E_{x \sim P_r} [D(x)] + E_{\tilde{x} \sim P_g} [D(\tilde{x})] \quad (5)$$

其中,  $x$  表示符合真实分布的样本;  $\tilde{x}$  表示符合生成分布的样本.  $D(x)$  表示判别器  $D$  的输出, 代表  $x$  样本为真的概率.  $P_r$  与  $P_g$  分别代表真实图像分布与生成图像的分布. 在 AD-WGAN 中, 生成器的任务是生成不同类别的样本, 这是一个难以控制的问题. 因此, 需要在目标函数中加入类别正确的约束. 为了加强生成器从不同类别中学习并生成样本的能力, 本文单独使用辅助分类器  $C$  用于为样本的标签进行分类. 判别器则专注于判断图片样本是真实的数据还是来源于生成器生成的数据; 判别器的结果也会帮助分类器进行训练.  $C$  的损失函数分为两部分. 首先, 对判别器判断为真实的图像, 分类器  $C$  输出图像类别标签; 对判别器鉴定为假的图像, 分类器  $C$  则将图像与假标签相关联.

判别器  $D$  的输入由真实图像的 patch 块、带有类别标签的生成的假样本  $X_{fake}$  组成,  $D$  的输出是一个概率分布  $D(x)$ . 判别器的作用是判断样品的真假. 设计  $D$  和  $C$  的目的是为 AD-WGAN 的每个部分分配一个特定的任务.

### 2.2.1 生成器结构

生成器  $G$  接受随机高斯噪声  $z$  作为输入. 在谱域中用 3 个波段将噪声变换为与真实输入数据相同的大小. 本文使用的生成器的结构如图 3 所示. 生成器使用 5 层上采样的 2D 转置卷积, 将  $100 \times 1 \times 1$  的噪声向量与类别标签  $c$  作为输入, 输出  $3 \times 64 \times 64$  的图像块. 然后这

些带有标签的图像块将会和真实图像一起送入判别器与分类器进行训练。




图3 生成器结构图

生成器的目标函数由两部分组成. 一部分来自于判别器  $D$ , 它保证了判别器不会识别由生成器产生的样本. 另一部分来自分类器  $C$ , 它保证了生成器生成的样本最大程度地属于相应的类别. 第2部分强化了类别信息和生成样本之间的联系. 因此, 这两部分之和构成了生成器  $G$  的目标函数:

$$L_G = E_{\tilde{x} \sim P_g} [D(\tilde{x})] + E[\log P(C = c | X_{\text{fake}})] \quad (6)$$

### 2.2.2 判别器结构

判别器  $D$  的结构如图4所示. 判别器  $D$  接受来自训练集中的图像块或生成的图像块作为输入, 输出这些图像块为真的概率分布. 输入图像进入判别器  $D$  后, 经过5层下采样卷积, 将  $3 \times 64 \times 64$  输入样本转换为  $128 \times 1 \times 1$  的数据, 最后经过全连接层, 输出图像为真的概率.




图4 判别器结构图

判别器  $D$  的作用是判断图像的真假, 再结合 Wasserstein 距离对网络损失的更新, 判别器  $D$  的目标函数为:

$$L_D = E_{x \sim P_r} [D(x)] - E_{\tilde{x} \sim P_g} [D(\tilde{x})] \quad (7)$$

### 2.2.3 分类器结构

分类器  $C$  的结构如图5所示. 其中,  $N$  表示数据集中的类别数量. 分类器  $C$  与判别器拥有相同的输入. 对判别器判断为真实的图像, 分类器输出图像类别标签; 对判别器鉴定为假的图像, 分类器则将图像与假标签相关联. 输入分类器的图像首先经过5层下采样的2D卷积层, 然后经过全连接层, 输出每个图像的类别.




图5 分类器结构图

分类器  $C$  的作用是输出每个图像的类别标签, 其目标函数如下:

$$L_C = E_{x \sim P_r} [\log P(C = c | D = \text{real})] + E_{x \sim P_g} [\log P(C = \text{fake} | D = \text{fake})] \quad (8)$$

## 2.3 SPCA 方法

HSI 数据的高维特性带来了维数灾难和数据传输存储的负担. 因此, HSI 预处理步骤中广泛采用降维技术来缓解这些问题, 同时将重要的信息保存在低维空间中. 在文献[24]中, Jiang 等人开发了一种基于多尺度分割的 SuperPCA 模型, 用于高光谱图像分类. 本文使用基于超像素的图像分割将观察到的图像分割成许多不同的区域, 并且认为其中每个区域中的光谱特征是相似的. 对分割后的区域单独进行 PCA 降维, 然后再把这些区域拼接起来, 组合成降维后的图像. SPCA 的结构如图6所示. 首先通过超像素分割将一个  $L \times M \times N$  的原始高光谱图像划分为许多个区域. 将这些区域用矩阵表示, 矩阵的列是像素的光谱向量. 分别对这些高维矩阵进行 PCA 降维, 得到降维矩阵. 降维后矩阵的列  $d < L$ . 最后, 对这些低维矩阵进行重新排列和组合, 形成降维后的高光谱图像.




图6 基于 SuperPCA 的 HIS 降维<sup>[24]</sup>

## 3 实验分析

### 3.1 实验数据集

本文使用两个具有代表性的高光谱遥感图像数据集: Indian Pines 数据集、Pavia University 数据集分别作为实验数据进行实验.

#### 3.1.1 Indian Pines 数据集

Indian Pines 数据集包括 1992 年美国印第安纳州

西北部的农业和森林地区的高光谱图像, 该数据集由利用机载可见/红外成像光谱仪 (AVIRIS) 的遥感设备收集. 数据集中的图像为 145×145 像素, 其空间分辨率为 20 m/像素. Indian Pines 数据集包含 220 个光谱波段, 其中去除了 20 个严重吸水波段, 本文对剩下的 200 个光谱波段进行了实验. 伪彩色合成图像和 ground truth 图像如图 7 所示.



图 7 Indian Pines 伪彩色合成图与真值图

### 3.1.2 Pavia University 数据集

Pavia University 数据集由反射光学系统成像光谱仪 (ROSIS) 传感器在意大利帕维亚大学收集. 该图像大小为 610×340 像素, 包含 430–860 nm 波长范围内的 103 个光谱带. 假彩色图像和地面真值如图 8 所示, 其中包含 9 个具有代表性的城市类别.

### 3.2 实验设置

为了验证所提出的 SPCA-AD-WGAN 的性能, 本文将其与 2DCNN<sup>[25]</sup>、3DCNN<sup>[26]</sup>、3DGAN<sup>[16]</sup>、ADGAN<sup>[22]</sup>、patch-wise SpectralFormer (SpectralFormer)<sup>[27]</sup> 进行了比较. 为了保证实验结果的公正性, 所有方法使用相同的训练集. 所有的实验结果都是通过随机分割训练集和测试集得到的. 在 Indian Pines 数据集中随机选择 307 个训练样本; 在 Pavia University 数据集中随机选择 1000 个训练样本, 拥有很小比例的训练集被用于模拟带有少量标记样本的场景. 对于只有一个样本的类别, 进行重采样等数据增强操作, 方法与文献[17]相同. 结果独立运行超过 15 次. 所有方法按照默认最优参数, 使用 PCA 的前 3 个主成分作为输入.

所有测试样本都有 3 个评价标准, 包括总体准确率 (OA)、平均准确率 (AA) 和 Kappa 系数.

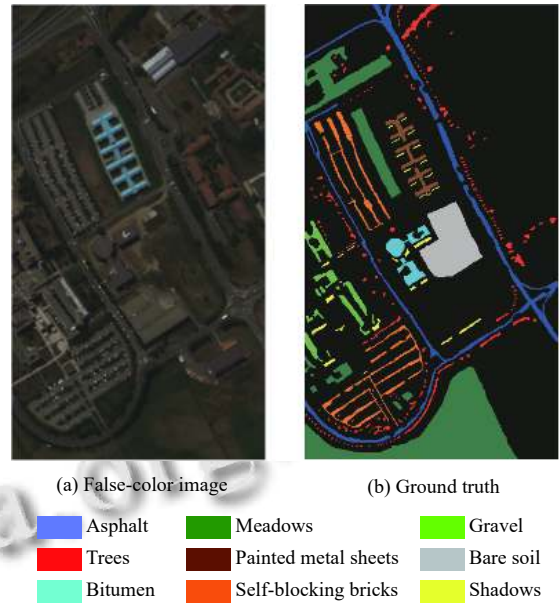


图 8 Pavia University 伪彩色合成图与真值图

总体准确率表示被正确分类的测试样本数在所有测试样本数中的比率; 平均准确率表示所有类别分类精度的平均值; Kappa 系数表示测试样本的分类预测类别与实际类别的一致性检测指标系数. 具体计算公式如下:

$$OA = \frac{\sum_{i=1}^K P(i, i)}{N} \quad (9)$$

$$AA = \frac{\sum_{i=1}^K OA(i)}{K} \quad (10)$$

$$Kappa = \frac{N \sum_{i=1}^K P(i, i) - \sum_{i=1}^K P(i, \cdot)P(\cdot, i)}{N^2 - \sum_{i=1}^K P(i, \cdot)P(\cdot, i)} \quad (11)$$

其中,  $K$  表示类别数;  $N$  表示测试样本总个数;  $P(i, i)$  表示第  $i$  类被正确分类;  $OA(i)$  表示第  $i$  类的总分类精度;  $P(i, \cdot)$  和  $P(\cdot, i)$  分别表示第  $i$  行和第  $i$  列的总测试样本数.

对于 ADGAN 和 SpectralFormer, 使用提供的源代码, 默认最优参数参见文献[22,27]. 对于 3DGAN, 使用大小为 64×64 的邻域, 将输入图像归一化到[-0.5, 0.5] 的范围内. 其他比较方法的实验设置都是在文献[25] 的基础上, 按主成分分析法个数进行设置. 对于本文提

出的 SPCA-AD-WGAN, 判别器  $D$  与生成器  $C$  的模型参数使用 RMSprop 优化器进行优化; 分类器  $C$  使用 Adam 优化器进行优化. 对于两个数据集, epoch 个数设置为 500 个, 学习率设置为 0.0002, 图像块的大小设置为  $64 \times 64$ .

### 3.3 实验结果

本文在 Indian Pines 数据集中随机选择 307 个训练样本 (具体见表 1), 在 Pavia University 数据集中随机选择 1000 个训练样本 (具体见表 2). 表 3、表 4 分别记录了比较算法和本文提出的 SPCA-AD-WGAN 方法在两个数据集上的平均分类精度和相应的标准差. 表格的前几行表示每个类别的结果, 后 3 行分别是  $OA$ 、 $AA$  和  $Kappa$  系数的结果.

#### 3.3.1 Indian Pines 数据集实验结果

Indian Pines 数据集的训练和测试样本数量见表 1. 表 3 显示了 Indian Pines 数据集的分类结果. 图 9 显示了各类方法在 Indian Pines 数据集上的分类效果. 本文提出的方法  $OA$  达到了 91.74%,  $AA$  达到了 83.77%,  $Kappa$  系数为 90.79%. 相比较于总体分类精度较好的 ADGAN 网络, 本文提出的方法在  $AA$ 、 $OA$ 、 $Kappa$  系数 3 个方面分别高出 1.52%、4.61%、0.66%. 本文提出的 SPCA-AD-WGAN 在 16 个类别中有 10 个类别的准确率最高. 这说明本文提出的方法在总体分类精度方面取得了最好的效果.

表 1 Indian Pines 数据集中的训练和测试像素的个数

No.	Class	Training	Testing
1	Alfalfa	1	45
2	Corn notill	43	1385
3	Corn mintill	25	805
4	Corn	7	230
5	Grass pasture	14	469
6	Grass trees	22	708
7	Grass pasture mowed	1	27
8	Hay windrowed	14	464
9	Oats	1	19
10	Soybean notill	29	943
11	Soybean mintill	73	2382
12	Soybean clean	18	575
13	Wheat	6	199
14	Woods	38	1227
15	Buildings grass trees	12	374
16	Stone steel towers	3	90
Total		307	9942

表 2 Pavia University 数据集中的训练和测试像素的个数

No.	Class	Training	Testing
1	Asphalt	155	6476
2	Meadows	436	18213
3	Gravel	49	2050
4	Trees	72	2992
5	Painted metal sheets	31	1314
6	Bare soil	118	4911
7	Bitumen	31	1299
8	Self-blocking bricks	86	3596
9	Shadows	22	925
Total		1000	41776

表 3 Indian Pines 数据集分类精度 (%)

Class	2DCNN	3DCNN	3DGAN	SpectralFormer	ADGAN	Proposed
Alfalfa	22.22±9.36	20.49±7.89	32.32±16.4	1.11±2.13	49.65±33.4	<b>53.33±25.6</b>
Corn notill	69.45±4.67	59.03±6.66	79.57±3.97	45.60±3.54	87.30±5.43	<b>88.94±3.95</b>
Corn mintill	73.91±8.55	58.72±7.79	86.49±6.24	39.95±4.50	87.96±5.88	<b>88.23±5.41</b>
Corn	43.53±8.53	34.44±5.18	84.03±10.8	14.96±4.25	84.88±8.57	<b>86.76±5.96</b>
Grass pasture	68.66±11.7	51.24±9.70	84.34±6.53	27.49±10.2	87.98±9.23	<b>89.12±8.14</b>
Grass trees	90.73±4.27	84.15±11.9	89.84±1.29	86.09±5.91	<b>93.39±2.96</b>	93.19±2.69
Grass pasture mowed	47.69±20.0	19.75±7.81	51.52±27.0	4.63±5.04	31.48±43.0	<b>60.87±26.9</b>
Hay windrowed	93.56±4.38	97.24±3.36	96.53±1.3	95.83±2.27	<b>97.28±4.22</b>	96.98±4.01
Oats	43.42±14.6	27.48±13.1	50.24±15.1	15.34±15.0	27.63±38.0	<b>57.89±21.5</b>
Soybean notill	79.24±1.85	63.00±13.9	85.32±5.90	65.67±4.48	<b>93.37±3.53</b>	92.37±3.74
Soybean mintill	86.07±3.54	80.95±7.32	93.21±2.46	69.62±3.38	<b>95.52±2.74</b>	94.63±3.03
Soybean clean	62.57±7.28	48.44±9.26	69.47±10.8	30.97±8.04	86.18±5.88	<b>88.35±5.41</b>
Wheat	86.18±10.4	80.91±9.68	82.64±6.64	<b>85.22±8.72</b>	84.44±19.8	84.92±15.7
Woods	95.31±2.06	83.60±11.7	95.38±2.76	88.96±4.67	97.38±1.89	<b>97.41±1.79</b>
Buildings grass trees	82.59±5.06	58.73±7.88	82.36±8.60	36.92±9.04	87.80±7.90	<b>89.78±6.58</b>
Stone steel towers	77.50±11.4	47.41±18.1	63.53±15.8	<b>87.87±10.9</b>	74.27±23.7	77.61±19.6
$OA$	80.10±1.34	69.67±3.80	86.84±2.00	61.44±1.31	90.21±1.33	<b>91.74±1.42</b>
$AA$	70.16±2.28	57.23±3.16	76.67±3.24	49.76±1.38	79.16±4.14	<b>83.77±3.51</b>
$Kappa$	77.25±1.51	65.07±4.36	84.97±2.26	55.77±1.48	90.13±1.21	<b>90.79±1.19</b>

在训练样本较少的类别如 Alfalfa、Corn、Grass pasture mowed 和 Oats, 本文提出的方法取得了最好分

类精度, 分别达到了 53.33%、86.76%、60.87%、57.89%. 比较于其他的分类方法, 分别提高了 3.68%、1.88%、

9.35%、7.65%; 相比较于 ADGAN 网络, 在样本较少的类别上的分类精度都有较大幅度的提升. 这表明, 在样本数量较少的类别, 生成器依然可以生成多样化的样本, 而不是只生成数量较多类别的样本. 这说明本方法可以学习到这些样本的本质特征, 在训练样本较少的类别中也能生成高质量的 HSI 样本. 这说明模式崩溃问题得到了缓解.

### 3.3.2 Pavia University 数据集实验结果

Pavia University 数据集的训练和测试样本数量见表 2. 表 4 显示了 Pavia University 数据集的分类结果. 图 10 显示了各类方法在 Pavia University 数据集上的分类效果. 本文提出的方法 OA 达到了 96.89%, AA 达到了 95.76%, Kappa 系数为 96.34%. 相比较于总体分类

精度较好的 ADGAN 网络, 本文提出的方法在 AA、OA、Kappa 系数 3 个方面分别高出 1.51%、1.05%、1.13%. 总体而言, 本文提出的方法取得了较好的分类精度.

在训练样本较少的类别 (如 Bitumen), 除了 3DGAN 网络, 其他的方法都低于 89%; 而本文提出的方法取得了最高的分类精度. 相比较于 ADGAN 网络, 在样本较少的类别上的分类精度都有比较明显的提升. 这表明, 对于 Pavia University 数据集中样本数量较少的类别, 生成器依然可以生成多样化的样本, 而不是只生成数量较多类别的样本. 结合两个数据集上本文提出的方法在训练样本较少的类上的表现, 说明提出的方法可以学习到这些样本的本质特征, 即使在训练样本较少的类别中也能生成高质量的 HSI 样本, 有效缓解了模式崩溃的问题.

表 4 Pavia University 数据集分类精度 (%)

Class	2DCNN	3DCNN	3DGAN	SpectralFormer	ADGAN	Proposed
Asphalt	95.53±2.06	<b>96.10±0.84</b>	93.98±0.51	87.40±2.84	92.36±1.33	94.57±0.94
Meadows	98.33±1.16	98.75±0.48	<b>99.44±0.08</b>	96.71±1.65	96.18±0.45	96.34±0.54
Gravel	82.15±4.63	83.87±3.15	78.16±3.18	66.54±6.07	91.49±1.45	<b>92.51±1.17</b>
Trees	97.09±1.13	<b>97.58±0.72</b>	84.91±1.22	92.61±2.54	97.29±0.25	97.13±0.31
Painted metal sheets	97.65±5.79	99.95±0.06	99.27±0.33	<b>100.00±0.0</b>	98.54±0.16	98.67±0.19
Bare soil	84.69±11.7	86.72±4.34	96.81±0.67	29.63±8.53	96.37±0.27	<b>96.94±0.26</b>
Bitumen	85.41±4.68	82.47±3.17	92.28±2.50	42.46±20.0	88.40±1.54	<b>92.82±1.13</b>
Self-blocking bricks	95.53±2.93	94.24±0.91	92.47±1.59	86.13±3.0	<b>95.75±1.25</b>	95.59±1.35
Shadows	90.77±11.2	97.10±2.01	80.03±4.04	95.96±3.18	96.02±0.26	<b>97.34±0.29</b>
OA	94.58±1.76	95.22±0.44	94.94±0.32	83.10±0.86	95.38±0.54	<b>96.89±0.39</b>
AA	91.91±1.98	92.98±0.83	90.82±0.85	77.49±2.92	94.71±0.35	<b>95.76±0.33</b>
Kappa	92.77±2.41	93.62±0.61	93.92±0.76	76.85±1.31	95.21±0.41	<b>96.34±0.27</b>

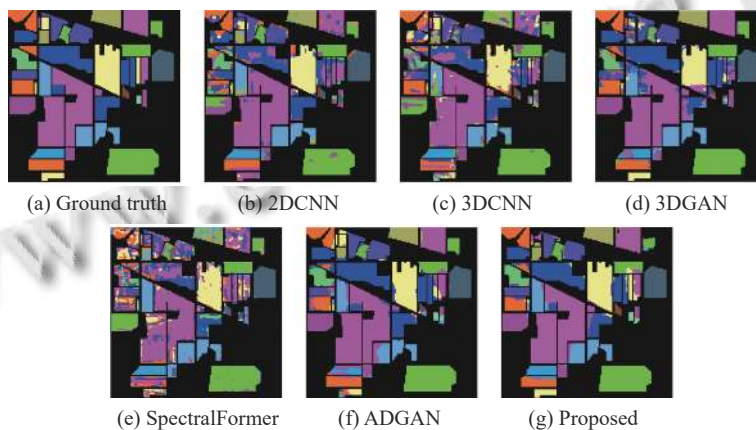


图 9 Indian Pines 数据集分类效果图

### 3.4 消融实验

在消融实验部分, 本文将分别验证模型中的提出方法的有效性. 实验将本文模型与 3 个模型进行比较, 分别是: 1) ADGAN; 2) AD-WGAN, 在 ADGAN 的基础上引入 Wasserstein 距离; 3) SPCA-ADGAN, 是指在

ADGAN 的基础上运用 SPCA 方法对数据进行降维; 4) SPCA-AD-WGAN. 本次所有的消融实验均在 Indian Pines 与 Pavia University 两个数据集上进行, 参数设置与实验过程保持一致.

表 5、表 6 分别是不同的方法在两个数据集上的



分类效果对比. 通过实验结果可以发现, 在 Pavia University 数据集上 AD-WGAN 在  $OA$ 、 $AA$ 、 $Kappa$  系数 3 个方面对比原方法分别提升了 0.65%、0.59%、0.70%; SPCA-ADGAN 在  $OA$ 、 $AA$ 、 $Kappa$  系数 3 个方面对比原方法分别提升了 0.46%、0.22%、0.11%; 在 Indian Pines 数据集上 AD-WGAN 在  $OA$ 、 $AA$ 、

$Kappa$  系数 3 个方面对比原方法分别提升了 0.98%、2.21%、0.54%; SPCA-ADGAN 在  $OA$ 、 $AA$ 、 $Kappa$  系数 3 个方面对比原方法分别提升了 0.33%、0.90%、0.18%. 这说明了本文提出的方法的有效性. 同时, 通过 SPCA-ADGAN 与 AD-WGAN 的比较, 可以发现引入 Wasserstein 距离对分类结果的提升效果更加显著.




图 10 Pavia University 数据集分类效果图

表 5 Indian Pines 数据集消融实验对比 (%)

方法	$OA$	$AA$	$Kappa$
ADGAN	90.21	79.16	90.13
AD-WGAN	91.19	81.37	90.67
SPCA-ADGAN	90.54	80.06	90.31
SPCA-AD-WGAN	91.74	83.77	90.79

表 6 Indian Pines 数据集消融实验对比 (%)

方法	$OA$	$AA$	$Kappa$
ADGAN	95.38	94.71	95.21
AD-WGAN	96.03	95.32	95.91
SPCA-ADGAN	95.84	94.93	95.36
SPCA-AD-WGAN	96.89	95.76	96.34

## 4 结论

本文提出了一种用于 HSI 分类的 SPCA-AD-WGAN 模型方法. 该方法使用 SPCA 方法将高光谱数据集进行降维; 在 ADGAN 网络的基础上, 引入了单独的分类器, 用于样本的分类任务; 同时, 将 Wasserstein 距离引入模型, 更新判别器与生成器的损失, 缓解 GAN 网络存在的模式崩塌问题, 进而提高对高光谱图像的分类精度. 在 Indian Pines、Pavia University 两个高光谱数据集上进行了实验. 结果表明, 本文提出的方法与 2DCNN、3DCNN、3DGAN、SpectralFormer、ADGAN 相比, 提出的方法总体获得了更高的分类精度, 在样本数量较少的类别也取得了较好的结果, 证明了本文提出方法的有效性.

## 参考文献

- Audebert N, Le Saux B, Lefèvre S. Deep learning for classification of hyperspectral data: A comparative review. *IEEE Geoscience and Remote Sensing Magazine*, 2019, 7(2): 159–173. [doi: [10.1109/MGRS.2019.2912563](https://doi.org/10.1109/MGRS.2019.2912563)]
- 覃寓媛, 佃松宜. 多尺度 3D 胶囊网络高光谱图像分类. *计算机系统应用*, 2022, 31(12): 220–226. [doi: [10.15888/j.cnki.csa.008837](https://doi.org/10.15888/j.cnki.csa.008837)]
- Chen YS, Lin ZH, Zhao X, *et al.* Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2094–2107. [doi: [10.1109/JSTARS.2014.2329330](https://doi.org/10.1109/JSTARS.2014.2329330)]
- Chen YS, Zhao X, Jia XP. Spectral-spatial classification of hyperspectral data based on deep belief network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2381–2392. [doi: [10.1109/JSTARS.2015.2388577](https://doi.org/10.1109/JSTARS.2015.2388577)]
- Pan B, Shi ZW, Xu X. R-VCANet: A new deep-learning-based hyperspectral image classification method. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(5): 1975–1986. [doi: [10.1109/JSTARS.2017.2655516](https://doi.org/10.1109/JSTARS.2017.2655516)]
- Zhang HK, Li Y, Zhang YZ, *et al.* Spectral-spatial classification of hyperspectral imagery using a dual-channel convolutional neural network. *Remote Sensing Letters*, 2017, 8(5): 438–447. [doi: [10.1080/2150704X.2017.1280200](https://doi.org/10.1080/2150704X.2017.1280200)]
- 肖志云, 蒋家旭, 倪晨. 自适应深层残差 3D-CNN 高光谱图像快速分类算法. *计算机辅助设计与图形学学报*, 2019, 31(11): 2017–2029. [doi: [10.3724/SP.J.1089.2019.17552](https://doi.org/10.3724/SP.J.1089.2019.17552)]
- Chen YS, Zhu L, Ghamisi P, *et al.* Hyperspectral images

- classification with Gabor filtering and convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(12): 2355–2359. [doi: [10.1109/LGRS.2017.2764915](https://doi.org/10.1109/LGRS.2017.2764915)]
- 9 Szegedy C, Liu W, Jia YQ, *et al.* Going deeper with convolutions. *Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015. 1–9.
- 10 Gong ZQ, Zhong P, Yu Y, *et al.* A CNN with multiscale convolution and diversified metric for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(6): 3599–3618. [doi: [10.1109/TGRS.2018.2886022](https://doi.org/10.1109/TGRS.2018.2886022)]
- 11 王雷全, 周家梁, 林瑶. 基于全局注意力信息交互的高光谱图像分类. *计算机系统应用*, 2023, 32(5): 28–35. [doi: [10.15888/j.cnki.csa.009120](https://doi.org/10.15888/j.cnki.csa.009120)]
- 12 巩传江, 臧德厚, 郭金, 等. 基于小波卷积网络的高光谱图像分类. *计算机系统应用*, 2023, 32(7): 23–34. [doi: [10.15888/j.cnki.csa.009186](https://doi.org/10.15888/j.cnki.csa.009186)]
- 13 吴鸿昊, 王立国, 石瑶. 高光谱图像小样本分类的卷积神经网络方法. *中国图象图形学报*, 2021, 26(8): 2009–2020. [doi: [10.11834/jig.210103](https://doi.org/10.11834/jig.210103)]
- 14 Goodfellow I, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial networks. *Communications of the ACM*, 2020, 63(11): 139–144. [doi: [10.1145/3422622](https://doi.org/10.1145/3422622)]
- 15 Zhan Y, Hu D, Wang YT, *et al.* Semisupervised hyperspectral image classification based on generative adversarial networks. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(2): 212–216. [doi: [10.1109/LGRS.2017.2780890](https://doi.org/10.1109/LGRS.2017.2780890)]
- 16 Zhu L, Chen YS, Ghamisi P, *et al.* Generative adversarial networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(9): 5046–5063. [doi: [10.1109/TGRS.2018.2805286](https://doi.org/10.1109/TGRS.2018.2805286)]
- 17 Feng J, Yu HP, Wang L, *et al.* Classification of hyperspectral images based on multiclass spatial-spectral generative adversarial networks. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(8): 5329–5343. [doi: [10.1109/TGRS.2019.2899057](https://doi.org/10.1109/TGRS.2019.2899057)]
- 18 Zhong ZL, Li J, Clausi DA, *et al.* Generative adversarial networks and conditional random fields for hyperspectral image classification. *IEEE Transactions on Cybernetics*, 2020, 50(7): 3318–3329. [doi: [10.1109/TCYB.2019.2915094](https://doi.org/10.1109/TCYB.2019.2915094)]
- 19 Li JJ, Du Q, Li YS, *et al.* Hyperspectral image classification with imbalanced data based on orthogonal complement subspace projection. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(7): 3838–3851. [doi: [10.1109/TGRS.2018.2813366](https://doi.org/10.1109/TGRS.2018.2813366)]
- 20 Odena A, Olah C, Shlens J. Conditional image synthesis with auxiliary classifier GANs. *Proceedings of the 34th International Conference on Machine Learning*. Sydney: JMLR.org, 2017. 2642–2651.
- 21 Chavdarova T, Fleuret F. SGAN: An alternative training of generative adversarial networks. *Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake: IEEE, 2018. 9407–9415.
- 22 Wang JJ, Gao F, Dong JY, *et al.* Adaptive DropBlock-enhanced generative adversarial networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(6): 5040–5053. [doi: [10.1109/TGRS.2020.3015843](https://doi.org/10.1109/TGRS.2020.3015843)]
- 23 Licciardi G, Marpu PR, Chanussot J, *et al.* Linear versus nonlinear PCA for the classification of hyperspectral data based on the extended morphological profiles. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(3): 447–451. [doi: [10.1109/LGRS.2011.2172185](https://doi.org/10.1109/LGRS.2011.2172185)]
- 24 Jiang JJ, Ma JY, Chen C, *et al.* SuperPCA: A superpixelwise PCA approach for unsupervised feature extraction of hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(8): 4581–4593. [doi: [10.1109/TGRS.2018.2828029](https://doi.org/10.1109/TGRS.2018.2828029)]
- 25 Paoletti ME, Haut JM, Plaza J, *et al.* Deep learning classifiers for hyperspectral imaging: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 158: 279–317. [doi: [10.1016/j.isprsjprs.2019.09.006](https://doi.org/10.1016/j.isprsjprs.2019.09.006)]
- 26 Hamida AB, Benoit A, Lambert P, *et al.* 3-D deep learning approach for remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(8): 4420–4434. [doi: [10.1109/TGRS.2018.2818945](https://doi.org/10.1109/TGRS.2018.2818945)]
- 27 Hong DF, Han Z, Yao J, *et al.* SpectralFormer: Rethinking hyperspectral image classification with transformers. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5518615.

(校对责编: 孙君艳)