

基于多尺度非对称密集网络的高光谱图像分类

蔡轶珩* 谭美伶 潘建军 何楷祺

(北京工业大学信息与通信工程学院 北京 100124)

摘要: 近年来, 基于有限标记样本的高光谱图像(HSI)分类方法取得了重大进展。然而, 由于高光谱图像的特殊性, 冗余的信息和有限的标记样本给提取强判别特征带来了巨大挑战。此外, 由于各类别像素分布不均, 如何强化中心像素的作用, 减弱不同类别的周围像素的负面影响也是提高分类性能的关键。为了克服上述局限性, 该文提出一种基于多尺度非对称密集网络(MS-ADNet)的高光谱图像分类方法。首先, 提出一个多尺度样本构建模块, 通过在每个像素周围提取多个尺度的图像块, 并进行反卷积和拼接以构建输入样本, 使其既包含详细的结构区域, 又包含较大的同质区域; 然后, 提出一个非对称密集连接结构, 在空间和光谱特征联合提取中实现核骨架增强, 即增强了方形卷积核的中心十字区域部分提取的特征, 有效地促进了特征重用。此外, 为了提高光谱特征的鉴别性, 提出一种精简的元素光谱注意力机制, 并将其置于密集连接网络的前端和后端。在每类仅采用5个样本进行网络训练的情况下, 该方法在Indiana Pines, Pavia University和Salinas数据集上的总体准确率分别达到了77.66%, 84.54%和92.39%, 取得了极具竞争力的分类结果。

关键词: 高光谱图像分类; 多尺度; 非对称卷积; 光谱注意力机制

中图分类号: TN911.73; TP751

文献标识码: A

文章编号: 1009-5896(2024)04-1448-10

DOI: [10.11999/JEIT230651](https://doi.org/10.11999/JEIT230651)

Hyperspectral Image Classification Based on Multi-scale Asymmetric Dense Network

CAI Yiheng TAN Meiling PAN Jianjun HE Kaiqi

(School of Information and Communications Engineering, Beijing University of Technology,
Beijing 100124, China)

Abstract: HyperSpectral Image (HSI) classification methods based on limited labeled samples have made significant progress in recent years. However, due to the specificity of hyperspectral images, redundant information and limited labeled samples pose great challenges for extracting highly discriminative features. In addition, owing to the uneven distribution of pixels in each category, how to strengthen the role of central pixels and attenuate the negative impact of surrounding pixels with different categories is also the key to improve the classification performance. To overcome the above limitations, an HSI classification method based on Multi-Scale Asymmetric Dense Network (MS-ADNet) is proposed. Firstly, a multi-scale sample construction module is proposed, which extracts multiple scale patches around each pixel and performs deconvolution and stitching to construct multiscale input samples that contain both detailed structural regions and large homogeneous regions. Next, an asymmetric densely connected structure is proposed to achieve kernel skeleton enhancement in joint spatial and spectral feature extraction, i.e., enhancement of features extracted from the central cross-skeleton portion of a square convolutional kernel, which effectively facilitates feature reuse. Moreover, to improve the discriminability of spectral features, a streamlined element spectral attention mechanism is proposed and placed at the front and back ends of the densely connected network. With only five samples per class used for network training, the proposed method achieves competitive classification results with overall accuracies of 77.66%, 84.54%, and 92.39% on the Indiana Pines, Pavia University, and Salinas datasets, respectively.

Key words: HyperSpectral Image (HSI) classification; Multiscale; Asymmetric convolution; Spectral attention mechanism

收稿日期: 2023-06-30; 改回日期: 2023-12-05; 网络出版: 2023-12-14

*通信作者: 蔡轶珩 caiyiheng@bjut.edu.cn

基金项目: 国家重点研发计划(2017YFC1703302)

Foundation Item: The National Key Research and Development Program of China (2017YFC1703302)

1 引言

高光谱图像 (HyperSpectral Image, HSI) 由高光谱成像仪捕获, 包含数百个窄光谱带信息和丰富的空间分布信息。图像分类作为高光谱图像分析中最重要也是最基本的问题, 广泛应用于农业生产、环境监测、资源勘测、军事侦察等领域^[1, 2]。

卷积神经网络(Convolutional Neural Network, CNN)通过局部连接和权值共享, 可以显著减少网络参数。此外, 通过分割数据块, 还可以同时捕获光谱信息和空间信息。因此, 其广泛应用于高光谱图像分类任务中。文献[3]提出了一种用于光谱-空间特征提取的3维卷积神经网络, 直接从原始数据中联合提取光谱和空间特征。文献[4]提出了一种3维卷积神经网络(3D-CNN)框架, 可以在不依赖任何预处理和后处理的情况下全面查看HSI立方体数据, 高效提取深层光谱-空间组合特征。除了CNN以外, 其他一些性能较好的网络也被用于高光谱图像分类^[5]。文献[6]采用以光谱矢量作为图信号构图的图卷积网络(Graph Convolutional Network, GCN)学习高光谱图像复杂的空间信息。文献[2]采用全卷积网络(Fully Convolutional Network, FCN)学习高光谱图像的深层特征。此外, 生成对抗网络^[7]、递归神经网络^[8]和胶囊网络^[9]等也被引入HSI分类。

理论上, 网络越深, 它的拟合能力越强。然而实际上, 随着深度的增加, 网络训练过程中可能会出现梯度消失或梯度爆炸等问题。为了解决这些问题, 研究人员引入了残差连接和密集连接来加速信息流动, 使网络更快更好地收敛。文献[10]提出的光谱-空间残差网络(Spectral-Spatial Residual Network, SSRN)引入了残差结构, 缓解了深度模型的精度下降现象。文献[11]提出了一种快速密集光谱-空间卷积网络(Fast Dense Spectral-Spatial Convolution network, FDSSC), 增加了层与层之间的连接, 有效地减少了梯度消失现象。文献[12]引入密集连接的光谱块和残差空间块来缓解精度下降现象。

高光谱图像由于波段之间的相关性以及环境的噪声及光照变化, 导致其包含较多的冗余信息。为了使网络聚焦于感兴趣的区域, 从而提取有价值的信息, 一些学者在高光谱图像分类算法中引入了注意力机制, 以提高分类精度。文献[13]引入了压缩和激励(Squeeze-and-Excitation, SE)模块, 以实现光谱注意力机制。文献[14]提出了一种3维级联光谱-空间元素注意网络, 分别使用3维卷积获取权重向量, 选择有利于分类的空间和光谱特征, 并将其

应用到参数较少的网络中。文献[15]提出了一种3维混合注意力模块, 可以同时光谱信息和空间信息进行注意力加权。文献[16]将光谱注意力模块置于网络的前端, 用于从原始输入数据中选择光谱波段, 强调对分类有用的波段, 抑制无用的波段。文献[17]采用Transformer中的多头自注意力模块实现局部空间语义信息及光谱序列信息的相关性建模, 从而突出重要的光谱和空间特征。具有不同大小感受野的卷积层倾向于关注不同尺度的信息。为了保证提取的特征能够捕获多尺度信息, 研究人员引入了多尺度模块。文献[2]引入不同膨胀率的空洞卷积以实现多尺度特征提取。文献[18]采用不同大小的卷积核并行连接提取多尺度特征。

在研究人员对网络结构的不断改进中, 样本量充足的情况下, 模型达到了很高的分类精度。然而, 由于标注高光谱数据耗时费力, 所需训练样本较多的分类模型不利于高光谱遥感的广泛应用。在有限标记样本情形下, 训练一个能从冗余的光谱和空间信息中提取鉴别性特征用于准确分类的网络至关重要。现有的方法主要从两方面着手, 一是引入额外数据辅助训练网络, 二是改进网络结构以充分提取样本的鉴别性特征。为了引入额外数据辅助训练网络, 文献[19]将未标记样本增强后生成的两个视图送入残差网络进行对比学习以增强网络对同类样本和不同类样本的区分能力, 然后用少量带标签样本对分类层进行微调。文献[20]采用元学习范式进行小样本学习, 引入标记样本充足的高光谱数据集来训练网络的自主区分能力, 以便将从源域获得的知识迁移到目标域。为了改进网络结构以充分提取样本的鉴别性特征, 文献[21]提出了一种新颖的、极其轻量级的非深度并行网络, 利用逐点卷积和逐通道动态卷积分别提取光谱和空间特征进行融合。文献[22]提出了双GCN的有监督分类方法, 两个GCN分别提取HSI样本特征和标签分布信息后整合, 以减少类间距离, 从而提高分类精度。文献[23]提出了双分支双注意机制网络, 在两个分支上分别提取光谱和空间特征。总的来说, 网络结构的改进侧重于提出有价值的模块来增强网络的特征提取能力, 引入辅助数据这类方法侧重于引入额外数据对网络进行预训练, 以期增强网络的区分能力。考虑到网络结构在特征提取方面的重要性, 本文主要从网络改进的角度入手, 以构建一个具有鉴别性特征提取能力的网络。

现有网络主要采用3维卷积来提取光谱和空间特征, 同时引入注意力机制和采用多尺度数据块作为输入, 以增强提取的特征的鉴别性。尽管已经取

得了不错的进展,但仍有可提升的空间。首先,现有网络对多尺度数据块的特征提取往往采用多个分支网络分别提取后再融合,网路参数量较大。其次,现有网络的3维卷积通常采用方形卷积对空间信息进行均匀提取,可能无法充分捕获数据中重要的空间细节。另外,现有光谱注意力机制多使用1维权重系数对提取的3维特征进行逐平面加权,可能导致部分空间信息的丢失。为了解决上述问题,在现有方法基础上,本文提出一种用于HSI分类的多尺度非对称密集网络(Multi-Scale Asymmetric Dense Network, MS-ADNet),本网络通过多尺度样本构建模块、非对称密集连接模块和光谱特征细化模块,可以有效地提取多尺度数据块中的光谱和空间特征,同时,对中心骨架部分的特征实现增强,从而克服了方形卷积核对空间邻域信息均匀提取的不足,提升了特征的强鉴别性,缓解了标记样本不足问题,并有效提升了类别像素分布零散情况下的分类精度。具体地,本研究的贡献如下:(1)提出多尺度样本构建模块,通过在每个像素周围截取多个尺度的图像块,然后进行反卷积和拼接,以将多尺度输入数据放大到同一尺度,从而在随后的单一分支网络中进行特征提取。该模块解决了现有网络多个尺度分支包含较多参数的问题。(2)引入非对称卷积块,并构建了非对称密集连接结构,以提取具有内核骨架增强的空间和光谱特征。(3)利用频谱

卷积和激活函数,提出一种新的元素光谱注意力模块,使用3维权重系数有效地对3维特征张量进行逐元素加权,从而提高了光谱间的连通性,增强了关键波段信息,避免了空间信息的模糊化。值得注意的是,本文在特征提取模块的前端和后端都加入了这种注意力机制,以保留重要的原始光谱波段并细化提取的特征。

2 多尺度非对称密集网络

2.1 MS-ADNet概述

为了在有限的训练样本下获得较高的分类精度,本文设计了一个多尺度非对称密集网络,本网络可以提取高鉴别性的空间和光谱特征。具体结构如图1所示。

MS-ADNet主要由3个部分组成:数据预处理部分、特征提取部分和分类部分。由于待分类对象往往属于不同的类别,且各类别区域的大小形状各异,因此,数据预处理部分在每个高光谱像素周围截取多尺度图像块,并通过多尺度样本构建模块对图像块进行反卷积和拼接,在不增加后续网络分支的情况下构建多尺度输入样本,以体现不同尺度的上下文信息。在特征提取部分,为了实现光谱信息和空间信息的联合提取并弥补3维卷积参数量较多这一不足,本文引入了深度可分离卷积。其次,为了增强卷积层的表示能力,弥补方形卷积核在提取

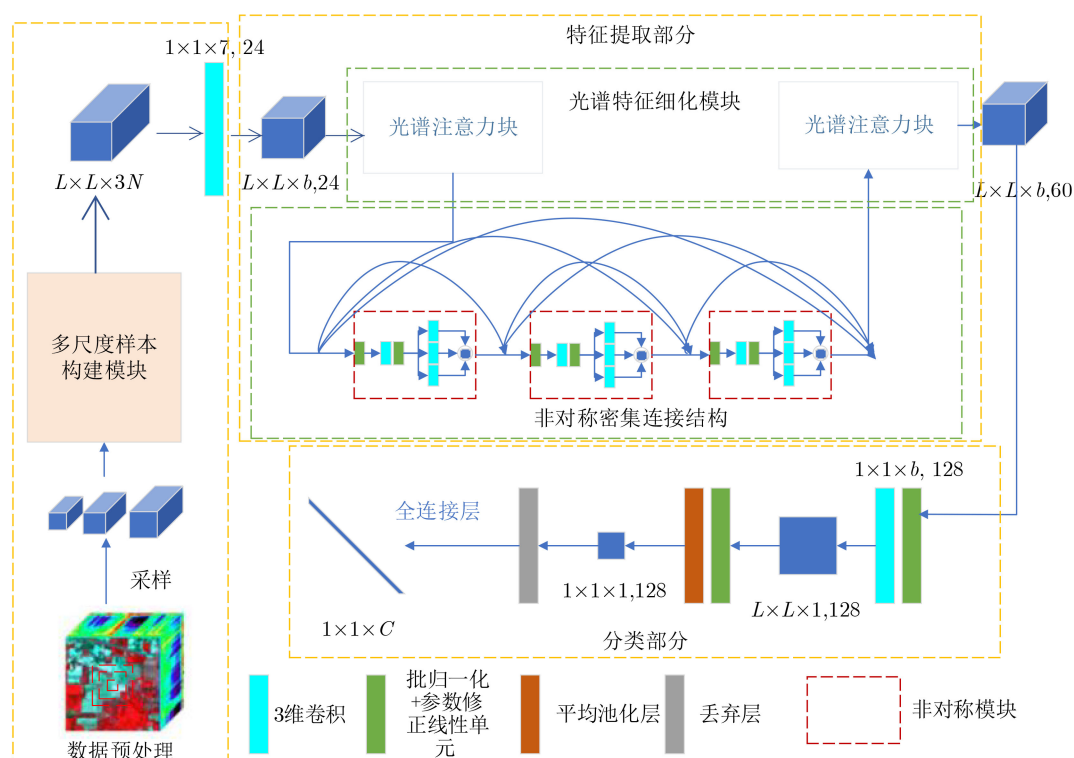


图1 MS-ADNet结构

空间信息方面的不足，本文采用3分支的非对称卷积块与光谱卷积级联，从而构建非对称模块，并将其密集连接以促进特征重用。此外，为了提取关键的光谱信息，本文提出了一个精简的元素光谱注意力模块，它仅使用光谱卷积和激活函数来生成加权系数，所需的参数和计算量更少。另一方面，它对3维数据进行逐元素加权，保留了空间细节信息。与传统网络实现中间特征的注意力加权不同，本文将设计的注意力模块置于密集连接模块的前端和后端，使其既作用于原始HSI数据块，也作用于提取的特征。最后，分类部分利用3D-CNN和平均池化层对提取的特征进行维度变换，生成 $1 \times 1 \times C$ 向量完成分类，其中 C 表示类别数。

2.2 多尺度样本构建模块

由于采用单一尺度数据作为输入的网络不能很好地对不同形状和大小的物体进行分类，在文献[24]中，多尺度图像块作为输入样本被证明对网络分类性能的提升是有效的。然而，已有的网络对多尺度数据块的特征提取往往采用多个分支网络分别提取后再融合，网络参数量较大。为了解决这一问题，本文提出多尺度样本构建模块，并将其嵌入到特征提取网络之前。该模块的作用是将多个尺度的输入数据块放大到同一尺寸，以便后续的单分支网络进行特征提取并实现权值共享。同时，通过最大化利用有限标记样本周围像素点来充分提取不同感知域的特征，这有助于建立小样本像素点与更多的空间和光谱信息之间的联系，以扩充小样本提供的信息量。具体地，通过在高光谱像素周围截取多个尺度的图像块，以表示不同尺度的上下文信息，然后采用反卷积将多尺度样本放大到固定尺寸，同时反卷积也可以自适应地提取不同尺度的重要数据。此外，该模块将多尺度样本沿通道维拼接以适应单分支网络。具体结构如图2所示。

2.3 非对称密集连接结构

密集连接结构不仅能提取深层特征和缓解梯度消失现象，还能增强特征的传播和重用。因此，它适用于高维数据的特征提取。然而，现有的密集连接网络主要依靠3维卷积来提取光谱和空间特征，空间特征的均匀提取不利于网络分类性能的提升。为此，本文提出一个非对称密集连接结构，如图3所示。本结构将非对称模块与密集连接相结合，可以有效地提取具有核骨架增强的空间和光谱特征，同时实现特征重用。非对称模块由光谱卷积和非对称卷积块级联而成。其中，非对称卷积块由并行的垂直卷积、水平卷积和方形卷积组成。水平卷积和垂直卷积统称为1维非对称卷积。在训练过程中，1维非对称卷积将学习到的知识叠加到方形卷积层中，以增强卷积层的特征表示能力，从而充分利用中心像素周围十字区域的像素点信息。如图3中蓝色方格所示，以左上角滑动窗口为例，3个卷积产生的特征图之和等于3个卷积核叠加产生的特征图，证明了非对称卷积对核骨架的增强作用，使得

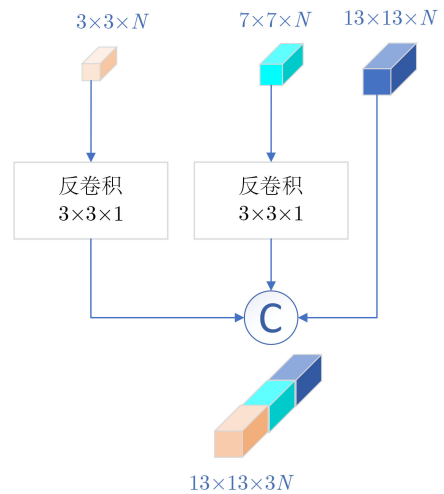


图2 多尺度样本构建模块

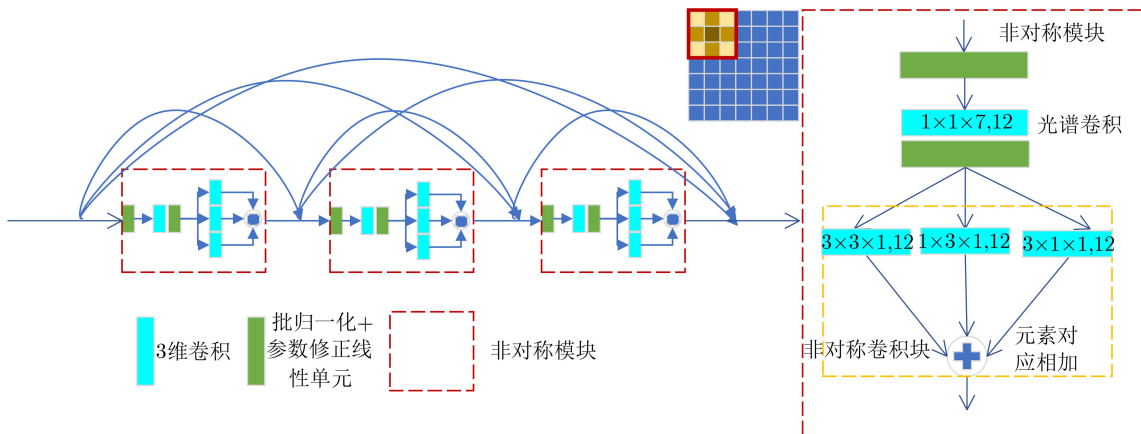


图3 非对称密集连接结构

提取足够的空间信息成为可能。级联的光谱卷积和非对称卷积块采用了深度可分离卷积的思想,有效地减少了网络的参数量。

2.4 元素光谱注意力模块

由于不同的光谱波段对分类的贡献不同,研究者提出了SE模块^[25]和高效通道注意力(Efficient Channel Attention, ECA-Net)^[26]对光谱波段进行注意力加权,这是目前最经典的两种光谱注意力机制。然而,上述两种机制均使用池化操作将3维特征块转换为1维特征向量后生成权重系数,模糊了样本的空间布局。为了解决上述问题,本文提出了一种元素光谱注意力机制。其结构如图4所示,它去除了池化操作,并将逐平面加权替换为逐元素的特征加权。此外,本文提出的注意力机制利用光谱卷积来优化SE模块中涉及的全连接层,大大减少了参数的数量,同时当前波段仅与相邻的高相关性光谱波段相互作用,保持了相当的性能。

3 实验结果与分析

3.1 实验数据集

选择印第安纳州松树数据集(INdiana pines, IN)、帕维亚大学数据集(the University of Pavia, UP)、萨利纳斯山谷数据集(SALinas, SA)和茶树等10种地类高光谱遥感数据集(TeaData)这4个数据集来评估MS-ADNet模型的性能。IN数据集包含 145×145 个像素和224个光谱反射带,波长范围为 $0.4 \sim 2.5 \mu\text{m}$ 。去除覆盖吸水区的波段外,剩余200个波段可用。在该数据集中,16类地物的共10 249个像素被标记,其中大部分是农作物。UP数据集的光谱覆盖范围为 $0.43 \sim 0.86 \mu\text{m}$,包含103个光谱波段。该数据集的大小为 610×340 ,包含9个类别的42 776个标记像素。SA数据集包含 512×217 个像素和204个波段。其中,54 129个像素被标记,共包含16个类别,如休耕,芹菜等。TeaData数据集由航空推扫式高光谱成像仪(Pushbroom Hyperspectral Imager, PHI)在中国江苏省常州市方麓村茶树

种植基地收集。它包含 348×512 个像素和80个光谱波段,光谱范围为 $0.417 \sim 0.855 \mu\text{m}$ 。其中,53 734个像素被标记,共包含10个类别,如马尾松、竹林、茶树、芦苇等。

3.2 实验设置

本实验采用总体分类精度(Overall Accuracy, OA)、平均分类精度(Average Accuracy, AA)和Kappa系数作为分类结果的评价指标。在本实验中,每类选用5个带标签样本训练网络,其余样本用于测试。在训练过程中,使用Adam优化器对网络参数进行优化,并采用交叉熵损失作为损失函数。此外,学习率、批大小和epoch数分别设置为0.000 3,10和150。为了更好地分析,本文中所有实验均在搭载Intel Xeon(R) Silver 4214R CPU和Nvidia RTX2080TI GPU的设备上运行。设备使用的系统为Ubuntu18.04,网络框架为Pytorch。

在3个真实数据集上,研究了单一尺度下具有不同空间大小的原始数据对MS-ADNet分类性能的影响,以确定用作网络输入的基准大小。具体结果如图5所示,从图5可以看出,随着空间大小的增加,3种数据集的总体分类精度都呈现先升后降的趋势,当空间大小为 13×13 时,3种数据集的分类性能均达到最优。因此,采用 13×13 作为基准空间大小。考虑到大多数类别的样本体积小且分布碎片化,选择小尺度块与 13×13 的基准块组成多尺度输入图像块。本文测试了空间大小为(3,5,13),(3,7,13)和(3,5,7,13)这3种多尺度方案,从图6可以看出,(3,7,13)这一多尺度方案分类精度最高,故而,本文采用(3,7,13)这一多尺度方案。在光谱注意力模块中,考虑到核大小为 $1 \times 1 \times 5$ 的光谱卷积无法充分捕获到当前光谱波段周围的光谱信息,而 $1 \times 1 \times 9$ 的卷积核则过大,导致提取的光谱特征受到较远光谱波段的干扰。因此,本文选择 $1 \times 1 \times 7$ 作为光谱卷积核的尺寸,以在充分考虑周围光谱信息的同时避免过度扩展。

3.3 实验结果

为了验证所提MS-ADNet的有效性,本文将所提方法与两种经典方法(3D-CNN^[4]和FDSSC^[11])和3种基于有限标记样本的创新方法(深度少样本学习(Deep Few-Shot Learning, DFSL)+支持向量机(Support Vector Machine, SVM)^[27]、深度多视图学习(Deep MultiView Learning, DMVL)^[19]和深度跨域少样本学习(Deep Cross-domain Few-Shot Learning, DCFSL)^[20])进行比较。以上方法的参数均与原文一致,且每个类使用5个带标签样本训练网络。为了消除随机抽样的影响,所有实验均进行

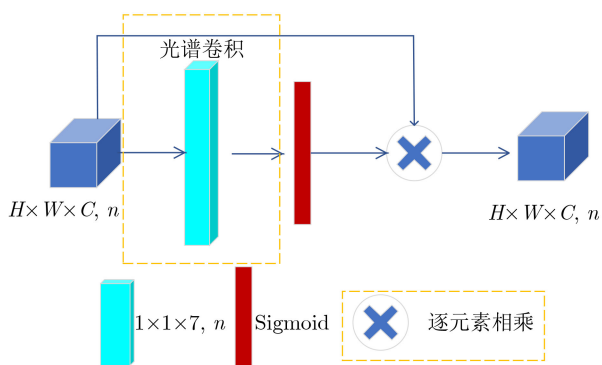


图4 元素光谱注意力模块

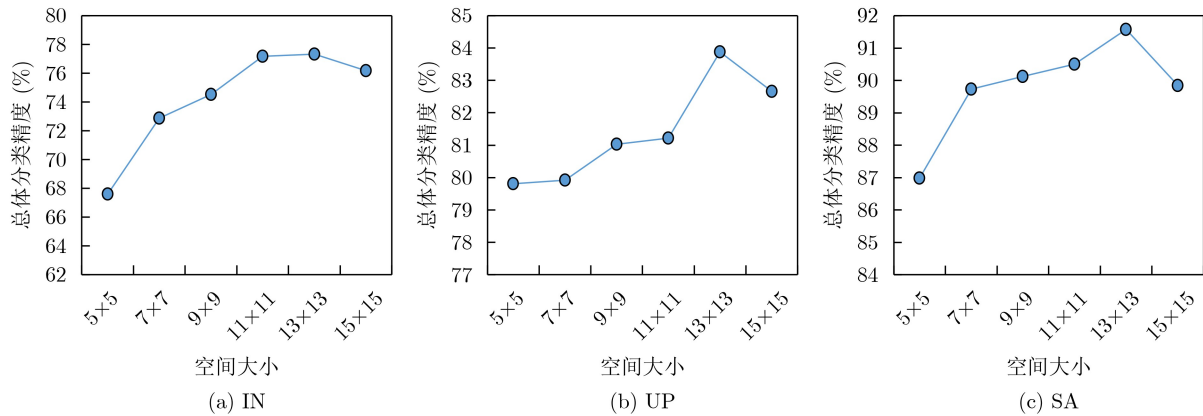


图5 不同空间大小对3个数据集分类准确性的影响

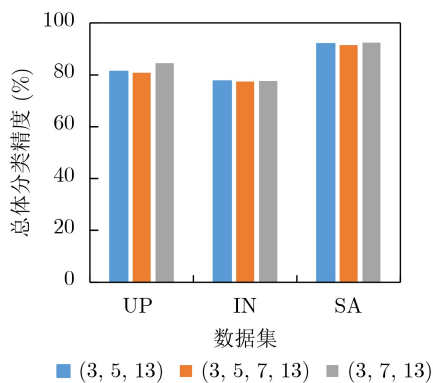


图6 不同多尺度方案对3个数据集分类准确性的影响

10次。表1-表3给出了本文方法和5种比较方法在3个高光谱数据集上的特定类别分类精度、总体精度、平均精度和kappa系数。

从表1-表3可以看出，所提MS-ADNet在大多数指标上都达到了最佳性能。在UP数据集上，MS-ADNet的OA, AA和Kappa分别为84.54%, 85.65%和80.46%，对比方法中表现最好的DCFSL算法分别高出0.89%,1.88%和1.76%。此外，该方法在类

内分布较为分散的类别4和类别9上取得了最优的分类精度。对于呈条状分布的类别1和类别8，该方法也取得了优异的分类性能，证明了非对称结构强化中心骨架像素的有效性。在SA数据集上，MS-ADNet的OA, AA和Kappa分别为92.39%, 95.61%和91.56%，对比方法中的最优算法DCFSL分别高出3.05%, 1.57%和3.39%。此外，MS-ADNet在13个类别上的分类精度超过95%，优于DCFSL仅在10个类别上的分类精度超过95%，进一步证明了所提方法在提取鉴别性特征方面的优异性能。由于SA数据集上各类别样本分布相对均衡，很明显，所提MS-ADNet在这种类型的数据集上表现最好。在IN数据集上，MS-ADNet的OA, AA和Kappa分别为77.66%, 77.10%和74.89%，优于对比方法仅在部分指标上高于70%，证明了所提方法对鉴别性特征提取的强化作用。而AA略低于DCFSL，这可能是由于IN数据集中某些类别的数据量相对较少，如类别7和类别9。综上所述，MS-ADNet无论是与3D-CNN, FDSSC等经典算法相比，还是与DFSL+

表1 UP数据集上的分类结果对比(%)

类别	3D-CNN	FDSSC	DFSL+SVM	DMVL	DCFSL	MS-ADNet
1	59.82	92.03	73.43	62.69	82.20	97.04
2	63.05	96.44	89.25	96.00	87.74	98.19
3	68.91	59.30	48.09	84.26	67.46	69.77
4	77.31	67.75	84.72	36.70	93.16	93.49
5	90.77	96.82	99.65	86.22	99.49	98.56
6	63.40	77.88	67.81	90.86	77.32	61.08
7	87.64	69.53	64.48	82.11	81.18	79.13
8	57.27	73.36	67.37	79.10	66.73	74.91
9	95.57	92.18	92.92	22.56	98.66	98.75
OA	65.74±1.77	81.10±6.93	79.63±1.09	73.81±5.40	83.65±1.77	84.54±0.05
AA	73.72±1.01	80.59±5.31	76.41±1.39	71.17±3.20	83.77±1.74	85.65±0.03
Kappa	57.37±1.97	76.07±8.48	73.05±1.60	66.87±6.16	78.70±2.01	80.46±0.06

表 2 SA数据集上的分类结果对比(%)

类别	3D-CNN	FDSSC	DFSL+SVM	DMVL	DCFSL	MS-ADNet
1	95.29	98.16	73.92	97.06	99.40	100
2	97.20	99.01	96.85	97.83	99.76	100
3	91.45	95.59	96.28	97.79	91.96	95.45
4	97.31	95.94	99.11	54.39	99.55	95.76
5	91.24	94.56	80.72	87.34	92.70	99.62
6	98.80	99.56	91.63	90.83	99.52	99.98
7	99.69	99.23	97.73	94.95	98.88	98.89
8	66.40	81.45	82.33	93.35	74.57	90.43
9	96.25	99.29	94.44	98.27	99.59	99.30
10	70.72	94.77	80.96	97.36	86.42	95.42
11	93.15	94.79	93.38	76.91	96.61	95.63
12	99.65	99.32	97.94	96.06	99.93	98.70
13	92.63	96.53	95.79	76.24	99.30	96.64
14	93.56	85.97	98.87	71.96	98.85	91.10
15	68.02	65.34	71.13	82.53	75.38	73.04
16	81.41	99.87	90.57	100.0	92.22	99.84
OA	84.20±2.62	88.62±4.03	86.95±1.30	89.16±1.63	89.34±2.19	92.39±0.03
AA	89.56±1.79	93.71±1.82	90.08±1.44	88.30±1.42	94.04±1.14	95.61±0.01
Kappa	82.46±2.90	87.37±4.44	85.51±1.42	87.98±1.79	88.17±2.40	91.56±0.03

表 3 IN数据集上的分类结果对比(%)

类别	3D-CNN	FDSSC	DFSL+SVM	DMVL	DCFSL	MS-ADNet
1	95.12	67.79	96.75	24.33	95.37	77.38
2	37.70	71.03	36.38	72.38	43.26	81.35
3	19.77	63.69	38.34	66.77	57.95	65.49
4	32.51	63.70	77.16	63.73	80.60	57.33
5	88.45	86.87	73.92	74.91	72.91	89.73
6	73.65	95.08	86.25	66.49	87.96	98.03
7	81.82	32.92	97.10	29.79	99.57	43.75
8	53.35	99.31	81.82	86.39	86.26	99.60
9	100.0	17.24	75.56	13.74	99.33	53.62
10	41.35	53.21	52.22	77.67	62.44	61.22
11	66.71	86.98	59.96	86.68	62.75	84.58
12	37.40	69.73	36.56	83.26	48.72	67.83
13	85.71	72.71	98.00	47.00	99.35	95.43
14	62.57	93.49	84.63	91.16	85.40	97.01
15	56.42	68.57	74.10	66.41	66.69	78.03
16	90.36	53.84	100.0	31.11	97.61	83.27
OA	54.76±0.03	72.49±4.12	61.69±1.85	70.26±4.86	66.81±2.37	77.66±0.06
AA	63.93±0.02	68.51±3.05	73.05±0.84	61.36±3.00	77.89±0.86	77.10±0.04
Kappa	48.72±0.03	69.38±4.42	56.78±1.90	66.92±5.16	62.64±0.86	74.89±0.07

SVM, DMVL, DCFSL等在小样本情况下分类效果优异的算法相比,即使每个类别只使用5个样本作

为训练数据,均表现出了优异的性能优势,足以证明该方法非常适合样本量有限的情况。

为了评估MS-ADNet的综合性能，本文将它的参数量和训练时间与其他方法进行了比较。具体结果见表4。从中可以看出，在3个数据集上，尽管相较于分类准确率较低的3D-CNN, FDSSC和DFSL+SVM, MS-ADNet参数和训练时间较多，但相比于分类准确率较高的DMVL和DCFSL方法，MS-ADNet的参数和训练时间明显较少。这是因为MS-ADNet采用了深度可分离卷积的思想，并用频谱卷积取代了注意力机制中的全连接层，从而减少了参数数量，进而减少了网络的训练时间。这表明本文方法在达到小样本条件下较高分类准确率的同时，参数量和训练时间也相对较少。

3.4 消融实验

3.4.1 非对称密集连接结构

为了证明非对称密集连接结构在提取更多判别特征方面的能力，在不改变其他网络结构的情况下，本文分别比较了嵌入非对称密集连接结构、密集光谱块与密集空间块的级联结构和对称密集连接结构时模型精度的变化。如图7(a)所示，使用对称密集连接结构的网络在UP, IN和SA数据集上的分类准确率均优于使用级联的密集光谱块和密集空间块的网路，说明光谱和空间特征的联合提取比分开提取能提取更多利于分类的特征。进一步地，使用

非对称密集连接结构的网络在3个数据集上的总体分类精度优于使用对称密集连接结构的网络，说明非对称密集连接结构可以有效提高提取的空间特征的判别能力。

3.4.2 元素光谱注意力模块

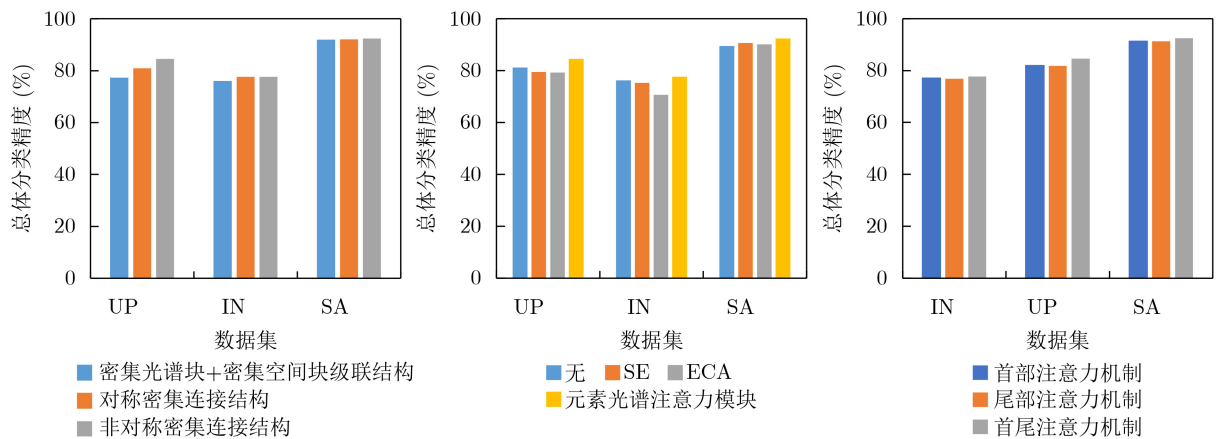
为了验证光谱注意力机制在增强有价值的光谱特征和减少不相关的光谱特征方面的有效性，本文分别比较了没有注意力机制和嵌入SE块、ECA块和元素光谱注意力模块时所提模型的精度变化。结果如图7(b)所示，元素光谱注意力机制显著提高了网络在UP, IN和SA数据集上的分类准确率，分别提高了3.34%, 1.41%和2.83%，表明提出的光谱注意力机制在强化有利于分类的光谱特征方面是有效的。与SE和ECA注意力模块相比，由于所提注意力模块在加权过程中保留了样本的空间布局，因此，其性能明显更好。

3.4.3 首尾注意力机制

为了验证首尾注意力机制从原始数据中选择关键信息，同时突出区分性特征的有效性，本文对所提网络使用首尾注意力机制，首部注意力机制和尾部注意力机制在3个高光谱数据集上的性能进行了比较。具体结果如图7(c)所示，可以明显看出，使用首尾注意力机制的网络的整体准确率高于使用单

表4 网络参数量和训练时间对比

方法	IN		SA		UP	
	参数量(M)	训练时间(min)	参数量(M)	训练时间(min)	参数量(M)	训练时间(min)
3D-CNN	0.096	1.039	0.098	1.051	0.048	0.898
FDSSC	1.230	0.990	1.250	1.180	0.640	0.260
DFSL+SVM	0.033	7.922	0.033	8.084	0.033	10.848
DMVL	24.620	141.200	24.620	243.100	24.620	197.700
DCFSL	4.070	20.920	4.070	21.120	4.060	20.670
MS-ADNet	2.330	18.430	2.380	18.890	1.210	5.090



(a) 非对称密集连接结构的有效性验证 (b) 光谱注意力机制的有效性验证 (c) 首尾光谱注意力机制的有效性验证

图7 各结构的有效性验证

一注意力机制的网络,说明增强原始数据和提取的特征中的关键光谱信息有助于提升网络性能。值得注意的是,具有首部注意力机制的网络在所有3个数据集上的表现都优于具有尾部注意力机制的网络,这突出了从原始数据中选择关键光谱信息的重要性。

3.5 附加验证

为了全面验证MS-ADNet在高光谱地物分类上的性能,本文在国产高光谱数据集TeaData上进行了附加验证。采用的对比方法为在前述实验中表现较好的3种方法。结果如表5所示,MS-ADNet在TeaFarm数据集上的OA,AA和Kappa分别为91.82%,87.08%和88.40%。与对比方法相比,MS-ADNet在OA和Kappa方面表现出色,取得了最高的结果,而其AA值仅略低于DCFSL。具体地,MS-ADNet在呈条状分布的类别3和类别5上取得了最优的分类精度,印证了非对称结构对中心骨架像素的增强作用。在呈小块散状分布的类别6上,MS-ADNet也表现出了不错的性能优势。对于分布比较聚集的类别1和9,提出的MS-ADNet在这类类别上仍旧取得了优异的分类准确率。从而验证了MS-ADNet能够提取更具鉴别性的特征,并对小块散状分布的类别的分类性能较好。

4 结论

本文针对现有方法中特征提取不充分,零散样本分类精度亟待提升等问题,提出一种新的高光谱图像分类方法MS-ADNet。通过多尺度图像块采样和多尺度样本构建模块,构建多尺度输入样本,使得输入样本既包含详细的结构区域,又包含较大的同质区域,并适用于单分支网络。为了减少3维CNN

的参数,增强卷积核的表征能力,本文提出了非对称模块,并将其密集连接以实现特征重用。此外,本文提出了一种元素光谱注意力机制来选择更多的判别性光谱特征,在有限的参数下取得了良好的性能。在3个公共数据集上的实验表明该方法在性能方面取得了优异的效果,尤其对于样本分布分散的数据集效果显著。

参考文献

- [1] YAO Ding, ZHANG Zhili, ZHAO Xiaofeng, *et al.* Deep hybrid: Multi-graph neural network collaboration for hyperspectral image classification[J]. *Defence Technology*, 2023, 23: 164–176. doi: [10.1016/j.dt.2022.02.007](https://doi.org/10.1016/j.dt.2022.02.007).
- [2] WANG Xue, TAN Kun, DU Peijun, *et al.* A unified multiscale learning framework for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 4508319. doi: [10.1109/tgrs.2022.3147198](https://doi.org/10.1109/tgrs.2022.3147198).
- [3] CHEN Yushi, JIANG Hanlu, LI Chunyang, *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. doi: [10.1109/TGRS.2016.2584107](https://doi.org/10.1109/TGRS.2016.2584107).
- [4] LI Ying, ZHANG Haokui, and SHEN Qiang. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network[J]. *Remote Sensing*, 2017, 9(1): 67. doi: [10.3390/rs9010067](https://doi.org/10.3390/rs9010067).
- [5] 刘娜, 李伟, 陶然. 图信号处理在高光谱图像处理领域的典型应用[J]. *电子与信息学报*, 2023, 45(5): 1529–1540. doi: [10.11999/JEIT220887](https://doi.org/10.11999/JEIT220887).
- LIU Na, LI Wei, and TAO Ran. Typical Application of graph signal processing in hyperspectral image processing[J]. *Journal of Electronics & Information Technology*, 2023, 45(5): 1529–1540. doi: [10.11999/JEIT220887](https://doi.org/10.11999/JEIT220887).
- [6] SHAHRAKI F F and PRASAD S. Graph convolutional neural networks for hyperspectral data classification[C]. 2018 IEEE Global Conference on Signal and Information Processing, Anaheim, USA, 2018: 968–972. doi: [10.1109/GlobalSIP.2018.8645969](https://doi.org/10.1109/GlobalSIP.2018.8645969).
- [7] ZHU Lin, CHEN Yushi, GHAMISI P, *et al.* Generative adversarial networks for hyperspectral image classification[J]. *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).
- [8] MOU Lichao, GHAMISI P, and ZHU Xiaoxiang. Deep recurrent neural networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(7): 3639–3655. doi: [10.1109/TGRS.2016.2636241](https://doi.org/10.1109/TGRS.2016.2636241).
- [9] ZHU Kaiqiang, CHEN Yushi, GHAMISI P, *et al.* Deep

表5 TeaFarm数据集上的分类结果对比(%)

类别	FDSSC	DMVL	DCFSL	MS-ADNet
1	91.60	92.28	92.64	95.59
2	53.18	81.00	74.79	62.51
3	99.34	96.98	88.30	99.63
4	86.99	42.30	100	91.90
5	97.75	91.22	98.68	98.88
6	47.48	24.24	89.63	91.83
7	82.53	25.37	99.06	77.94
8	51.92	36.23	60.59	57.71
9	100	99.46	98.83	99.99
10	75.05	46.01	100	94.83
OA	86.45±0.07	82.38±3.80	90.47±1.09	91.82±0.01
AA	78.58±0.06	63.51±3.53	90.25±0.77	87.08±0.03
Kappa	81.83±0.09	75.47±4.63	86.51±1.32	88.40±0.02

- convolutional capsule network for hyperspectral image spectral and spectral-spatial classification[J]. *Remote Sensing*, 2019, 11(3): 223. doi: [10.3390/rs11030223](https://doi.org/10.3390/rs11030223).
- [10] ZHONG Zilong, LI J, LUO Zhiming, *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. doi: [10.1109/TGRS.2017.2755542](https://doi.org/10.1109/TGRS.2017.2755542).
- [11] WANG Wenju, DOU Shuguang, JIANG Zhongmin, *et al.* A fast dense spectral-spatial convolution network framework for hyperspectral images classification[J]. *Remote Sensing*, 2018, 10(7): 1068. doi: [10.3390/rs10071068](https://doi.org/10.3390/rs10071068).
- [12] CAI Yiheng, GUO Yajun, LANG Shinan, *et al.* Classification of hyperspectral images by spectral-spatial dense-residual network[J]. *Journal of Applied Remote Sensing*, 2020, 14(3): 036513. doi: [10.1117/1.JRS.14.036513](https://doi.org/10.1117/1.JRS.14.036513).
- [13] FANG Bei, LI Ying, ZHANG Haokui, *et al.* Hyperspectral images classification based on dense convolutional networks with spectral-wise attention mechanism[J]. *Remote Sensing*, 2019, 11(2): 159. doi: [10.3390/rs11020159](https://doi.org/10.3390/rs11020159).
- [14] YAN Huaiping, WANG Jun, TANG Lei, *et al.* A 3D cascaded spectral-spatial element attention network for hyperspectral image classification[J]. *Remote Sensing*, 2021, 13(13): 2451. doi: [10.3390/rs13132451](https://doi.org/10.3390/rs13132451).
- [15] PAN Jianjun, CAI Yiheng, TAN Meiling, *et al.* Multiscale residual weakly dense network with attention mechanism for hyperspectral image classification[J]. *Journal of Applied Remote Sensing*, 2022, 16(3): 034504. doi: [10.1117/1.JRS.16.034504](https://doi.org/10.1117/1.JRS.16.034504).
- [16] ZHU Minghao, JIAO Licheng, LIU Fang, *et al.* Residual spectral-spatial attention network for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(1): 449–462. doi: [10.1109/TGRS.2020.2994057](https://doi.org/10.1109/TGRS.2020.2994057).
- [17] SUN Le, ZHAO Guangrui, ZHENG Yuhui, *et al.* Spectral-spatial feature tokenization transformer for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5522214. doi: [10.1109/TGRS.2022.3144158](https://doi.org/10.1109/TGRS.2022.3144158).
- [18] CAI Yiheng, XIE Jin, LANG Shinan, *et al.* Hyperspectral image classification using multi-branch-multi-scale residual fusion network[J]. *Journal of Applied Remote Sensing*, 2021, 15(2): 024512. doi: [10.1117/1.JRS.15.024512](https://doi.org/10.1117/1.JRS.15.024512).
- [19] LIU Bing, YU Anzhu, YU Xuchu, *et al.* Deep multiview learning for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(9): 7758–7772. doi: [10.1109/TGRS.2020.3034133](https://doi.org/10.1109/TGRS.2020.3034133).
- [20] LI Zhaokui, LIU Ming, CHEN Yushi, *et al.* Deep cross-domain few-shot learning for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5501618. doi: [10.1109/TGRS.2021.3057066](https://doi.org/10.1109/TGRS.2021.3057066).
- [21] XUE Zhixiang, YU Xuchu, LIU Bing, *et al.* HresNetAM: Hierarchical residual network with attention mechanism for hyperspectral image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 3566–3580. doi: [10.1109/JSTARS.2021.3065987](https://doi.org/10.1109/JSTARS.2021.3065987).
- [22] HE Xin, CHEN Yushi, and GHAMISI P. Dual graph convolutional network for hyperspectral image classification with limited training samples[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5502418. doi: [10.1109/TGRS.2021.3061088](https://doi.org/10.1109/TGRS.2021.3061088).
- [23] LI Rui, ZHENG Shunyi, DUAN Chenxi, *et al.* Classification of hyperspectral image based on double-branch dual-attention mechanism network[J]. *Remote Sensing*, 2020, 12(3): 582. doi: [10.3390/rs12030582](https://doi.org/10.3390/rs12030582).
- [24] XIE Jie, HE Nanjun, FANG Leyuan, *et al.* Multiscale densely-connected fusion networks for hyperspectral images classification[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, 31(1): 246–259. doi: [10.1109/TCSVT.2020.2975566](https://doi.org/10.1109/TCSVT.2020.2975566).
- [25] HU Jie, SHEN Li, and SUN Gang. Squeeze-and-excitation networks[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 7132–7141. doi: [10.1109/CVPR.2018.00745](https://doi.org/10.1109/CVPR.2018.00745).
- [26] WANG Qilong, WU Banggu, ZHU Pengfei, *et al.* ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, USA, 2020: 11531–11539. doi: [10.1109/CVPR42600.2020.011155](https://doi.org/10.1109/CVPR42600.2020.011155).
- [27] LIU Bing, YU Xuchu, YU Anzhu, *et al.* Deep few-shot learning for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(4): 2290–2304. doi: [10.1109/TGRS.2018.2872830](https://doi.org/10.1109/TGRS.2018.2872830).

蔡轶珩: 女, 副教授, 研究方向为图像处理和模式识别。

谭美伶: 女, 硕士生, 研究方向为图像和信息处理。

潘建军: 男, 硕士生, 研究方向为图像和信息处理。

何楷祺: 男, 硕士生, 研究方向为图像和信息处理。

责任编辑: 余蓉