

## 基于双通道特征增强的高光谱图像分类

赵利<sup>1</sup>, 王雷全<sup>1</sup>, 张俊三<sup>1\*</sup>, 邵志敏<sup>2</sup>, 朱杰<sup>3</sup><sup>1</sup>中国石油大学(华东)计算机科学与技术学院, 山东 青岛 266580;<sup>2</sup>国网山东省电力公司, 山东 济南 250003;<sup>3</sup>中央司法警官学院信息管理系, 河北 保定 071000

**摘要** 针对如何在训练样本有限的情况下更加充分提取和利用高光谱图像的空间信息和光谱信息这一问题, 提出一种基于双通道特征增强(DCFE)的高光谱图像分类方法。首先, 设计两个通道分别捕获光谱特征和空间特征, 在每个通道中使用三维卷积作为特征提取器。然后, 将降维后的光谱通道中的特征图与空间通道的特征图进行融合。最后, 将融合了光谱特征和空间特征的特征图输入注意力模块中, 通过提升重要信息的关注度和降低无用信息的干扰来实现特征增强。实验结果表明, 所提方法在 Indian Pines(3% 训练样本)、Pavia University(0.5% 训练样本)、Salinas(0.5% 训练样本)和 Botswana(1.2% 训练样本)等 4 个高光谱数据集上的总体分类精度分别为 96.57%、98.15%、98.95% 和 96.83%, 与其他 5 种高光谱分类方法相比, 所提方法在分类性能上取得了明显提升。

**关键词** 图像处理; 高光谱图像分类; 双通道; 特征增强; 注意力机制

中图分类号 TP751 文献标志码 A

DOI: 10.3788/LOP221628

## Hyperspectral Image Classification Based on Dual-Channel Feature Enhancement

Zhao Li<sup>1</sup>, Wang Leiquan<sup>1</sup>, Zhang Junsan<sup>1\*</sup>, Shao Zhimin<sup>2</sup>, Zhu Jie<sup>3</sup><sup>1</sup>College of Computer Science and Technology, China University of Petroleum (East China), Qingdao 266580, Shandong, China;<sup>2</sup>State Grid Shandong Electric Power Company, Jinan 250003, Shandong, China;<sup>3</sup>Department of Information Management, the National Police University for Criminal Justice, Baoding 071000, Hebei, China

**Abstract** A classification method of hyperspectral images based on dual channel feature enhancement (DCFE) is proposed to solve the problem of how to extract and use the spatial and spectral information of hyperspectral images more fully when the training samples are limited. First, two channels are designed to capture spectral and spatial features, and 3D convolution is used as a feature extractor in each channel. The feature map from the reduced-dimension spectral channel is fused with the feature map of the spatial channel. Finally, the feature map combining spectral and spatial features is input into the attention module, and feature enhancement is achieved by increasing attention to important information while decreasing interference from irrelevant information. The experimental results show that the proposed method has an overall classification accuracy of 96.57%, 98.15%, 98.95%, and 96.83% on four hyperspectral data sets, including Indian Pines (3% training sample), Pavia University (0.5% training sample), Salinas (0.5% training sample), and Botswana (1.2% training sample), respectively. When compared to the other five hyperspectral classification methods, the proposed method has remarkably improved the classification performance.

**Key words** image processing; hyperspectral image classification; dual channel; feature enhancement; attention mechanism

## 1 引言

高光谱图像(HSI)又称高光谱遥感图像,是由搭

载高光谱成像仪的航空航天飞行器捕捉到的三维立体图像,由二维空间维度与光谱维度组成,其中,光谱维度包含数十甚至上百个光谱波段,这使其在土地覆盖

收稿日期: 2022-05-17; 修回日期: 2022-06-01; 录用日期: 2022-06-16; 网络首发日期: 2022-06-26

基金项目: 山东省自然科学基金(ZR2020MF006)、中国石油大学(华东)自主创新科研计划项目(20CX05019A)

通信作者: \*zhangjunsan@upc.edu.cn

分析<sup>[1]</sup>、水监测<sup>[2]</sup>、异常检测<sup>[3]</sup>、变化区域检测<sup>[4]</sup>等诸多领域有着广泛的应用前景。因此,发展快速且具有高分类准确率的高光谱图像分类技术将给社会发展带来很大的进步。

高光谱图像分类的目标是依据样本特征为图像中的每个像素赋予类别标签。在早期对高光谱图像分类的研究中,提出了支持向量机(SVM)<sup>[5]</sup>、稀疏表示分类(SRC)<sup>[6]</sup>、多项式逻辑回归(MLR)<sup>[7-8]</sup>等方法,然而此类方法仅利用到了光谱维度的信息,没有考虑到高光谱图像在包含丰富的光谱特征的同时具有较高的空间相关性,因而导致特征提取不够完整,在较少样本的情况下很难学习到准确率较高的分类器。

深度学习在提取非线性和层次特征方面具有突出表现,在图像分类、自然语言处理和目标检测等领域取得了重大突破。高光谱图像分类作为一种典型的分类任务,深受深度学习的影响。文献[9]提出一种基于栈式自编码网络(SAE)的深度学习方法来提取高光谱图像数据的高阶特征,并使用逻辑回归得到分类结果。文献[10]提出一种采用随机主成分分析(R-PCA)来一体化地提取空间和光谱特征的方法。文献[11]提出一种基于深度置信网络(DBN)和受限玻尔兹曼机(RBM)的分类方法。文献[12]提出一种使用空间更新的深度自动编码器(DAE)来提取光谱空间特征的方法,并设计了一种新的协同表示来处理小规模的训练集。上述方法虽然提取了样本中的空间信息,但是在进行空间特征提取时会将图像块扁平化为向量,破坏了样本初始空间结构,导致空间信息丢失。随着卷积神经网络(CNN)的出现,其在不破坏原有空间结构的情况下提取空间信息这一特征可以很好解决这一问题,因此一些基于CNN的方法被引入高光谱图像分类任务中。文献[13]将CNN作为特征提取器应用到高光谱图像分类中。文献[14]提出一种基于差异化区域卷积神经网络(DRCNN)的方法,该方法以目标像素邻域内不同的图像块作为CNN的输入,对输入数据进行了有效的增强。文献[15]提出一种具有更深和更广网络的上下文深层卷积神经网络(CDCNN)。文献[16]提出一种轻量级融合CNN算法,在保证高分类精度的前提下有效提高数据分析速度。

在一般情况下,网络结构越深,捕获到的特征就越加精细,但同时也出现了由于计算量增大导致模型训练困难的问题。残差网络(ResNet)<sup>[17]</sup>和密集卷积网络(DenseNet)<sup>[18]</sup>的出现很好地解决了这一问题,在不增加网络结构深度的前提下也能够提取深层次的特征。受ResNet的启发,文献[19]提出光谱-空间残差网络(SSRN),它包含光谱残差块和空间残差块,可依次提取光谱特征和空间特征。受DenseNet的启发,文献[20]提出一种基于DenseNet和域自适应的网络,可缓解梯度消失和频谱偏移的问题。文献[21]提出快速密集光谱-空间卷积网络(FDSSC),在减少训练时间

的同时取得了更好的性能。

在模型训练过程中,卷积层对特征的关注度并不是相同的,为了优化提取到的特征,采用注意力机制有区别处理不同的特征也是近年来研究的热点。文献[22]提出一种基于卷积块注意力模块(CBAM)<sup>[23]</sup>的双分支多注意机制网络(DBMA)。文献[24]提出一种基于双注意力机制网络(DANet)<sup>[25]</sup>的双分支双注意力机制网络(DBDA)。上述方法分别在空间维度和光谱维度上引入空间注意力机制和通道注意力机制。虽然这些方法很有效,但是对于高光谱图像的空间信息和光谱信息的提取和利用不够充分,导致在训练样本有限的情况下不能获得更好的分类效果。

随着注意力机制的发展,文献[26]提出coordinate attention(CA)机制,该注意力机制通过将空间信息嵌入通道注意力中来充分利用捕获到的空间信息以及有效建立通道间的关系。实验结果表明,该注意力机制在分类任务中能够较好提升分类性能。

为了解决在高光谱图像分类中空间信息和光谱信息提取和利用不充分的问题,本文提出一种基于双通道特征增强(DCFE)的高光谱图像分类方法。该方法包含光谱和空间两个通道,在每个通道中使用多分支的3D-CNN分别捕获光谱特征和空间特征,并将两个通道中的输出特征图融合之后输入CA模块中,相比于其他方法使用的只能建立特征图单向关系的注意力模块,CA模块使用空间信息编码的方式将特征图空间上的信息嵌入通道注意力中,不仅可以利用空间上的信息,还建立了特征图通道之间的关系,实现了对特征图中重要特征的增强。最后,通过全连接(FC)层来获得最终的分类结果。

## 2 实验原理

### 2.1 加入批量归一化的3D-CNN

在卷积过程中,3D-CNN在宽、高和通道等3个方向上进行卷积运算,可以直接提取高光谱图像样本中的光谱信息和空间信息。因此,使用3D-CNN作为所提DCF E方法的基本结构。此外,在每个3D-CNN层中添加一个批归一化(BN)<sup>[27]</sup>层,以提高数值稳定性。

图1中,输入为 $n^k$ 个大小为 $p^k \times p^k \times b^k$ 的特征图,




图1 加入批量归一化的3D-CNN  
Fig. 1 3D-CNN with batch normalization

经过  $n^{k+1}$  个卷积核大小为  $a^{k+1} \times a^{k+1} \times d^{k+1}$  的 3D-CNN 层,从而生成  $n^{k+1}$  个大小为  $p^{k+1} \times p^{k+1} \times b^{k+1}$  特征图,加入批量归一化的第  $k+1$  个 3D-CNN 层的第  $i$  个输出可表示为

$$\mathbf{X}_i^{k+1} = R\left(\sum_{j=1}^{n^k} \hat{\mathbf{X}}_j^k \times \mathbf{H}_i^{k+1} + \mathbf{b}_i^{k+1}\right), \quad (1)$$

$$\hat{\mathbf{X}}^k = \frac{\mathbf{X}^m - E(\mathbf{X}^m)}{\text{Var}(\mathbf{X}^m)}, \quad (2)$$

式中:  $\hat{\mathbf{X}}_j^k \in \mathbf{R}^{p \times p \times k}$  是第  $k+1$  层的第  $j$  个输入特征图;  $\hat{\mathbf{X}}^k$  表示第  $k$  层的最终输出;  $E(\cdot)$  和  $\text{Var}(\cdot)$  表示期望和方差函数;  $\mathbf{H}_i^{k+1}$  和  $\mathbf{b}_i^{k+1}$  表示第  $k+1$  层的权重和偏差;  $R(\cdot)$  是网络中的非线性激活函数。

## 2.2 CA 模块

CA 模块的架构如图 2 所示,为了能够保留空间信息,将全局池化分解为两个一维特征编码操作。具体来说,给定输入  $\mathbf{X}$ ,  $\mathbf{X}$  的大小为  $C \times H \times W$ , 使用两个大小为  $(H, 1)$  和  $(1, W)$  的池化核分别沿水平坐标和垂直坐标对每个通道进行编码。因此,高度为  $h$  的第  $c$  个通道的输出以及宽度为  $w$  的第  $c$  个通道的输出可以表示为

$$z_c^h(h) = \frac{1}{w} \sum_{0 \leq i \leq w} x_c(h, i), \quad (3)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq i \leq H} x_c(i, w), \quad (4)$$

式中:  $x_c$  表示输入。上述两种变换分别沿两个空间方向聚合特征,生成一对方向感知特征图。将式(3)和式(4)生成的特征图进行特征融合,然后输入  $C/r$  个大小为  $1 \times 1$  的卷积核的卷积层当中,卷积层的输出可以表示为

$$\mathbf{f} = \delta\left\{F_1\left[\left(z^h, z^w\right)\right]\right\}, \quad (5)$$

式中:  $\mathbf{f} \in \mathbf{R}^{C/r \times 1 \times (W+H)}$ ,  $r$  是用来控制通道个数的缩小率;  $(\cdot, \cdot)$  表示沿空间维度的拼接操作;  $\delta$  是非线性激

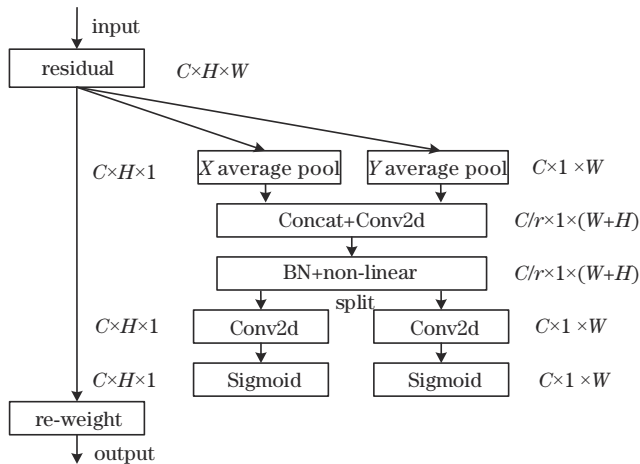


图 2 CA 架构图

Fig. 2 Architecture diagram of CA

活函数。然后将  $\mathbf{f}$  沿着空间维度拆分为  $\mathbf{f}^h \in \mathbf{R}^{C/r \times H \times 1}$  和  $\mathbf{f}^w \in \mathbf{R}^{C/r \times 1 \times W}$  进行卷积运算,变换为和输入  $\mathbf{X}$  相同的通道数,从而得到输出  $\mathbf{g}^h$  和  $\mathbf{g}^w$ :

$$\mathbf{g}^h = \sigma\left[F_h(\mathbf{f}^h)\right], \quad (6)$$

$$\mathbf{g}^w = \sigma\left[F_w(\mathbf{f}^w)\right], \quad (7)$$

式中:  $F_h(\cdot)$  和  $F_w(\cdot)$  代表卷积运算;  $\sigma$  代表 Sigmoid 激活函数。将输出  $\mathbf{g}^h$  和  $\mathbf{g}^w$  展开作为注意力权重,最后输出可以表示为

$$y_c(i, j) = x_c(i, j) \times g^h(i) \times g^w(j). \quad (8)$$

## 2.3 多分支结构网络

通常情况下,可以通过增加网络深度的方式来提取较为复杂的特征,但同时也会出现梯度消失或者梯度爆炸的问题,这使得深度学习模型很难训练。ResNet 的出现很好地解决了这一问题,受 ResNet 的启发,提出一种多分支结构网络,如图 3 所示。




图 3 多分支结构

Fig. 3 Multiple-branch construction

图 3 中,  $F$  表示隐藏层,它包含卷积层、归一化层和激活层,  $G$  表示卷积核大小为  $1 \times 1 \times 1$  的卷积层,直接通过网络到达下一层的是 identity 分支。正是这些分支的存在使提取到的特征更加精细,并且解决了深层网络中的梯度消失问题。图中第  $i-1$  个多分支块的输出可表示为

$$\mathbf{X}_i = F_{i-1}(\mathbf{X}_{i-1}) + G_{i-1}(\mathbf{X}_{i-1}) + \mathbf{X}_{i-1}, \quad (9)$$

式中:  $F(\cdot)$  表示卷积、归一化和激活操作;  $G(\cdot)$  表示卷积操作。通道中对光谱特征和空间特征进行提取的网络由多个多分支块组成,如图 4 所示,假设输入为  $n$  个大小为  $p \times p \times b$  的特征图,先进行归一化层和激活层再进入使用  $m$  个  $a \times a \times d$  的卷积核的卷积层进行 3D 卷积运算,将经过卷积层后的特征图与两个残差分支的特征图逐元素相加,并将结果作为下一个多分支块的输入。

## 2.4 DCFE 网络架构

DCF 模型的整体架构如图 5 所示,本小节以 Indian Pines (IP) 数据集为例对 DCFE 模型架构进行介绍。Indian Pines 包含  $145 \times 145$  个像素,每个像素有




图 4 多分支块结构

Fig. 4 Structure of multi-branch block

200 个光谱带,即 Indian Pines 数据集的大小为  $145 \times 145 \times 200$ 。具有相应标签的像素个数为 20249,其他像素是背景,样本大小分配为  $11 \times 11 \times 200$ ,卷积层的卷积核数量都固定为 24 个。

在光谱通道中,首先通过卷积层将  $11 \times 11 \times 200$  的图像样本卷积为  $11 \times 11 \times 97$  的特征图,之后输入光谱块中,光谱块由 3 个多分支块组成,每个多分支块由卷积层、批归一化层和 Mish 激活函数<sup>[28]</sup>组成,光谱通道的实现如表 1 所示。

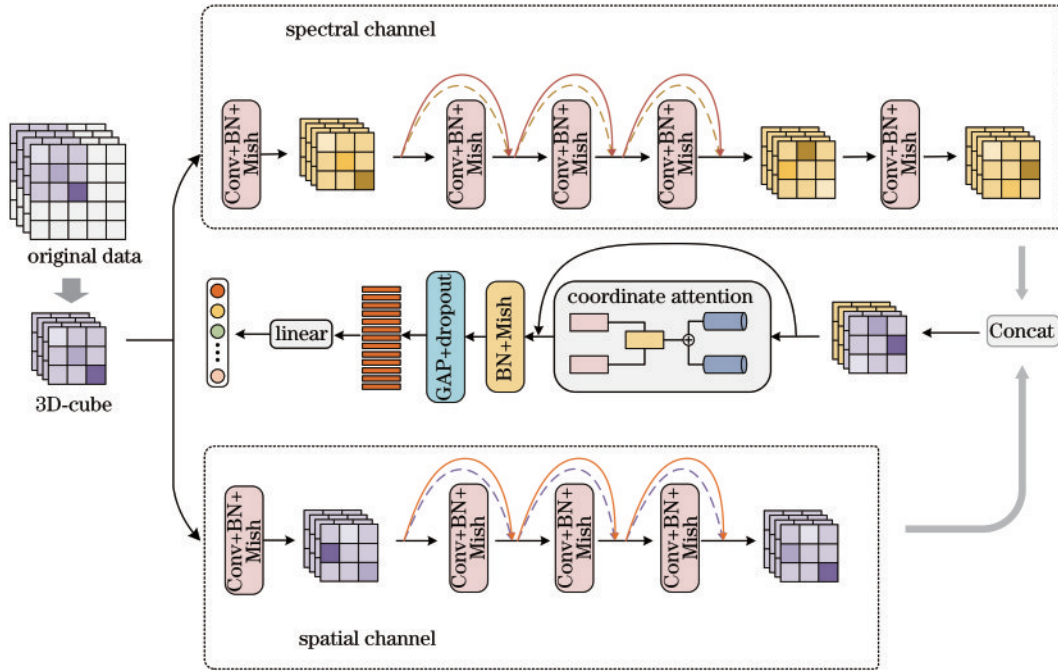


图 5 DCFE 网络架构

Fig. 5 DCFE network structure

表 1 光谱通道的实现

Table 1 Implementation of spectral-channel

Layer name	Kernel size	Output size
Input		$(11 \times 11 \times 200)$
Conv	$(1 \times 1 \times 7)$	$(11 \times 11 \times 97, 24)$
Spectral block	$(1 \times 1 \times 7)$	$(11 \times 11 \times 97, 24)$
BN-Mish-Conv	$(1 \times 1 \times 97)$	$(11 \times 11 \times 1, 24)$

在空间通道中,首先通过卷积层将  $11 \times 11 \times 200$  的图像样本卷积为  $11 \times 11 \times 1$  的特征图,之后输入空间块中,空间块由 3 个多分支块组成,每个多分支块由卷积层、批归一化层和 Mish 激活函数组成,光谱通道的实现如表 2 所示。

表 2 空间通道的实现

Table 2 Implementation of spatial-channel

Layer name	Kernel size	Output size
Input		$(11 \times 11 \times 200)$
Conv	$(1 \times 1 \times 200)$	$(11 \times 11 \times 1, 24)$
Spatial block	$(3 \times 3 \times 1)$	$(11 \times 11 \times 1, 24)$

将光谱通道的输出特征图和空间通道的特征图进行特征融合,输入注意力模块当中,然后将计算得到的注意力权重加到原特征图上,通过池化操作得到  $1 \times 48$  的特征图,最后通过全连接层得到分类结果,实现如表 3 所示。

表 3 分类模块的实现

Table 3 Implementation of classification module

Layer name	Kernel size	Output size
Concatenate		$(11 \times 11 \times 1, 48)$
Attention block		$(11 \times 11 \times 1, 48)$
BN-Mish-dropout-GAP		$(1 \times 48)$
Fully connected		$(1 \times 16)$

在网络结构中,合适的激活函数可以加速网络反向传播和收敛的速度,在 DCFE 模型中,每一次的卷积操作之后,都进行归一化和激活操作,选用的激活函数是 Mish 函数,一种自正则化非单调激活函数,而不是传统的 ReLU<sup>[29]</sup> 激活函数,Mish 函数的计算方式如下:

$$\text{Mish}(x) = x \times \tanh\{\ln[1 + \exp(x)]\}, \quad (10)$$

式中:  $x$  表示激活函数的输入。ReLU 是一种分段线性函数, 即使负输入中包含着有用的信息, 也会将所有的负输入统一为零。不同的是, Mish 函数将负输入保留为负输出, 因此, 部分有用的信息也会被保留下来。

### 3 实验结果与分析

#### 3.1 数据集划分

为了验证所提方法的有效性, 使用 Indian Pines (IP)、Pavia University (UP)、Salinas Valley (SV) 和 Botswana (BS) 等 4 个公开的高光谱数据集进行实验。分类结果评价指标为总体精度 (OA)、平均精度

(AA)、Kappa 系数。OA 表示正确分类的样本占总测试样本的比例, AA 表示所有类别的平均精度, Kappa 系数表示真实值和分类结果之间的一致性。3 个评价指标越高, 说明分类结果越好。

在进行实验之前, 把数据集划分为训练集、验证集和测试集等 3 部分, 训练集及其相应标签用于更新网络参数, 验证集及其标签用于监测在训练阶段生成的临时模型, 测试集用于模型评估。不同的数据集的划分标准也不相同, IP 的划分如表 4 所示, UP 的划分如表 5 所示, SV 的划分如表 6 所示, BS 的划分如表 7 所示。

表 4 IP 数据集的各类训练、验证和测试集样本

Table 4 Samples for each category of training, validation, and testing for IP dataset

Order	Class	Number	Training set	Verification set	Test set
1	alfalfa	46	3	3	40
2	corn-notill	1428	42	42	1344
3	corn-mintill	830	24	24	782
4	corn	237	7	7	223
5	grass-pasture	483	14	14	455
6	grass-trees	730	21	21	688
7	grass-pasture-mowed	28	3	3	22
8	hay-windrowed	478	14	14	450
9	oats	20	3	3	14
10	soybean-notill	972	29	29	914
11	soybean-mintill	2455	73	73	2309
12	soybean-clean	593	17	17	559
13	wheat	205	6	6	193
14	woods	1265	37	37	1191
15	buildings-grass-tree-drives	386	11	11	364
16	stone-steel-towers	93	3	3	87
Total		10249	307	307	9635

表 5 UP 数据集的各类训练、验证和测试集样本

Table 5 Samples for each category of training, validation, and testing for UP dataset

Order	Class	Number	Training set	Verification set	Test set
1	asphalt	6631	33	33	6465
2	meadows	18649	93	93	18463
3	gravel	2099	10	10	2079
4	corn	3064	15	15	3034
5	trees	1345	6	6	1333
6	bare soil	5029	25	25	4979
7	bitumen	1330	6	6	1318
8	self-blocking bricks	3682	18	18	3646
9	shadows	947	4	4	939
Total		42776	210	210	42356

#### 3.2 参数设定

为了验证所提 DCFE 的分类性能, 将其与 SVM<sup>[5]</sup>、SSRN<sup>[19]</sup>、FDSSC<sup>[21]</sup>、DBMA<sup>[22]</sup> 和 DBDA<sup>[24]</sup> 进

行了对比实验, 所有的实验均是在 Intel(R) Xeon(R) 4208 CPU @ 2.10 GHz 处理器、Nvidia GeForce RTX 2060Ti 显卡的系统上运行的, 所有的分类器均采用

表 6 SV 数据集的各类训练、验证和测试集样本

Table 6 Samples for each category of training, validation, and testing for SV dataset

Order	Class	Number	Training set	Verification set	Test set
1	brocoli-green-weeds-1	2009	10	10	1989
2	brocoli-green-weeds-2	3726	18	18	3690
3	fallow	1976	9	9	1958
4	fallow-rough-plow	1394	6	6	1382
5	fallow-smooth	2678	13	13	2652
6	stubble	3959	19	19	3921
7	celery	3579	17	17	3545
8	grapes-untrained	11271	56	56	11159
9	soil-vinyard-develop	6203	31	31	6141
10	corn-senesced-green-weeds	3278	16	16	3246
11	lettuce-romaine-4wk	1068	5	5	1058
12	lettuce-romaine-5wk	1927	9	9	1909
13	lettuce-romaine-6wk	916	4	4	908
14	lettuce-romaine-7wk	1070	5	5	1060
15	vinyard-untrained	7268	36	36	7196
16	vinyard-vertical-trellis	1807	9	9	1789
	Total	54129	263	263	53603

表 7 BS 数据集的各类训练、验证和测试集样本

Table 7 Samples for each category of training, validation, and testing for BS dataset

Order	Class	Number	Training set	Verification set	Test set
1	water	270	3	3	264
2	hippo grass	101	2	2	97
3	floodplain grasses 1	251	3	3	245
4	floodplain grasses 2	215	3	3	209
5	reeds 1	269	3	3	263
6	riparian	269	3	3	263
7	fierscar 2	259	3	3	253
8	island interior	203	3	3	197
9	acacia woodlands	314	4	4	306
10	acacia shrublands	248	3	3	242
11	acacia grasslands	305	4	4	297
12	short mopane	181	2	2	177
13	mixed mopane	269	3	3	263
14	exposed soils	95	1	1	93
	Total	3248	40	40	3168

PyTorch 实现, 批次大小设置为 16, 优化器使用 RMSprop, 学习率初始值为 0.00008, 采用余弦退火<sup>[30]</sup>调整学习率, 损失函数使用交叉熵损失函数。

### 3.3 实验结果

#### 3.3.1 IP 数据集实验结果

本次实验使用 3% 的样本作为训练样本, 3% 的样

本用作验证样本, 94% 的样本作为测试样本。不同的方法对 IP 数据集的分类结果如表 8 所示, 不同的分类方法结果如图 6 所示。

#### 3.3.2 UP 数据集实验结果

由于 UP 数据集样本数量较多, 本次实验使用 0.5% 的样本作为训练样本, 0.5% 的样本作为验证样本, 99% 的样本作为测试样本。不同方法对 UP 数据集的分类结果如表 9 所示, 不同的分类方法结果如图 7 所示。

#### 3.3.3 SV 数据集实验结果

本次实验使用 0.5% 的样本作为训练样本, 0.5% 的样本作为验证样本, 99% 的样本作为测试样本。不同的方法对 SV 数据集的分类结果如表 10 所示, 不同的分类方法结果如图 8 所示。

#### 3.3.4 BS 数据集实验结果

















本次实验使用 1.2% 的样本作为训练样本, 1.2% 的样本作为验证样本, 97.6% 的样本作为测试样本。不同的方法对 BS 数据集的分类结果如表 11 所示, 不同的分类方法结果如图 9 所示。

#### 3.3.5 训练样本的数量对实验结果的影响

为了验证训练样本的数量对实验结果的影响, 使用不同比例的样本作为训练样本进行实验, 对于 IP 数据集, 分别使用 0.5%、1%、3%、5% 和 10% 的样本作为训练集, 实验结果如表 12 所示。对于 UP 和 SV 数据集, 分别使用 0.1%、0.5%、1%、3% 和 5% 的样本作为训练集, 实验结果如表 13、表 14 所示。对于 BS 数据集, 分别使用 0.5%、1.2%、3%、5% 和 10% 的样本作为训练集, 实验结果如表 15 所示。

表 8 3% 训练样本的 IP 数据集的分类结果

Table 8 Classification results of IP dataset of 3% training samples

Class	Color	SVM	SSRN	FDSSC	DBMA	DBDA	DCFE
1 / %		24.19	67.39	97.72	61.76	87.50	100
2 / %		56.71	84.58	98.74	92.30	94.22	98.13
3 / %		65.09	92.49	97.31	97.93	98.32	94.61
4 / %		39.63	91.37	97.20	96.15	98.18	96.81
5 / %		87.33	99.04	99.53	98.00	100	97.63
6 / %		83.87	96.18	92.83	94.86	96.34	95.91
7 / %		57.20	88	100	52.94	83.33	90.90
8 / %		89.28	95.70	100	100	100	97.59
9 / %		22.58	57.14	88.88	50.00	100	100
10 / %		66.70	78.33	88.92	95.52	91.16	94.77
11 / %		62.50	95.83	99.23	95.99	97.47	96.84
12 / %		51.86	85.57	97.16	86.89	97.61	95.63
13 / %		94.79	91.86	98.90	100	97.95	100
14 / %		90.42	91.90	93.44	92.81	95.86	96.88
15 / %		62.82	90.76	95.92	90.93	93.67	96.24
16 / %		98.46	100	92.30	92.22	92.30	93.18
OA / %		69.35	90.52	96.14	93.14	96.19	96.57
AA / %		65.86	87.88	96.15	86.77	95.24	96.57
Kappa / %		64.65	89.21	95.44	92.18	95.65	96.09
Training time /s		12.23	56.06	132.43	108.67	78.96	75.41
Test time /s		1.39	3.39	5.65	7.68	6.83	7.33




图 6 IP 数据集的分类结果图。(a)真值图;(b)~(g)不同方法的分类结果图

Fig. 6 Classification result diagrams of IP dataset. (a) Ground truth; (b)-(g) classification results of different methods










### 3.4 实验结果分析

实验结果表明,相较于其他 5 种方法,DCFE 方法在 OA、AA 和 Kappa 等 3 个指标上都取得了较为明显的提升。在时间上,由于 3D 卷积的输入量大,需要训练的参数多,因此相比于 SVM 方法时间成本更高,但在分类精度上,SVM 方法要远远低于使用 3D 卷积作为特征提取器的方法。在大多数情况下,DCFE 方法比其他基于 3D 卷积的方法花费的时间要少,尽管 SSRN 的时间更少,但是 DCFE 方法的分类精度更高。

对于 IP 数据集:DCFE 方法的 OA 为 96.57%,与其他 5 种方法相比分别提高了 27.22 个百分点、6.05 个百分点、0.43 个百分点、3.43 个百分点和 0.38 个百分点;AA 为 96.57%,与其他 5 种方法相比分别提高了 30.71 个百分点、8.69 个百分点、0.42 个百分点、9.8 个百分点和 1.33 个百分点;Kappa 系数为 96.09%,与其他 5 种方法相比分别提高了 31.44 个百分点、6.88 个百分点、0.65 个百分点、3.91 个百分点和 0.44 个百分点,每个类别的分类精度达到了 90% 以上。相比于其

表 9 0.5% 训练样本的 UP 数据集的分类结果

Table 9 Classification results of UP dataset of 0.5% training samples

Class	Color	SVM	SSRN	FDSSC	DBMA	DBDA	DCFE
1 / %		80.26	94.81	98.88	93.67	96.24	96.49
2 / %		86.94	98.50	98.82	96.34	99.23	99.26
3 / %		71.13	100	100	99.02	99.87	99.44
4 / %		96.44	100	91.74	97.43	98.20	98.78
5 / %		90.85	99.32	99.92	99.55	99.92	99.92
6 / %		77.02	93.43	99.61	98.67	98.06	99.97
7 / %		69.70	95.96	100	98.50	100	99.21
8 / %		67.30	75.87	84.02	82.48	84.11	91.19
9 / %		99.89	99.68	99.66	96.88	100	99.33
OA / %		83.07	94.85	97.02	95.06	97.11	98.15
AA / %		82.24	95.28	96.96	95.84	97.29	98.18
Kappa / %		77.07	93.17	96.04	93.40	96.17	97.54
Training time / s		5.32	12.06	32.16	29.83	21.88	20.12
Test time / s		2.19	5.21	13.22	13.52	11.25	12.10

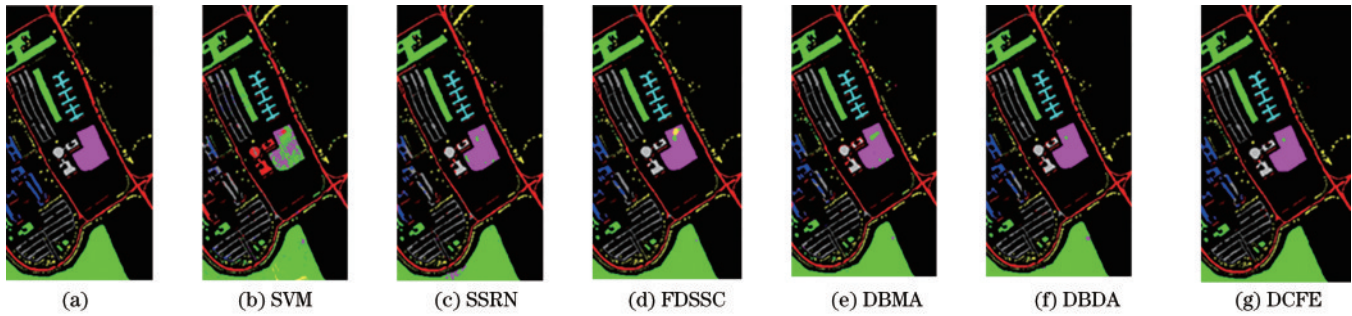


















图 7 UP 数据集的分类结果图。(a)为真值图;(b)~(g)不同方法的分类结果图

Fig. 7 Classification result diagrams of UP dataset. (a) Ground-truth; (b)–(g) classification results of different methods

表 10 0.5% 训练样本的 SV 数据集的分类结果

Table 10 Classification results of SV dataset of 0.5% training samples

Class	Color	SVM	SSRN	FDSSC	DBMA	DBDA	DCFE
1 / %		99.84	100	100	100	100	100
2 / %		98.95	100	97.20	100	97.84	100
3 / %		89.87	94.35	99.58	99.57	96.92	100
4 / %		97.30	95.63	96.91	90.26	97.71	94.33
5 / %		93.55	99.40	100	97.66	99.26	100
6 / %		99.79	100	99.74	100	99.97	99.77
7 / %		91.33	99.46	100	91.90	99.88	100
8 / %		74.73	89.14	95.15	95.62	96.53	97.32
9 / %		97.69	99.51	89.31	99.69	98.76	100
10 / %		90.01	97.75	98.17	97.38	97.70	99.28
11 / %		75.92	92.97	93.17	81.76	95.40	95.49
12 / %		95.19	99.63	98.35	95.93	99.79	100
13 / %		94.86	99.88	100	99.88	100	100
14 / %		89.26	98.04	95.92	97.62	96.00	97.78
15 / %		75.85	87.95	91.94	89.97	94.47	99.03
16 / %		99.03	100	100	100	100	100
OA / %		88.09	95.35	95.85	95.90	97.70	98.95
AA / %		91.45	97.11	97.21	96.08	98.14	98.93
Kappa / %		86.70	94.82	95.38	95.44	97.44	98.83
Training time / s		10.27	85.65	123.14	146.28	82.33	80.56
Test time / s		4.12	16.32	31.05	42.56	25.67	23.66



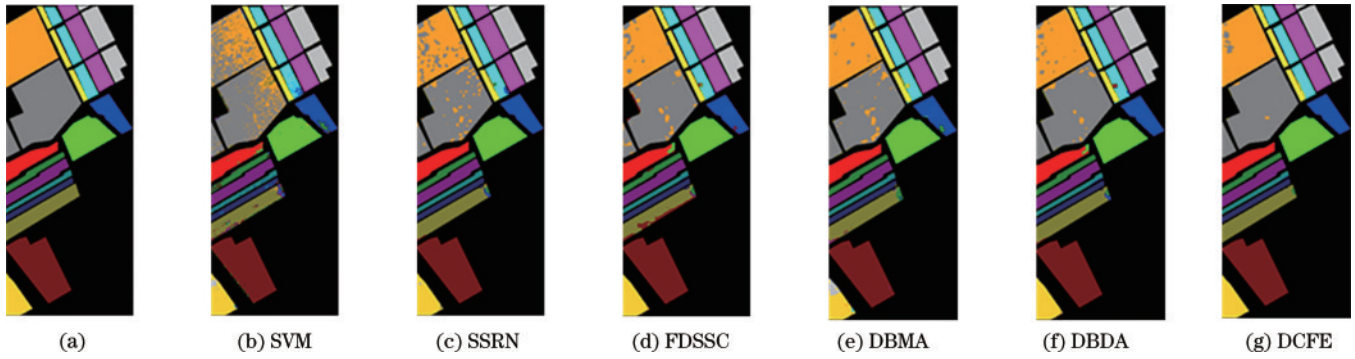


图 8 SV 数据集的分类结果图。(a)为真值图;(b)~(g)不同方法的分类结果图

Fig. 8 Classification result diagram of SV dataset. (a) Ground-truth; (b)~(g) classification results of different methods

表 11 1.2% 训练样本的 BS 数据集的分类结果

Table 11 Classification results of BS dataset of 1.2% training samples

Class	Color	SVM	SSRN	FDSSC	DBMA	DBDA	DCFE
1 / %		100	100	83.95	96.33	95.97	93.26
2 / %		70.70	95.83	78.40	100	98.00	95.14
3 / %		84.10	100	95.57	100	100	100
4 / %		65.95	81.18	82.82	89.40	85.77	86.12
5 / %		82.62	84.55	100	99.45	98.96	92.30
6 / %		65.71	93.24	62.11	80.18	87.04	95.45
7 / %		78.77	94.75	98.82	84.33	100	96.93
8 / %		65.87	97.51	100	100	99.49	100
9 / %		75.18	81.74	100	100	91.04	100
10 / %		69.82	100	97.60	99.18	100	97.99
11 / %		95.49	100	99.00	99.32	100	100
12 / %		93.10	100	93.12	94.62	100	100
13 / %		76.25	100	100	100	100	100
14 / %		90.41	100	100	100	100	100
OA / %		78.63	94.27	90.80	94.87	96.39	96.83
AA / %		79.57	94.91	92.45	95.91	96.87	96.94
Kappa / %		76.87	93.79	90.03	94.45	96.09	96.57
Training time / s		1.65	10.25	22.35	20.88	18.65	19.39
Test time / s		0.41	2.01	2.37	3.02	2.11	2.04




图 9 BS 数据集的分类结果图。(a)为真值图;(b)~(g)不同方法的分类结果图

Fig. 9 Classification result diagram of BS dataset. (a) Ground-truth; (b)~(g) classification results of different methods

表 12 IP 中不同比例训练样本的 OA

Table 12 OA for different proportions of training samples in IP unit: %

Algorithm	0.5%	1%	3%	5%	10%
SVM	48.53	55.95	69.35	74.74	80.55
SSRN	64.99	81.40	90.52	0.955	97.84
FDSSC	70.75	84.71	96.14	97.21	98.02
DBMA	59.33	77.64	93.14	93.75	96.91
DBDA	56.97	78.81	96.19	96.58	97.55
DCFE	74.10	86.54	96.57	97.83	98.34

表 13 UP 中不同比例训练样本的 OA

Table 13 OA for different proportions of training samples in UP unit: %

Algorithm	0.1%	0.5%	1%	3%	5%
SVM	70.59	83.07	88.45	90.35	93.29
SSRN	78.32	94.85	97.11	99.43	99.69
FDSSC	88.97	97.02	97.74	99.50	99.58
DBMA	89.87	95.06	96.37	99.10	99.49
DBDA	88.01	97.11	98.40	99.07	99.33
DCFE	90.79	98.15	98.66	99.99	99.99

表 14 SV 中不同比例训练样本的 OA

Table 14 OA for different proportions of training samples in SV unit: %

Algorithm	0.1%	0.5%	1%	3%	5%
SVM	78.65	88.09	89.89	91.24	92.47
SSRN	67.22	95.35	96.32	97.23	98.14
FDSSC	88.83	95.85	96.48	97.52	98.85
DBMA	92.15	95.90	96.66	97.62	98.21
DBDA	94.23	97.70	98.31	98.95	99.36
DCFE	95.70	98.95	99.25	99.81	99.98

表 15 BS 中不同比例训练样本的 OA

Table 15 OA for different proportions of training samples in BS unit: %

Algorithm	0.5%	1.2%	3%	5%	10%
SVM	73.53	78.63	87.82	89.06	92.76
SSRN	84.07	94.27	95.52	98.19	99.15
FDSSC	87.98	90.80	96.33	97.24	99.46
DBMA	93.36	94.87	95.88	98.01	99.04
DBDA	96.27	96.39	97.38	98.64	99.33
DCFE	96.66	96.83	99.24	99.62	99.80

他地物, grass-pasture mowed 的分类精度较低, 是由于该地物训练样本较少, 在模型训练过程中, 很难对该地物的特征进行充分学习。

对于 UP 数据集: DCFE 方法的 OA 为 98.15%, 与其他 5 种方法相比分别提高了 15.08 个百分点、3.3 个百分点、1.13 个百分点、3.09 个百分点和 1.04 个百分点; AA 为 98.18%, 与其他 5 种方法相比分别提高了

15.94 个百分点、2.9 个百分点、1.22 个百分点、2.34 个百分点和 0.89 个百分点; Kappa 系数为 97.54%, 与其他 5 种方法相比分别提高了 20.47 个百分点、4.37 个百分点、1.5 个百分点、4.14 个百分点和 1.37 个百分点, 每个类别的分类精度达到了 91% 以上。相比于其他地物, self-blocking bricks 的分类精度较低, 是由于该地物的特征中类别特征不明显, 不易进行提取, 其他方法对于该地物的分类精度都在 85% 以下, 但 DCFE 方法可以达到 91.19% 的分类精度。

对于 SV 数据集: DCFE 方法的 OA 为 98.95%, 与其他 5 种方法相比分别提高了 10.86 个百分点、3.6 个百分点、3.1 个百分点、3.05 个百分点和 1.25 个百分点; AA 为 98.93%, 与其他 5 种方法相比分别提高了 7.48 个百分点、1.82 个百分点、1.72 个百分点、2.85 个百分点和 0.79 个百分点; Kappa 系数为 98.83%, 与其他 5 种方法相比分别提高了 12.13 个百分点、4.01 个百分点、3.45 个百分点、3.39 个百分点和 1.39 个百分点, 每个类别的分类精度达到了 94% 以上。

对于 BS 数据集: DCFE 方法的 OA 为 96.83%, 与其他 5 种方法相比分别提高了 18.2 个百分点、2.56 个百分点、6.03 个百分点、1.96 个百分点和 0.44 个百分点; AA 为 96.94%, 与其他 5 种方法相比分别提高了 17.37 个百分点、1.97 个百分点、4.49 个百分点、1.03 个百分点和 0.07 个百分点; Kappa 系数为 96.57%, 与其他 5 种方法相比分别提高了 19.7 个百分点、2.78 个百分点、6.54 个百分点、2.12 个百分点和 0.48 个百分点。相比于其他地物, floodplain grasses 2 的分类精度较低, 是由于该地物的训练样本较少以及该地物特征比较复杂, 在训练模型的过程中特征提取比较困难。

为了进一步验证 DCFE 方法对于少训练样本数据集的分类性能, 针对不同比例的训练样本进行了实验, 随着训练样本的增加, SVM、SSRN、FDSSC、DBMA、DBDA 和 DCFE 方法的分类精度都有所提升。同时, 不同模型之间的性能差距也随着训练样本的增加而缩小。以上实验结果表明, 在训练样本有限的情况下, 所提 DCFE 方法通过两个通道分别捕获光谱特征和空间特征, 能够更好地获取不同类之间的显著特征, 通过注意力机制来实现特征增强, 获得了较好的分类性能。

## 4 结 论

针对高光谱图像在样本量较少的情况下难以充分提取和利用高光谱图像的空间信息和光谱信息这一问题, 提出一种基于双通道特征增强的高光谱图像分类方法。该方法设计两个通道分别对高光谱图像的光谱特征和空间特征进行提取, 在每个通道中, 使用三维卷积作为特征提取器, 在每层卷积之后使用 Mish 激活函数, 以加快反向传播和收敛过程。将两通道提取到的特征图进行特征融合, 通过注意力机制进行特征增强, 最后通过全连接层得到分类结果。

与 SVM、SSRN、FDSSC、DBMA 和 DBDA 方法在 Indian Pines、Pavia University、Salinas 和 Botswana 等 4 个公开高光谱数据集上的对比实验结果表明,在训练样本比较少少的情况下,所提 DCFE 方法的分类精度提升明显。在后续研究中,将继续针对少样本问题构建更有效的分类模型,进一步提高高光谱图像的分类精度。

### 参 考 文 献

- [1] Bhosle K, Musande V. Evaluation of deep learning CNN model for land use land cover classification and crop identification using hyperspectral remote sensing images [J]. *Journal of the Indian Society of Remote Sensing*, 2019, 47(11): 1949-1958.
- [2] Zhao C H, Wang Y L, Qi B, et al. Global and local real-time anomaly detectors for hyperspectral remote sensing imagery[J]. *Remote Sensing*, 2015, 7(4): 3966-3985.
- [3] Pipitone C, Maltese A, Dardanelli G, et al. Monitoring water surface and level of a reservoir using different remote sensing approaches and comparison with dam displacements evaluated via GNSS[J]. *Remote Sensing*, 2018, 10(1): 71.
- [4] Marinelli D, Bovolo F, Bruzzone L. A novel change detection method for multitemporal hyperspectral images based on binary hyperspectral change vectors[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(7): 4913-4928.
- [5] Pal M. Ensemble of support vector machines for land cover classification[J]. *International Journal of Remote Sensing*, 2008, 29(10): 3043-3049.
- [6] Chen Y, Nasrabadi N M, Tran T D. Classification for hyperspectral imagery based on sparse representation [C]//2010 2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, June 14-16, 2010, Reykjavik, Iceland. New York: IEEE Press, 2010.
- [7] Li J, Bioucas-Dias J M, Plaza A. Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(11): 4085-4098.
- [8] Li J, Bioucas-Dias J M, Plaza A. Spectral-spatial hyperspectral image segmentation using subspace multinomial logistic regression and Markov random fields [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(3): 809-823.
- [9] Chen Y S, Lin Z H, Zhao X, et al. Deep learning-based classification of hyperspectral data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2094-2107.
- [10] Makantasis K, Karantzas K, Doulamis A, et al. Deep supervised learning for hyperspectral data classification through convolutional neural networks[C]//2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), July 26-31, 2015, Milan, Italy. New York: IEEE Press, 2015: 4959-4962.
- [11] Chen Y S, Zhao X, Jia X P. Spectral-spatial classification of hyperspectral data based on deep belief network[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2381-2392.
- [12] Ma X R, Wang H Y, Geng J. Spectral-spatial classification of hyperspectral image based on deep auto-encoder[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(9): 4073-4085.
- [13] 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.
- [14] Zhang M M, Li W, Du Q. Diverse region-based CNN for hyperspectral image classification[J]. *IEEE Transactions on Image Processing*, 2018, 27(6): 2623-2634.
- [15] Lee H, Kwon H. Going deeper with contextual CNN for hyperspectral image classification[J]. *IEEE Transactions on Image Processing*, 2017, 26(10): 4843-4855.
- [16] 刘金香, 班伟, 陈宇, 等. 融合多维度 CNN 的高光谱遥感图像分类算法[J]. *中国激光*, 2021, 48(16): 1610003. Liu J X, Ban W, Chen Y, et al. Multi-dimensional CNN fused algorithm for hyperspectral remote sensing image classification[J]. *Chinese Journal of Lasers*, 2021, 48(16): 1610003.
- [17] 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.
- [18] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [19] 赵春晖, 李彤, 冯收. 基于密集卷积和域自适应的高光谱图像分类[J]. *光子学报*, 2021, 50(3): 0310001. Zhao C H, Li T, Feng S. Hyperspectral image classification based on dense convolution and domain adaptation[J]. *Acta Photonica Sinica*, 2021, 50(3): 0310001.
- [20] Zhong Z L, Li J, Luo Z M, et al. Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(2): 847-858.
- [21] Wang W J, Dou S G, Jiang Z M, et al. A fast dense spectral-spatial convolution network framework for hyperspectral images classification[J]. *Remote Sensing*, 2018, 10(7): 1068.
- [22] Ma W P, Yang Q F, Wu Y, et al. Double-branch multi-attention mechanism network for hyperspectral image classification[J]. *Remote Sensing*, 2019, 11(11): 1307.
- [23] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018*.

- Lecture notes in computer science. Cham: Springer, 2018, 11211: 3-19.
- [24] Li R, Zheng S Y, Duan C X, et al. Classification of hyperspectral image based on double-branch dual-attention mechanism network[J]. Remote Sensing, 2020, 12(3): 582.
- [25] Fu J, Liu J, Tian H J, et al. Dual attention network for scene segmentation[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 3141-3149.
- [26] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 13708-13717.
- [27] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [EB/OL]. (2015-02-11)[2021-02-04]. <https://arxiv.org/abs/1502.03167v3>.
- [28] Mishra D. Mish: a self regularized non-monotonic neural activation function[EB/OL]. (2019-08-23) [2022-02-02]. <https://arxiv.org/abs/1908.08681>.
- [29] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C]//NIPS'12: Proceedings of the 25th International Conference on Neural Information Processing Systems, December 3-6, 2012, Lake Tahoe, Nevada, USA. New York: ACM Press, 2012: 1097-1105.
- [30] Loshchilov I, Hutter F. SGDR: stochastic gradient descent with warm restarts[EB/OL]. (2016-08-13)[2022-02-04]. <https://arxiv.org/abs/1608.03983>.