

DOI:10.16136/j.joel.2022.05.0570

# 一种基于可变形卷积的高光谱图像分类算法

唐 婷, 潘 新\*

(内蒙古农业大学 计算机与信息工程学院, 内蒙古 呼和浩特 010018)

**摘要:**随着深度学习的不断发展,基于深度学习的机器视觉方法被广泛应用,其中,卷积神经网络(convolutional neural network, CNN)对高光谱图像(hyperspectral imagery, HSI)分类有着显著的效果。传统卷积网络中卷积核的采样位置是固定的,不能根据 HSI 中复杂的空间结构而改变,忽略了数据在空间分布上的特征,为了提高高光谱图像分类在实际应用中的性能,本文提出了一种基于可变形卷积的高光谱图像分类方法,考虑到 HSI 高维度的特性,将可变形卷积从 2D 引伸到 3D,从而更好地提取 3D 空间上的特征。本文结合双分支双注意机制网络(double-branch dual-attention mechanism network, DBDA)的网络结构和 3D 可变形卷积,在 Indian Pines (IP) 和 Botswana (BS) 2 个数据集上进行了实验。实验结果表明,本文的方法在综合精度(overall accuracy, OA)、平均精度(average accuracy, AA)、KAPPA 评价标准上均获得了更好的分类准确率,相较于次优算法,OA 提高了 0.15%—0.23%,AA 提高了 0.21%,KAPPA 提高了 0.0003—0.0014。

**关键词:**高光谱图像分类;可变形卷积;深度学习;卷积神经网络

**中图分类号:**TP391.41 **文献标识码:**A **文章编号:**1005-0086(2022)05-0488-07

## A hyperspectral image classification algorithm based on deformable convolution

TANG Ting, PAN Xin\*

(College of computer and information engineering, Inner Mongolia Agricultural University, Hohhot, Inner Mongolia 010018, China)

**Abstract:** With the continuous development of deep learning, machine vision methods based on deep learning are widely used, and the convolutional neural network (CNN) has remarkable effect on hyperspectral imagery (HSI) classification. The sampling position of the convolutional kernel in traditional convolutional networks is fixed and cannot be changed according to the complex spatial structure in HSI, ignoring the features of the data on spatial distribution. To improve the performance of hyperspectral image classification in practical applications, this paper proposes a deformable convolution-based hyperspectral image classification method, which extends the deformable convolution from 2D to 3D considering the high dimensionality of HSI, so as to better extract the features on 3D space. This paper combines the double-branch dual-attention mechanism network (DBDA) structure and 3D deformable convolution, and experiments are conducted on two datasets, Indian Pines (IP) and Botswana (BS), and the experimental results show that the method of this paper achieves better classification accuracy on overall accuracy (OA), average accuracy (AA) and KAPPA evaluation criteria, and improves OA by 0.15%—0.23%, AA by 0.21%, and KAPPA by 0.0003—0.0014 compared with the suboptimal algorithm.

**Key words:** hyperspectral image classification; deformable convolution; deep learning; convolutional neural network

\* E-mail: pxffyfx@126.com

收稿日期: 2021-08-13 修订日期: 2021-09-09

基金项目: 国家自然科学基金(61962048, 61562067)和中央级基本科研业务费(1610332020020)资助项目

## 1 引言

高光谱图像(hyperspectral image, HSI)是由从可见光谱到红外光谱的数百个光谱带组成的,包含丰富的光谱信息和空间信息,实现了图谱合一。与普通图像相比,高光谱图像由于具备丰富的光谱和空间信息,已被广泛应用于很多领域,比如精准农业<sup>[1]</sup>、大气环境监测<sup>[2]</sup>、医学图像处理<sup>[3]</sup>等。早期的高光谱图像分类一般采用传统的方法,只利用了光谱特征进行分类,没有深入挖掘图像内部的上下文信息,例如支持向量机<sup>[4]</sup>、随机森林<sup>[5]</sup>等。仅利用光谱特征,在分类中容易出现 Hughes 现象,另外也容易造成地物空间上的不连续,产生“椒盐”现象。近几年来,以卷积神经网络(convolutional neural network, CNN)为代表的深度学习也被广泛地应用在高光谱图像分类中,例如采用2维(two-dimensional, 2D)或3维(three-dimensional, 3D)卷积<sup>[6]</sup>提取特征进行 HSI 分类。基于2D-CNN 和 ResNet, LEE 等<sup>[7]</sup>提出了一种具有更深更广网络的 CDCNN,通过联合利用相邻单个像素向量的局部时空关系,来优化探索局部上下文的相互作用。ZHONG 等<sup>[8]</sup>设计了一个端到端的光谱-空间残差网络(spectral-spatial residual network, SSRN),通过构建光谱残差块和空间残差块来提取光谱特征和空间特征。WANG 等<sup>[9]</sup>提出一个端到端、快速且密集的光谱-空间卷积(fast dense spectral-spatial convolution, FDSSC)框架,通过构建密集光谱块和密集空间块自动提取 HSI 中丰富的光谱特征和空间特征。受 DBMA(double-branch multi-attention mechanism network, DBMA)<sup>[10]</sup>的启发,LI 等<sup>[11]</sup>提出了一种用于 HSI 分类的双分支双注意力机制网络(double-branch dual-attention mechanism network, DBDA),使用2个分支分别提取光谱和空间特征,并在这2个分支上分别应用了2种类型的注意力机制,以确保更有区别地利用光谱和空间特征,最后将2个分支上提取到的光谱和空间特征融合进行分类。

基于 CNN 或者改进的更深网络的 CNN 在提取特征时,卷积核的采样位置通常是固定网格的,并且池化层不能被训练用来学习特征下采样。对于非常复杂的、不同尺度或形状的物体,传统的基于卷积神经网络方法不能有效地从复杂结构中提取特征,从而限制了分类性能。而基于可变形卷积<sup>[12-14]</sup>的 HSI 分类方法可以有效解决上述问题,可变形卷积可以根据图像的实际情况动态调整感受野<sup>[15]</sup>的尺寸,更好地提取特征,这里感受野是

指卷积神经网络每一层输出的特征图上的像素点在原始图像上映射的区域大小。可变形卷积通常是2维的,而高光谱图像与普通图像相比更为复杂,为了将可变形卷积运用到 HSI 的特征提取上,需要将可变形卷积从2D引伸到3D。

本文将可变形卷积从2D引伸到了3D,并将3D可变形卷积应用到了目前 HSI 分类效果比较好的 DBDA 网络中,在训练样本有限的情况下,本文方法取得了更好的分类精度。

## 2 算法原理

### 2.1 DBDA 算法原理

DBDA 网络<sup>[11]</sup>是一种基于 DenseNet 和 3D-CNN 的端到端框架的双分支双注意力机制网络,对于高光谱图像分类,在训练样本非常有限的情况下,该网络显著提高了分类精度,具有优于现有算法的性能。DBDA 包含2个分支:光谱分支和空间分支,分别捕捉 HSI 中包含的大量光谱和空间特征。并且在这2个分支上分别应用了光谱注意块和空间注意块来细化和优化提取的特征图,光谱注意块聚焦于信息丰富的光谱带,空间注意块聚焦于信息丰富的像素。最后将得到的光谱特征图和空间特征图进行融合运算得到分类结果。接下来将分别描述带光谱注意块的光谱分支和带空间注意块的空间分支的实现过程。

在光谱分支中,首先,输入大小为  $9 \times 9 \times 200$  的特征图,使用具有  $1 \times 1 \times 7$  大小的 3D-CNN 层,向下采样步幅设置为(1,1,2),得到  $(9 \times 9 \times 97, 24)$  大小的特征图,这样做的目的是为了减少波段的数量。然后,经过 3D-CNN 与 BN 结合的密集光谱块,密集光谱块中的每个 3D-CNN 有12个通道,卷积核大小为  $1 \times 1 \times 7$ 。在经过密集光谱块之后,特征图的通道数量增加到了60,获得了大小为  $(9 \times 9 \times 97, 60)$  的特征图。接下来经过一个卷积核大小为  $1 \times 1 \times 97$  的 3D-CNN 之后,生成  $(9 \times 9 \times 1, 60)$  特征图。然而,这60个通道对分类的贡献是不同的,为了细化光谱特征,再经过光谱注意块来增加有用信息的权重,弱化无用信息的权重。在经过光谱注意块获得加权光谱特征图后,应用 BN 层和 Dropout 层来增强数值稳定性和克服过拟合。最后,通过全局平均池化层,得到  $1 \times 60$  大小的光谱特征图。

同时,将  $9 \times 9 \times 200$  大小的原始特征图输入到空间分支,初始 3D-CNN 层的大小被设置为  $1 \times 1 \times 20$ ,可以将光谱带压缩到1维,然后得到  $(9 \times 9 \times 1, 24)$  大小的特征图。然后,经过由 3D-CNN 和 BN 结合的密集空间块,密集空间块中的每个 3D-CNN 有12个通道,卷积核大小为  $3 \times 3 \times 1$ 。接下来将经过

密集空间块提取的大小为 $(9 \times 9 \times 1, 60)$ 的特征图输入到空间注意块,利用空间注意块,对每个像素的系数进行加权,得到更具区分性的空间特征。在捕获到加权空间特征图之后,再经过一个BN层和Drop-out层,来增强数值稳定性和克服过拟合。最后,通过全局平均池化层,得到 $1 \times 60$ 大小的空间特征图。

利用光谱分支和空间分支可以得到多幅光谱特征图和空间特征图。然后,在2个特征之间执行连接以进行分类。最后,通过全连接层和softmax激活函数获得分类结果。

## 2.2 可变形卷积

传统的卷积核通常是固定尺寸、固定大小的,例如 $3 \times 3, 5 \times 5, 7 \times 7$ 等,对未知形状的图形变换存在固有的缺陷,主要有卷积单元对输入特征图的固定位置进行采样,池化层以固定的比例进行池化。这些特性会对特征提取产生显著的影响,例如,同一CNN层中的所有激活单元的感受野尺寸是一样的,而不同的位置可能对应着不同尺度或变形的物体,这就需要能够自动调整尺度或者感受野的大小,可变形卷积是解决上述问题的一个有力手段。可变形卷积是指卷积核在每一个元素上额外增加了一个方向参数,这样卷积核就能在训练过程中扩展到很大的范围。

2D可变形卷积<sup>[12,13]</sup>网络结构图如图1所示,与标准卷积相比,可变形卷积对卷积核中每个采样点的位置都增加了一个偏移变量,可以根据图像内容进行动态调整,从而适应不同物体的形状、大小等几何形变。可变形卷积的偏差是通过一个卷积层获得,该卷积层的卷积核与普通卷积核一样,输出的偏差尺寸和输入的特征图尺寸一致,生成通道维度是 $2N$ ,分别对应原始输出特征和偏移特征。这2个卷积核通过双线性插值后向传播算法同时学习。




图1 2D可变形卷积网络结构图

Fig. 1 The structure of the deformable 2D convolutional network

可变形卷积操作和池化操作一样,都是2维的,且都是在同一个通道上进行的,首先在输入的特征图上使用规则网格进行采样,然后再进行加权运算, $\mathcal{R}$ 定义了感受野的大小和扩张。

$$\mathcal{R} = \{(-1, -1), (-1, 0), \dots, (0, 1), (1, 1)\}. \quad (1)$$

对于在输出的特征图上的每个位置 $p_0$ ,通过下列表达式进行计算,其表示为:

$$y(p_0) = \sum_{p_n \in \mathcal{R}} w(p_n) \cdot x(p_0 + p_n), \quad (2)$$

式中, $p_n$ 是对 $\mathcal{R}$ 中所列位置的枚举。

在可变形卷积网络的操作中,常规的规则网格 $\mathcal{R}$ 过增加一个偏移量进行扩张,同样的位置 $p_0$ 表示为:

$$y(p_0) = \sum_{p_n \in \mathcal{R}} w(p_n) \cdot x(p_0 + p_n + \Delta p_n). \quad (3)$$

现在,采样的位置变成了不规则位置, $\Delta p_n$ 为偏移矩阵,由于偏移量 $\Delta p_n$ 通常是小数,因此要通过双线性插值法进行实现,表达式为:

$$x(p) = \sum_q G(q, p) \cdot x(q). \quad (4)$$

## 2.3 可变形卷积从2D到3D的引伸

可变形卷积通常是2维的,3D可变形卷积(deformable 3D convolution, D3D)<sup>[16]</sup>将可变形卷积和3D-CNN融合在一起,从而显著提升了CNNs的形变建模能力。D3D可通过可学习的偏移变量来扩大空间感受野,其结构图如图2所示,大小为 $C \times D \times H \times W$ 的输入特征首先经过大小为 $3 \times 3 \times 3$ 的3D-CNN,以生成大小为 $2N \times D \times H \times W$ 的偏移特征




图2 3D可变形卷积网络结构图

Fig. 2 The structure of the deformable 3D convolutional network

(其中  $C$ 、 $2N$  为通道大小,  $D$  为 3 维特征图的深度,  $H$  为高度,  $W$  为宽度)。沿其通道维度具有  $2N$  个值, 这些值代表 D3D 采样网格的变形值(高度为  $N$ , 宽度为  $N$ )。这里  $N=27$  是采样网格的大小。然后将所学习的偏移特征用于 3D-CNN 采样网格的变形, 以生成 D3D 采样网格。最后, 使用 D3D 采样网格来产生输出特征。总之, D3D 可以用 2.2 节中的式(3)表示, 其中  $\Delta p_n$  表示对应于  $3 \times 3 \times 3$  卷积采样网格中第  $n$  个值的偏移。由于偏移变量通常是小数, 所以使用双线性插值来生成精确的值。

## 2.4 结合可变形卷积的 DBDA 算法

普通的 2D 或 3D 卷积操作一般使用固定尺寸的卷积核进行特征提取, 不能根据图像的比例和形状来调整感受野的大小, 从而更好地提取特征。而可变形卷积可以适应不同物体的形状、大小等几何形变, 通过引入偏移量来扩大感受野, 提升对图像变化

的适应能力, 能够更好地提取图像的特征。

可变形卷积通常都在 2D 空间域上运行, 为了将可变形卷积运用到高光谱遥感图像上, 本文将可变形卷积从 2D 引伸到了 3D, 并将 3D 可变形卷积运用到了目前高光谱图像分类效果比较好的双分支双注意力机制网络 DBDA 中。图 3 为本文方法网络结构图, 在 DBDA 网络的基础上引入了 3D 可变形卷积, DBDA 的算法原理可参照 2.1 节中的描述, 将原始数据分别输入到光谱分支和空间分支以提取光谱特征图和空间特征图, 最后将 2 个分支上提取到的光谱特征图和空间特征图融合运算进行分类。光谱分支由基于 3D 可变形卷积和 DenseNet 的密集光谱块、光谱注意块等组成, 空间分支由基于 3D 可变形卷积和 DenseNet 的密集空间块、空间注意块等组成。引入了 3D 可变形卷积的 DBDA 网络能更好地提取高光谱图像中的光谱和空间特征, 从而提高分




图3 本文方法网络结构图

Fig. 3 Network structure of the method in this paper

类精度。

## 3 实验结果与分析

### 3.1 数据集描述

本文在 2 个高光谱公开数据集上进行了实验, 即 Indian Pines(IP)数据集和 Botswana(BS)数据集。

采用综合精度(overall accuracy, OA)、平均精度(average accuracy, AA)和 Kappa 系数 3 个指标对分类性能进行定量评价。OA 指的是正确分类的数量与要分类的像素总数的比率, AA 指所有类别的平均准确度, Kappa 系数用于反映真实标签与分类结果的一致性。3 个度量值越高, 分类效果越好。

Indian Pines(IP)数据集:由机载可视红外成像光谱仪(AVIRIS)于1992年对美国印第安纳州一块印度松树进行成像,图像有16个类别,图像尺寸为 $145 \times 145$  pixels,分辨率为20 m/pixels,由200个光谱带组成,波长范围为0.4—2.5  $\mu\text{m}$ 。

Botswana(BS)数据集:由美国宇航局EO-1卫星于2001—2004年在Botswana获得的一系列数据,包括14个土地覆盖类别,图像尺寸为 $1475 \times 256$  pixels,分辨率为30 m/pixels,由145个光谱带组成,波长范围为0.4—2.5  $\mu\text{m}$ 。

本文提出的方法能够在训练样本非常有限的情况下保持良好的性能,因此,在实验中训练样本和验证样本的大小均被设定在较小的水平,对于IP和BS数据集,均设定3%的训练样本大小,3%的验证样本大小,其余样本用作测试集。

### 3.2 实验设置

为了验证本文方法的有效性,实验对比了其他4种方法,有基于深度学习的CDCNN<sup>[7]</sup>、SSRN<sup>[8]</sup>、FDSSC<sup>[9]</sup>和目前比较先进的DBDA<sup>[11]</sup>。所有实验都在配置了16GB内存和NVIDIA GeForce RTX 1080Ti GPU的同一平台上执行。并使用PyTorch实现所有基于深度学习的分类器。接下来将分别对上述方法进行简单描述。

CDCNN:基于2D-CNN和ResNet,输入的大小为 $5 \times 5 \times b$ ,其中 $b$ 表示光谱带的个数。

SSRN: 基于3D-CNN和ResNet,输入的大小为 $7 \times 7 \times b$ 。

FDSSC:基于3D-CNN和DenseNet,输入的大小为 $9 \times 9 \times b$ 。

DBDA:基于3D-CNN、DenseNet和一个注意力机制,输入的大小为 $9 \times 9 \times b$ 。

实验中所有方法批处理大小均设置为16,优化器设为Adam,学习率设置为0.0005,并采用余弦退火方法动态调整学习率。关于最优权重的选择,迭代次数均设置为150,在训练过程中优先选择验证集上准确率高的,若验证集的准确率一致,则选择在训练集上损失最小的。

### 3.3 实验结果

#### 3.3.1 IP数据集的分类结果

表1为不同方法在IP数据集上的分类结果,其中每一类中的最佳分类精度用粗体表示。从表1可以得出,本文提出的方法得到了最佳的分类结果,OA为95.63%,AA为94.51%,Kappa为0.9489。CDCNN的分类精度最低,OA仅为71.01%,因为CDCNN是基于2DCNN,由于训练样本有限,网络结构比较薄弱。FDSSC由于使用密集连接代替剩余连接,且分别提取光谱特征和空间特征,与SSRN相比在OA方面获得了0.58%的提升。基于FDSSC,DBDA提取2个独立分支的光谱和空间特征,并引入注意力机制,与FDSSC相比,OA提高了0.53%。本文方法由于引入了3D可变形卷积,与DBDA相比,OA提高了0.23%,AA提高了0.21%,Kappa提高了0.0014。

表1 使用3%训练样本的IP数据集的分类结果

Tab. 1 The categorized results for the IP dataset with 3% training samples

| Class | CDCNN              | SSRN               | FDSSC              | DBDA                             | Proposed                           |
|-------|--------------------|--------------------|--------------------|----------------------------------|------------------------------------|
| 1     | 46.94              | 88.28              | 85.42              | 96.64                            | <b>96.71</b>                       |
| 2     | 64.07              | 93.25              | <b>97.2</b>        | 94.21                            | 94.39                              |
| 3     | 53.43              | 92.09              | <b>94.45</b>       | 94.30                            | 94.27                              |
| 4     | 54.96              | 90.03              | <b>100.00</b>      | 94.41                            | 94.85                              |
| 5     | 90.89              | 97.34              | <b>100.00</b>      | 98.55                            | 98.83                              |
| 6     | 88.83              | 98.74              | <b>100.00</b>      | 98.81                            | 98.87                              |
| 7     | 42.06              | 81.40              | 75.53              | 84.43                            | <b>84.77</b>                       |
| 8     | 92.28              | 99.84              | 99.78              | <b>100.00</b>                    | <b>100.00</b>                      |
| 9     | 43.44              | 90.54              | <b>100.00</b>      | 83.78                            | 83.85                              |
| 10    | 64.71              | 87.68              | 89.25              | 92.05                            | <b>92.50</b>                       |
| 11    | 71.25              | 94.83              | 93.97              | 96.03                            | <b>96.12</b>                       |
| 12    | 40.42              | 94.08              | <b>95.41</b>       | 92.48                            | 92.36                              |
| 13    | 88.55              | 99.20              | <b>100.00</b>      | 98.67                            | 98.80                              |
| 14    | 87.95              | 96.89              | 93.14              | 97.00                            | <b>97.24</b>                       |
| 15    | 73.69              | <b>94.84</b>       | 90.61              | 93.83                            | 94.13                              |
| 16    | 90.64              | <b>96.90</b>       | 96.55              | 93.79                            | 94.07                              |
| OA    | 71.01 $\pm$ 1.59   | 94.29 $\pm$ 1.19   | 94.87 $\pm$ 1.22   | <b>95.40<math>\pm</math>1.10</b> | <b>95.63<math>\pm</math>1.08</b>   |
| AA    | 68.38 $\pm$ 2.45   | 93.50 $\pm$ 1.18   | 94.33 $\pm$ 1.25   | 94.30 $\pm$ 1.76                 | <b>94.51<math>\pm</math>1.66</b>   |
| Kappa | 0.6684 $\pm$ 0.019 | 0.9349 $\pm$ 0.014 | 0.9414 $\pm$ 0.018 | 0.9475 $\pm$ 0.013               | <b>0.9489<math>\pm</math>0.012</b> |

3.3.2 BS 数据集的分类结果

表 2 为不同方法在 BS 数据集上的分类结果,其中每一类中的最佳分类精度用粗体表示。从表 2 可以得出,本文提出的方法得到了最佳的分类结果,

OA 为 98.45%,AA 为 98.52%,Kappa 为 0.9819。由于 BS 的数据集很小,只有 3248 个标记样本,仅选择 97 个样本作为训练集,97 个样本作为验证集。尽管如此,本文方法与 DBDA 相比,OA 提升

表 2 使用 3%训练样本的 BS 数据集的分类结果  
Tab. 2 The categorized results for the BS dataset with 3% training samples

| Class | CDCNN        | SSRN          | FDSSC         | DBDA          | Proposed            |
|-------|--------------|---------------|---------------|---------------|---------------------|
| 1     | 97.33        | <b>99.50</b>  | 99.49         | 99.15         | 99.33               |
| 2     | 90.18        | 99.19         | 99.70         | <b>99.90</b>  | <b>99.90</b>        |
| 3     | 89.94        | 99.87         | <b>100.00</b> | <b>100.00</b> | <b>100.00</b>       |
| 4     | 92.55        | <b>98.32</b>  | 96.48         | 96.54         | 97.77               |
| 5     | 88.13        | <b>93.32</b>  | 92.69         | 92.36         | 92.73               |
| 6     | 76.87        | 92.36         | <b>96.27</b>  | 93.28         | 93.21               |
| 7     | 99.50        | <b>100.00</b> | <b>100.00</b> | <b>100.00</b> | <b>100.00</b>       |
| 8     | 91.39        | 97.74         | 98.11         | 99.44         | <b>99.52</b>        |
| 9     | 85.54        | 95.10         | 99.32         | <b>99.90</b>  | 99.85               |
| 10    | 93.62        | 96.32         | <b>99.50</b>  | 99.08         | 99.22               |
| 11    | 91.82        | <b>99.93</b>  | 99.53         | 99.90         | 99.90               |
| 12    | 89.97        | 99.23         | <b>99.94</b>  | 99.83         | 99.91               |
| 13    | 95.31        | 99.08         | 97.84         | 99.96         | <b>100.00</b>       |
| 14    | 89.21        | <b>100.00</b> | <b>100.00</b> | <b>100.00</b> | <b>100.00</b>       |
| OA    | 90.17±1.10   | 97.41±1.19    | 98.20±0.86    | 98.30±0.61    | <b>98.45±0.63</b>   |
| AA    | 90.81±1.32   | 97.85±0.88    | 98.49±0.66    | 98.52±0.52    | <b>98.52±0.54</b>   |
| Kappa | 0.8934±0.012 | 0.9719±0.013  | 0.9805±0.009  | 0.9816±0.007  | <b>0.9819±0.007</b> |

了 0.15%,本文方法能更有效地提取光谱和空间特征。

4 结 论

本文提出了一种基于 3D 可变形卷积的高光谱图像分类算法,在 DBDA 网络结构中,引入了 3D 可变形卷积提取特征。普通的 2D 和 3D 卷积采用固定大小的卷积核提取特征,不能适应图像的变化,可变形卷积通过引入偏移量扩大了感受野,可以根据图像的实际情况做出调整,更好地提取图像特征。而可变形卷积通常是 2 维的,本文将可变形卷积从 2D 引伸到了 3D,使其能够运用到高光谱图像的特征提取上。实验结果表明,在训练样本有限的情况下,与其他几种算法相比,本文方法能够更有效地提取高光谱图像的光谱和空间特征,得到最佳的分类性能。

参考文献:

[1] IBRAHIM A,FRANZ B,AHMAD Z,et al. Atmospheric correction for hyperspectral ocean color retrieval with application to the Hyperspectral Imager for the Coastal Ocean

(HICO)[J]. Remote Sensing of Environment,2018,204: 60-75.  
[2] 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.  
[3] ZHANG D,ZHANG J H,WANG Z,et al. Tongue colour and coating prediction in traditional Chinese medicine based on visible hyperspectral imaging[J]. IET Image Processing,2019,13(12):2265-2270.  
[4] MELGANI F,BRUZZONE L. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004,42(8):1778-1790.  
[5] LI L,REN Y M. Classification of hyperspectral data based on random forest[J]. Computer Engineering and Applications,2016,52(24):189-193.  
李垒,任越美. 基于随机森林的高光谱遥感图像分类[J]. 计算机工程与应用,2016,52(24):189-193.  
[6] QI Y F,CHEN J,HUO Y L. A hyperspectral image classification algorithm combining Gabor filtering and 3D/2D

- convolution[J]. Journal of Optoelectronics • Laser, 2021, 32(5):477-484.
- 齐永锋,陈静,火元莲. 一种融合 Gabor 滤波与 3D/2D 卷积的高光谱图像分类算法[J]. 光电子·激光, 2021, 32(5):477-484.
- [7] LEE H, KWON H. Going deeper with contextual CNN for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2017, 26, 4843-4855.
- [8] ZHONG Z, LI J, LUO Z, et al. Spectral-spatial residual network for hyperspectral image classification: A 3-D deep learning framework[J]. Remote Sensing, 2017, 56: 847-858.
- [9] WANG W, DOU S, JIANG Z, et al. A fast dense spectral-spatial convolution network framework for hyperspectral images classification [J]. Remote Sensing, 2018, 10: 1068.
- [10] MA W, YANG Q, WU Y, et al. Double-branch multi-attention mechanism network for hyperspectral image classification[J]. Remote Sensing, 2019, 11(11):1307.
- [11] LI R, ZHENG S, DUAN C, et al. Classification of hyperspectral image based on double-branch dual-attention mechanism network[J]. Remote Sensing, 2020, 12(3): 582.
- [12] DAI J F, QI H Z, XIONG Y W, et al. Deformable convolutional networks[C]//2017 IEEE International Conference on Computer Vision (ICCV), Oct. 22-29, 2017, Venice, Italy, New York: IEEE, 17453116.
- [13] ZHU X Z, HU H, LIN S, et al. Deformable ConvNets v2: more deformable, better results [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA, New York: IEEE, 2019:19263462.
- [14] ZHU J, FANG L Y, GHAMISI P. Deformable convolutional neural networks for hyperspectral image classification [J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(8):1254-1258.
- [15] JIN Y Y, ZHANG S J. Adaptive receptive field convolutional neural network model[J/OL]. Journal of Chinese Computer Systems, (2021-09-07) [2021-09-09]. <http://kns.cnki.net/kcms/detail/21.1106.TP.20210906.1633.054.html>.
- 金勇逸,张孙杰.一种自适应感受野卷积神经网络模型[J/OL]. 小型微型计算机系统(2021-09-07) [2021-09-09]. <http://kns.cnki.net/kcms/detail/21.1106.TP.20210906.1633.054.html>.
- [16] YING X Y, WANG L G, WANG Y Q, et al. Deformable 3D convolution for video super-resolution[J]. IEEE Signal Processing Letters, 2020, 27:1500-1504.

#### 作者简介:

潘 新 (1974—),女,教授,博士生导师,主要从事图像处理与模式识别方面的研究.