

基于多尺度近端特征拼接网络的高光谱图像分类方法

高红民, 曹雪莹, 陈忠昊, 花再军, 李臣明, 陈月

(河海大学计算机与信息学院, 江苏 南京 211100)

摘要: 针对基于传统卷积神经网络模型的高光谱图像分类算法细节表现力不强及网络结构过于复杂的问题, 设计了一种基于多尺度近端特征拼接网络的高光谱图像分类方法。通过引入多尺度滤波器和空洞卷积, 在保持模型轻量化的同时可以获取更丰富的空间-光谱判别特征, 并提出利用卷积神经网络近端特征间的相互联系进一步增强细节表现力。在 3 个基准高光谱图像数据集上的实验结果表明, 所提方法优于其他分类模型。

关键词: 卷积神经网络; 高光谱图像分类; 特征拼接; 多尺度滤波器; 空洞卷积

中图分类号: TP302

文献标识码: A

DOI: 10.11959/j.issn.1000-436x.2021024

Hyperspectral image classification method based on multi-scale proximal feature concatenate network

GAO Hongmin, CAO Xueying, CHEN Zhonghao, HUA Zaijun, LI Chenming, CHEN Yue

College of Computer and Information Engineering, Hohai University, Nanjing 211100, China

Abstract: Aiming at the phenomenon that the hyperspectral classification algorithm based on traditional CNN model was not expressive enough in detail and the network structure was too complex, a hyperspectral image classification method based on multi-scale proximal feature concatenate network (MPFCN) was designed. By introducing multi-scale filter and cavity convolution, the model could be kept light and the discriminative features of the space spectrum could be obtained, and the correlation between the proximal features of the CNN was proposed to further enhance the detail expression. Experimental results on three benchmark hyperspectral image data sets show that the proposed method is superior to other classification models.

Keywords: convolutional neural network, hyperspectral image classification, feature concatenate, multi-scale filter, dilated convolution

1 引言

高光谱图像 (HSI, hyperspectral image) 可以从上百条连续的光谱波段中提取地物信息, 这使其拥有强大的对地目标区分能力。在过去的几十年里, 高光谱图像在目标探测^[1]、土地监测^[2]、农业监测^[3]以及海洋遥感^[4]等方面均发挥了重要作用。

迄今为止, 研究者已经提出各种方法将高光谱图像的像元划分为特定的土地覆盖类。在早期的分类方法中, K 近邻分类器^[5]和支持向量机 (SVM, support vector machine)^[6]等光谱分类器被广泛使用, 但以上方法往往会面临高光谱图像极高的光谱波段维数带来的“小样本问题”和特征冗余带来的分类效率下降的问题。为了缓和其高维性, 特征选

收稿日期: 2020-07-20; 修回日期: 2020-10-20

基金项目: 国家自然科学基金资助项目 (No.62071168); 国家重点研发计划基金资助项目 (No.2018YFC1508106); 中央高校基本科研业务费资金资助项目 (No.B200202183); 江苏省研究生科研与实践创新计划基金资助项目 (No.SJ CX20_0181)

Foundation Items: The National Natural Science Foundation of China (No.62071168), The National Key Research and Development Program of China (No.2018YFC1508106), Fundamental Research Funds for the Central Universities (No.B200202183), Post-graduate Research & Practice Innovation Program of Jiangsu Province (No.SJ CX20_0181)

择^[7]和特征提取^[8]的方法常被选用，这 2 种方法的目标均是从原始高光谱数据集中提取更具代表性的信息，区别在于后者并非简单地选择波段，而是从中抽象出更具代表性的特征波段。

为了更好地应对高光谱图像复杂的空间分布和光谱分布，将空间和光谱特征纳入分类方法的多核分类器^[9]与基于稀疏表示的分类器^[10]也得到了广泛关注。但是这些方法大多属于浅层模型，这种模型中的非线性变换层数不足以表示高光谱图像复杂的空间和光谱特征，泛化能力较弱。同时，其往往基于手工特征，高度依赖个人经验。为了克服这些缺点，深度学习^[11]被引入高光谱图像分类中，它可以自动地从原始输入数据中由低到高地学习层次特征，进而充分挖掘高光谱图像中更具代表性的显著特征。Chen 等^[12]提出一种堆叠自动编码器方法对高光谱图像进行分类，Liu 等^[13]提出一种结合深度置信网络与主动学习的高光谱图像分类方法。这 2 种方法都是将原始三维图像压缩成一个扁平的向量以满足框架输入的要求，但会打破原始图像中固有的空间-光谱特征结构，破坏高光谱空间信息，最终导致分类精度下降。

为了进一步利用高光谱图像的空间特征信息，基于卷积神经网络（CNN, convolutional neural network）的高光谱图像分类算法被提出。作为深度学习的代表算法之一，卷积神经网络拥有出色的表征学习能力，这使其在空间特征信息提取方面拥有巨大的优势。为了提取更有效的空间-光谱判别特征信息，Chen 等^[14]提出了正则化特征提取方法，Li 等^[15]提出了一种不依赖任何预处理或后处理的三维 CNN 高光谱图像分类方法。但这些方法都面临 CNN 模型向深度进发时所产生的梯度弥散及网络退化现象的困扰。为此，借助残差网络^[16]，Zhong 等^[17]完成了一个可以从光谱特征和空间背景中连续学习判别特征的深网络模型，Song 等^[18]在残差网络的基础上加入深浅特征融合来进一步提升性能。为了进一步提升各层卷积利用率，获取更多有效判别特征，Wang 等^[19]设计了一种快速密集频谱空间卷积框架，不需要像深浅层特征信息融合方法那样手动寻找最优特征融合层，但其往往需要大量的跳跃结构参与，这会导致训练参数大幅增加，进而使计算代价增大。上述方法的分类模型均拥有非常深的网络结构，但过深的网络结构在提取更加抽象的特征信息的同时也会带来“精度饱和”和“网

络退化”的现象，这同样会影响高光谱图像的最终分类精度。为此，王莹^[20]提出了一种改进的基于 CNN 的高光谱图像分类网络来进一步提升分类结果，但其在小样本情况下的分类结果仍有进一步提升的空间。另一部分研究者选择增广网络宽度^[21]来获取更丰富的特征信息，如 Lee 等^[22]设计了一种多尺度滤波器对输入图像进行特征提取，Zhang 等^[23]提出了一种多尺度密集网络用于高光谱图像分类。与仅针对单一特征图进行提取的多尺度滤波器相比，多尺度密集网络利用不同卷积核获取更丰富的空间邻域信息，并提取了更加有效的判别特征，从而使其在分类精度上有了进一步提升，但将整个网络的各级特征信息进行组合同样会造成训练参数过大、计算成本过高，且其从本质上说，仍是完成了一种对较浅层空间-光谱特征的弥补，与深浅层特征信息融合所达成的目标差异不大，因此其在最终分类精度和运行时间上并没有获得显著提升。

为了解决以上问题，本文提出了一种基于多尺度近端特征拼接网络（MPFCN, multi-scale proximal feature concatenate network）的高光谱图像分类方法，它注重利用近端卷积层之间的相互联系进行特征提取，并结合多尺度融合手段搭建一个动态特征图来获取更丰富细致的空间-光谱判别特征，同时，它还具有轻量化的特点，具体创新总结如下。

1) 为充分利用各相邻卷积层间的特征相关性，本文引入近端特征上下文信息，相比于远端特征或密集特征融合，近端特征拼接可以获得更细致的空间-光谱判别特征，且不会因为过多的超链接结构增加网络负担，这有助于提升整体网络的性能，并获得更高的分类精度。

2) 为了进一步利用高光谱图像的空间域信息，本文设计了一种近端多尺度滤波器模块。该模块利用不同感受野的滤波器提取各相邻特征图上的特征信息，并利用超链接将所提取的信息相拼接，从而得到一个包含相邻近端特征上下文信息与不同尺寸空间相邻特征信息的动态特征图，使 HSI 的特征表达更加丰富全面。

3) 为了保持整体模型结构的轻量化，本文在多尺度滤波器中引入空洞卷积，在扩大卷积感受野的同时维持一个较低的训练参数，使整体模型可以进行高效轻量的特征提取，更好地应对高光谱图像“小样本”问题。

2 基本原理

2.1 空洞卷积

空洞卷积是指在普通卷积中添加零填充，以扩展卷积核感受野的卷积方法。其优势是在不改变特征图分辨率的前提下，使感受野比普通卷积更大，感知信息的范围更大，进而改善下采样带来的特征信息丢失问题。假设 k' 表示等效卷积核大小， k 表示真实卷积核尺寸， d 表示扩张率，则等效卷积尺寸为

$$k' = (d - 1) \times (k - 1) + k \quad (1)$$

为了更直接地展示空洞卷积的工作原理，图 1 中展示了在相同尺寸卷积核下，通过调整扩张率来获得不同的感受野。




图 1 空洞卷积原理示意

如图 1(a)所示，当 $d=1$ 时，感受野与卷积核的尺寸均为 3×3 。如图 1(b)所示，当 $d=2$ 时，感受野增加至 5×5 。如图 1(c)所示，当图 1(a)和图 1(b)级联时，感受野增加至 7×7 。图 1(b)中每个圆点像素都是图 1(a)的卷积输出。具体计算式为

$$G_{i+1} = G_i + (k' - 1)S \quad (2)$$

其中， G_i 表示当前图层的感受野， G_{i+1} 表示下一图层的感受野， S 表示从第 1 层到第 $i-1$ 层步长的乘积。可以看出，空洞卷积级联时，其感受野的面积呈指数级增长。此外，相较于普通卷积，空洞卷积不会因增大感受野而造成训练参数的增加，这使整体网络结构在获取更大范围内特征信息的同时，更加高效和轻量。

2.2 传统的多尺度滤波器模块

传统的多尺度滤波器以优化利用输入图像的不同局部结构为目标，深入挖掘特征图的空间局部相关性。因此，在高光谱图像中应用多尺度滤波器，可以很好地利用高光谱图像局部空间结构和局部谱相关。为展示所提方法相较于传统多尺度滤波器模块的优越性，本文选用尺寸为 3×3 、 5×5 、 7×7 的常用卷积核，搭建传统的多尺度滤波器模块，如

图 2 所示。拼接层中的 3×3 、 5×5 、 7×7 表示感受野范围。

2.3 特征拼接

为了提高各级卷积层的利用率，特征拼接常被用于基于 CNN 的高光谱图像分类算法中，本文利用卷积神经网络在响应输入特征平移不变性时往往具有一定规律的特点，将近端特征图进行拼接，得到一幅包含三层卷积结果的动态特征图。该动态特征图中包含了相邻卷积层所提取特征间的上下文联系，再一次提高了各级卷积层利用率，并使所提取的空间-光谱判别特征更加细致。




图 2 传统多尺度滤波器模块示意

2.4 本文算法描述

本文所提基于多尺度近端特征拼接网络的高光谱图像分类算法主体结构由一种改进的多尺度滤波器模块组合而成。

2.4.1 改进的多尺度滤波器模块

改进的多尺度滤波器模块如图 3 所示，它包含 3 个卷积核尺寸为 3×3 的卷积层，且每个卷积层都配置了批量归一化 (BN, batch normalization) 层和激活函数 ReLU 进行加速训练和非线性化处理。从图 3 中可以看出，该模块共有 3 条支路，分别为第一卷积层支路、第二卷积层支路、第三卷积层与第一卷积层级联支路。其中，第一卷积层扩张率为 1，感受野为 3×3 ；第二卷积层扩张率为 2，感受野为 5×5 ；第三卷积层与第一卷积层级联，所得特征图感受野为 7×7 。最后，将 3 条支路所得特征图进行拼接，并利用 BN 层与 ReLU 函数加速训练，增强模型泛化能力。

综上所述，改进的多尺度卷积块在充分利用各级卷积层提取的特征图的同时，利用空洞卷积降低了训练参数，使整体模型更加轻量化。此外，相邻特征的拼接引入近端特征上下文关联信息，也使光谱空间特征信息表达更细致。

2.4.2 多尺度近端特征拼接网络模型

图 4 展示了多尺度近端特征拼接网络模型的整

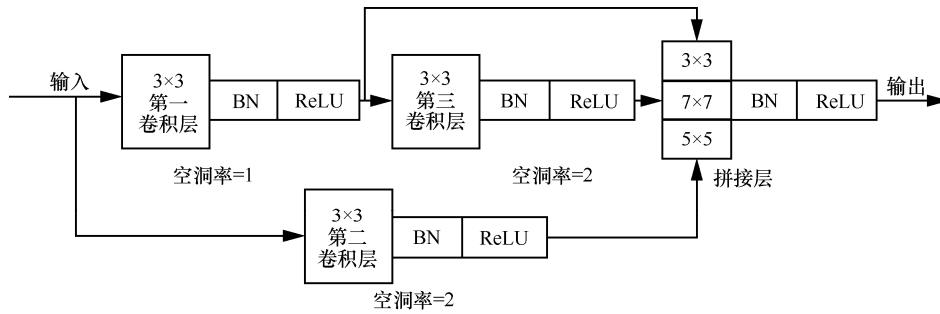


图 3 改进的多尺度滤波器模块




图 4 多尺度近端特征拼接网络模型的整体结构

体结构，其流程如下。首先，用主成分分析（PCA, principal component analysis）法对原始高光谱图像进行降维，提取主成分信息含量最大的波段；然后，以待分类像元为中心，提取相应尺寸的待分类图像块（patch）。这些 patch 将会被输入多尺度近端特征拼接网络中进行特征提取并分类，以此得到最终的地物分类图。具体来说，多尺度近端特征拼接网络包括改进的多尺度滤波器模块、平均池化层、全局平均池化层和 Softmax 分类器。其中，每个改进的多尺度滤波器模块后都配备了一个平均池化层。

为了防止前级滤波器图层数量对内存造成影响，本文以改进的多尺度滤波器模块为单位，逐步增加各多尺度滤波器图层数量，如第一个模块的滤波器图层数量为 32，第二个模块的滤波器图层的数量以 2 的倍数递增，依次类推。平均池化层的作用在于抑制过拟合，维持较低的训练参数，降低特征图尺寸，其尺寸为 2×2 。全局平均池化层起到将特征图降维重组并映射到样本空间的作用，相比全连接层，它占用更少的训练参数，抑制过拟合的效果更好。Softmax 分类器负责对每个像素点进行分类。以上部分共同协作，使多尺度近端特征拼接网络在小样本状态下获得了的高精度分类结果和分类效率。

3 实验结果与分析

3.1 实验数据集

1) IP (Indian pines) 数据集。IP 数据集是由

AVIRIS 成像光谱仪在美国印第安纳州西北部获取的图像。它的空间尺寸为 145 像素 \times 145 像素，单个像素分辨率为 20 m；光谱波段共 220 条，其波长范围为 0.4~2.45 μm 。本文将水汽吸收波段去除，则 IP 数据集的最终输入尺寸为 145 像素 \times 145 像素 \times 200 像素，其包含的真实地物类别为 16 种。

2) PU (University of Pavia) 数据集。PU 数据集是 ROSIS 成像光谱仪在帕维亚大学上空获取的图像。它的空间尺寸为 610 像素 \times 340 像素，去除水汽吸收波段后，光谱维波段共 103 条。PU 数据集的最终输入尺寸为 610 像素 \times 340 像素 \times 103 像素，其包含的真实地物类别为 9 种。

3) SA (Salinas) 数据集。SA 数据集同样由 AVIRIS 成像光谱仪获取，其图像呈现了萨利纳斯山谷地貌。它具有高空间分辨率的特点。去除水汽吸收波段后，SA 数据集的最终输入尺寸为 512 像素 \times 217 像素 \times 204 像素，其包含的真实地物类别为 16 种。

IP 数据集、PU 数据集和 SA 数据集灰度图和真实地物信息类别分别如图 5 和表 1 所示。

3.2 实验设置

为了验证本文所提多尺度近端特征拼接网络的合理性和有效性，本文分别在 3 幅高光谱图像数据集上进行验证实验。所有实验均在一台 CPU 为 Intel E5-2667、GPU 为 1080Ti 的笔记本电脑上进行，使用的编程语言为 Python，深度学习模型框架为

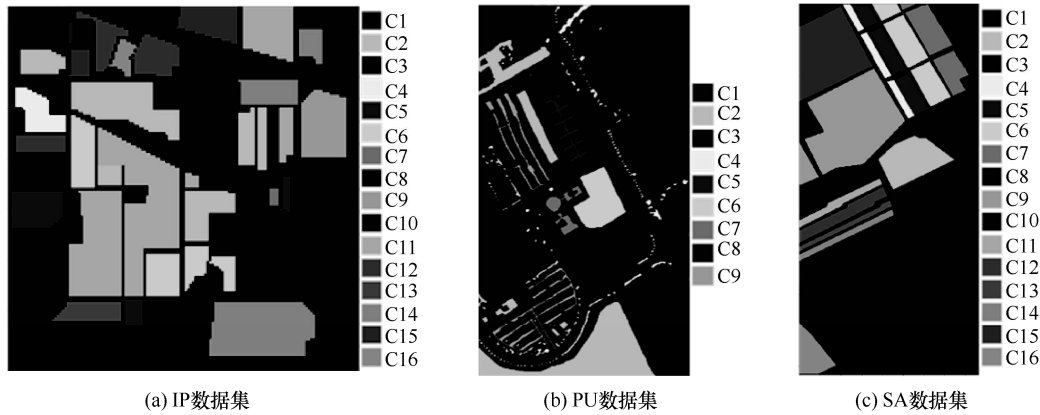


图 5 IP 数据集、PU 数据集和 SA 数据集灰度图

表 1 IP 数据集、PU 数据集和 SA 数据集真实地物信息类别

数据集	类别	名称	样本数/个	样本总数/个
IP	C1	Alfalfa	46	10 249
	C2	Corn-notill	1 428	
	C3	Corn-mintill	830	
	C4	Corn	237	
	C5	Grass-pasture	483	
	C6	Grass-trees	730	
	C7	Grass-pasture-mowed	28	
	C8	Hay-windrowed	478	
	C9	Oats	20	
	C10	Soybean-notill	972	
	C11	Soybean-mintill	2 455	
	C12	Soybean-clean	593	
	C13	Wheat	205	
	C14	Woods	1 265	
	C15	Buildings-Grass-Trees_Drives	386	
	C16	Stone-Steel-Towers	93	
PU	C1	Asphalt	6 631	42 776
	C2	Meadows	18 649	
	C3	Gravel	2 099	
	C4	Trees	3 064	
	C5	Painted metal sheets	1 345	
	C6	Bare Soil	5 029	
	C7	Bitumen	1 330	
	C8	Self-Blocking Bricks	3 682	
	C9	Shadows	947	
SA	C1	Brocoli_green_weeds_1	2 009	54 129
	C2	Brocoli_green_weeds_2	3 726	
	C3	Fallow	1 976	
	C4	Fallow_rough_plow	1 394	
	C5	Fallow_smooth	2 678	
	C6	Stubble	3 959	
	C7	Celery	3 579	
	C8	Grapes_untrained	11 271	
	C9	Soil_vinyard_develop	6 203	
	C10	Corn_senesced_green_weeds	3 278	
	C11	Lettuce_romaine_4wk	1 068	
	C12	Lettuce_romaine_5wk	1 927	
	C13	Lettuce_romaine_6wk	916	
	C14	Lettuce_romaine_7wk	1 070	
	C15	Vinyard_untrained	7 268	
	C16	Vinyard_vertical_trellis	1 807	

Keras。在评价指标方面，本文选取总体精度 (OA, overall accuracy)、平均精度 (AA, average accuracy) 和 Kappa 系数 (KA, Kappa coefficient) 3 个指标。为了避免随机因素的影响，所有展示数据均为相同条件下 10 次实验结果的平均值。在训练集的划分中，本文分别在 IP 数据集、PU 数据集、SA 数据集上随机选取 10%、4%、2% 的样本作为训练样本，并将剩余 90%、96% 和 98% 的样本作为测试样本。在利用 PCA 法对 3 个数据集的光谱维进行降维时，IP 数据集和 SA 数据集选择前 3 个波段，而 PU 数据集选择前 5 个波段。3 个数据集实验中，批尺寸均设置为 32，反向传播均选用随机梯度下降 (SGD, stochastic gradient descent) 法，初始学习率为 0.01，衰减率为 0.01 与迭代次数之比。迭代次数设置为 150 次。本文将从内部参数选取和与其他典型方法比较两方面对 MPFCN 的性能进行分析。

3.3 内部参数选取

本节将从 patch 尺寸和网络模型深度 (改进的多尺度滤波器模块数) 两方面进行参数选取实验，这是因为 patch 尺寸中包含高光谱图像的光谱信息与空间邻域信息，它决定了输入信息的多少；网络模型的深度决定了能否提取到关键光谱判别特征。具体实验方法如下。

本文分别选取 7×7、13×13、27×27 这 3 个 patch 尺寸进行实验。在多尺度滤波器模块数选取方面，由于平均池化层的作用，每增加一个多尺度滤波器模块，特征图尺寸就会缩小一半，因此本文根据 patch 尺寸，遵循尽可能深地增加网络模型的原则，分别选取多尺度滤波器模块数为 2、3、4、5 进行测试。在 3 幅高光谱数据集上的测试结果分别如表 2~表 4 所示。

表 2 IP 数据集参数测试

多尺度滤波器模块数/个	patch 尺寸	OA	AA	KA
5	27×27	98.51%	98.50%	98.31%
	13×13	98.48%	98.42%	98.27%
4	27×27	98.43%	97.86%	98.22%
	13×13	96.43%	96.11%	95.94%
3	27×27	98.03%	96.31%	97.75%
	7×7	83.13%	82.51%	79.66%
2	13×13	95.85%	95.69%	92.26%
	7×7	85.86%	84.32%	83.93%

表 3 PU 数据集参数测试

多尺度滤波器模块数/个	patch 尺寸	OA	AA	KA
5	27×27	99.57%	99.14%	99.43%
	13×13	98.29%	97.65%	97.74%
4	27×27	99.40%	98.62%	99.21%
	13×13	98.56%	97.70%	98.10%
3	27×27	99.08%	97.83%	98.78%
	7×7	92.49%	90.46%	89.91%
2	13×13	98.30%	97.67%	97.74%
	7×7	94.28%	92.59%	92.36%

表 4 SA 数据集参数测试

多尺度滤波器模块数/个	patch 尺寸	OA	AA	KA
5	27×27	99.70%	99.71%	99.66%
	13×13	95.97%	97.77%	95.51%
4	27×27	99.70%	99.70%	99.67%
	13×13	95.09%	98.03%	95.44%
3	27×27	99.51%	99.49%	99.45%
	7×7	90.44%	93.58%	89.34%
2	13×13	95.05%	97.45%	94.48%
	7×7	90.77%	93.32%	89.75%

从表 2~表 4 中可以看出,随着多尺度滤波器模块数量与 patch 尺寸的增加,3 个数据集的整体分类精度均逐步增加。在固定多尺度滤波器模块数量的情况下,patch 尺寸越大,OA、AA、KA 越大;在固定 patch 尺寸的情况下,增加多尺度滤波器模块数量会使整体分类精度呈现逐步攀升至某一值后开始波动的现象,这是由于在网络不断向深度进发的过程中往往会出现精度饱和及梯度弥散等现

象,从而对最终分类结果造成影响。

实验结果证明,本文所提方法通过加入近端特征上下文间的联系,提高了对各级卷积层及特征图的利用,进而提取更精细的空间-光谱特征信息,进一步提升了分类性能。同时,实验结果也证明本文所提网络不需要搭建一个过深的网络结构就可以达到非常高的分类精度,避免了过深网络所带来的精度饱和等一系列会影响最终分类结果的问题。

3.4 与其他典型方法的比较

为了突出 MPFCN 的先进性,本节将其与其他 4 种典型方法在定量分类结果、运行时间以及小样本情况下的分类效果进行对比。4 种典型方法分别为 SVM^[6]、2D 卷积神经网络(DCNN)^[20]、残差网络(ResNet)^[16]以及传统的多尺度滤波器网络 MCNN (multi-scale CNN)。为了更好地进行对比,ResNet、MCNN 和 DCNN 的输入 patch 尺寸及参数选取均与 MPFCN 相同,其迭代次数均以训练集样本数据精度收敛至 1 为止。其余设置参考上述相关文献进行设置。在 3 个数据集中,分别测试了在训练样本数量固定的情况下不同方法的分类性能。

3.4.1 定量分类结果

本节在 IP 数据集的对比实验中,随机选取了 10% 的训练样本,并将剩余 90% 样本作为测试样本。图 6 展示了 IP 数据集的地物灰度图和不同分类方法的分类图。

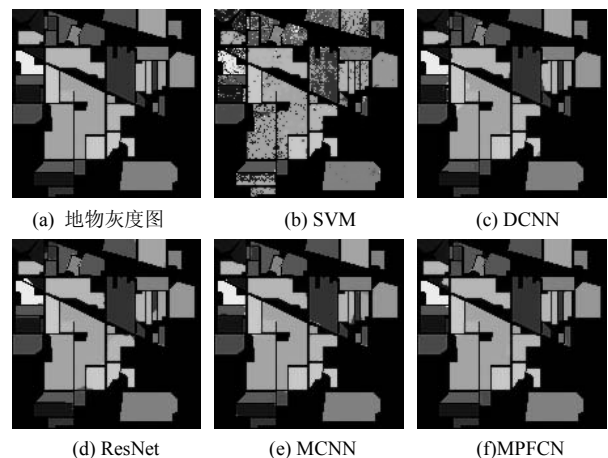


图 6 IP 数据集的地物灰度图和不同分类方法的分类图

从图 6 可以看出,SVM 的分类效果最差,且存在大量噪声,这是因为其为浅层模型分类方法,泛化能力差,不足以应对高光谱图像复杂的光谱空间分布。相比利用增加网络模型深度来提取更多判别特征的 DCNN 和 ResNet,MCNN 和

MPFCN 有更好的视觉体验, 本文所提 MPFCN 在细节表现力上优于 MCNN, 它可以更加精确地对边缘像素进行分类, 并展示与地物灰度图更相似的结果。表 5 和表 6 给出了不同分类方法针对 IP 数据集的定量分析结果和分类精度, 同样可以看出, 使用 DCNN、ResNet、MCNN 和 MPFCN 所获取的分类精度明显优于 SVM 的分类精度 (OA 为 75.07%), MPFCN 由于更加充分地利用了各层卷积及特征图, 并引入近端特征上下文联系信息,

分类精度最高, OA 达到 98.51%。此外, 表 6 展示了不同方法在 IP 数据集下的训练参数数量。

在 PU 数据集和 SA 数据集上进行的比较实验分别随机选取 4% 和 2% 的样本作为训练样本, 剩余 96% 和 98% 的样本作为测试样本。图 7 和图 8 分别展示了 2 个数据集的地物灰度图以及不同分类方法的分类图, 表 7~表 10 则给出了不同分类方法的定量分析结果和分类精度。在 2 个数据集对比实验中, MPFCN 在 PU 数据集和 SA 数据集上的 OA 均最高,

表 5 不同分类方法针对 IP 数据集的定量分析结果

类别	SVM	DCNN	ResNet	MCNN	MPFCN
Alfalfa	37.21%	100%	96.34%	95.93%	97.93%
Corn-notill	77.60%	98.17%	97.20%	97.17%	98.52%
Corn-mintill	57.54%	93.04%	97.05%	94.24%	96.90%
Corn	60.29%	100%	99.77%	98.59%	99.84%
Grass-pasture	90.40%	97.01%	99.20%	96.55%	96.27%
Grass-trees	92.89%	97.49%	97.95%	99.49%	99.59%
Grass-pasture-mowed	86.36%	94.00%	100%	94.67%	99.8%
Hay-windrowed	97.90%	99.88%	97.90%	99.84%	100%
Oats	55.05%	96.875%	100%	97.92%	100%
Soybean-notill	50.45%	96.34%	96.80%	96.42%	97.75%
Soybean-mintill	72.16%	98.44%	99.30%	98.43%	98.30%
Soybean-clean	50.56%	93.16%	92.98%	95.94%	96.50%
Wheat	93.86%	100%	98.91%	95.83%	98.73%
Woods	89.00%	99.12	99.52%	98.60%	99.94%
Buildings-Grass-Trees-Drives	48.02%	99.14%	99.86%	99.90%	98.27%
Stone-Steel-Towers	91.67%	91.67%	88.71%	96.03%	97.62%

表 6 不同分类方法针对 IP 数据集的分类精度

方法	OA	AA	KA	训练参数数量/个
SVM	75.07%	71.65%	71.52%	—
DCNN	97.50%	97.15%	97.15%	1 109 776
ResNet	97.97%	97.41%	97.69%	11 002 320
MCNN	97.62%	97.22%	97.29%	43 402 288
MPFCN	98.51%	98.50%	98.31%	12 593 104




图 7 PU 数据集的地物灰度图和不同分类方法的分类图

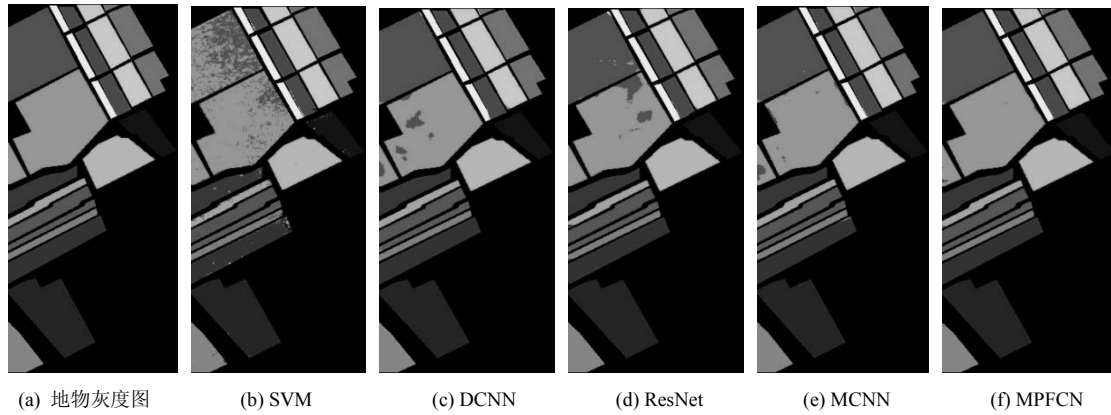


图 8 SA 数据集的地物灰度图和不同分类方法的分类图

表 7 不同分类方法针对 PU 数据集的定量分析结果

类别	SVM	DCNN	ResNet	MCNN	MPFCN
Asphalt	91.66%	99.68%	99.99%	99.35%	99.64%
Meadows	94.91%	99.92%	99.93%	99.20%	99.92%
Gravel	71.37%	98.81%	97.94%	96.67%	99.06%
Trees	85.00%	90.38%	92.39%	98.22%	98.07%
Painted metal sheets	99.00%	96.39%	95.91%	99.77%	99.76%
Bare Soil	68.09%	100%	99.81%	99.15%	100%
Bitumen	49.41%	99.40%	99.78%	98.72%	99.10%
Self-Blocking Bricks	86.76%	97.90%	97.93%	98.92%	99.24%
Shadows	99.89%	85.77%	85.12%	98.17%	97.52%

表 8 不同分类方法针对 PU 数据集的分类精度

方法	OA	AA	KA	训练参数数量/个
SVM	87.52%	82.90%	83.28%	—
DCNN	98.54%	96.47%	98.06%	1 109 776
ResNet	98.66%	96.53%	98.22%	10 989 129
MCNN	98.98%	98.68%	98.65%	43 396 841
MPFCN	99.56%	99.14%	99.43%	12 583 497

表 9 不同分类方法针对 SA 数据集的定量分析结果

类别	SVM	DCNN	ResNet	MCNN	MPFCN
Brocoli_green_weeds_1	98.62%	100%	99.78%	100%	100%
Brocoli_green_weeds_2	99.86%	98.83%	99.87%	99.98%	100%
Fallow	98.86%	99.63%	99.16%	100%	100%
Fallow_rough_plow	99.34%	99.74%	99.85%	99.82%	99.96%
Fallow_smooth	97.25%	99.56%	97.68%	99.79%	99.74%
Stubble	99.82%	99.74%	99.75%	99.98%	99.89%
Celery	99.40%	99.64%	99.86%	99.86%	99.58%
Grapes_untrained	89.69%	99.49%	94.28%	96.26%	99.45%
Soil_vinyard_develop	99.21%	100%	100%	99.97%	99.84%
Corn_senesced_green_weeds	92.75%	99.98%	99.76%	99.09%	99.82%
Lettuce_romaine_4wk	91.51%	97.76%	97.87%	98.62%	99.14%
Lettuce_romaine_5wk	97.72%	99.68%	99.81%	99.62%	99.87%
Lettuce_romaine_6wk	98.56%	99.58%	97.29%	99.83%	99.86%
Lettuce_romaine_7wk	91.78%	99.45%	99.49%	98.67%	99.18%
Vinyard_untrained	45.70%	94.51%	98.99%	97.37%	99.52%
Vinyard_vertical_trellis	98.26%	100%	99.98%	99.77%	99.48%

表 10 不同分类方法针对 SA 数据集的分类精度

方法	OA	AA	KA	训练参数数量/个
SVM	89.21%	93.65%	87.94%	—
DCNN	98.91%	99.22%	98.79%	1 109 776
ResNet	98.36%	98.96%	98.18%	10 994 640
MCNN	98.95%	99.25%	98.84%	43 402 288
MPFCN	99.70%	99.71%	99.66%	12 593 104

分别为 99.56%和 99.70%。此外，表 8 和表 10 展示了在 PU 数据集和 SA 数据集下，各对比方法的训练参数数量。总体来说，MPFCN 在 IP 数据集、PU 数据集和 SA 数据集上的 3 个指标性能均达到最优。

3.4.2 运行时间对比

本节以 SA 数据集为例，对比 DCNN、ResNet、MCNN 和 MPFCN 的运行时间，将各个网络的迭代次数设置为 150 次，结果如表 11 所示。

表 11 基于 SA 数据集的各分类方法运行时间

分类方法	训练时间/s	测试时间/s
DCNN	336.95	35.90
ResNet	335.24	35.83
MCNN	388.32	31.50
MPFCN	131.75	11.80

从表 11 可以发现，基于传统多尺度滤波器网络的 MCNN 分类方法运行时间最长，这是因为其引入了大量卷积核，造成训练参数的增加，从而使运行时间上升；DCNN 与 ResNet 本质上都是通过增加网络深度来获得更有效的空间-光谱判别特征进行分类，二者训练时间相差不大；本文所提 MPFCN 方法借助空洞卷积，减轻了扩大感受野所带来的卷积核尺寸增加从而导致训练参数增加的问题，同时在尽可能少的超链接结构下完成了对每层卷积的充分利用，降低了模型复杂度，相比其他

典型分类方法，缩短了训练及测试时间。

3.4.3 小样本情况下的分类效果对比

根据 3 个数据集各自的分布特点，本节对 IP 数据集随机划分了 5%、7%、10%、15%和 20%的样本数据作为训练集，剩余样本作为测试集；对 PU 数据集随机划分了 0.5%、1%、2%、4%和 5%的样本数据作为训练集；SA 数据集的相关训练样本的选取比例为 0.3%、0.5%、1%、2%和 5%。3 个数据集的实验结果如图 9 所示。

从图 9 可以看出，随着训练集样本占比的增加，所有数据集的分类结果均会迅速增加，当训练样本的规模足够大时，分类精度上升的速度会逐渐变缓，分类结果趋于稳定。同时，在小样本情况下，本文所提 MPFCN 依旧能提供良好的性能。

3.4.4 消融实验

为验证所提方法合理性及有效性，本节设计了原始模块、多尺度近端特征拼接模块、带有空洞卷积的多尺度模块和改进的多尺度滤波器模块，如图 10 所示。将这 4 个模块分别应用到多尺度近端拼接网络中，以 IP 数据集为例进行消融实验，对比结果如图 11 所示。

从图 11 可以看出，原始模块整体性能表现最差，这是因为其网络模型较大，训练代价昂贵，过拟合现象严重。在采用近端特征拼接，即引入相邻卷积层间上下文联系后，OA 上升至 97.87%。此外，从图 11 还可以看出，采用空洞卷积可以大




图 9 针对不同数量的样本进行性能分析

幅提升网络的分类性能，其 OA 达到了 98.41%，这是因为空洞卷积可以大幅减少训练参数，抑制过拟合。本文所提方法在加入空洞卷积及近端特征拼接后，3 个评价指标均取得了最优的结果，OA 达到了 98.51%。

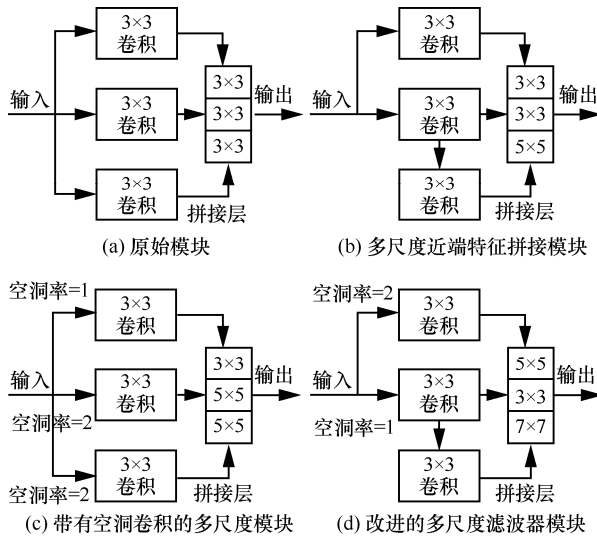


图 10 模块结构




图 11 消融实验对比结果

4 结束语

本文提出了一种基于多尺度近端特征拼接网络的高光谱图像分类方法，该方法通过将近端特征上下文信息引入网络模型中，使所提取的空间-光谱特征细节表现力更强，进而可以更好地应对高光谱图像复杂的空间分布与光谱分布。此外，为了保持整体模型轻量化，所提方法在不增加训练参数的情况下，利用空洞卷积对特征图进行多尺度信息提取，丰富了所提取的空间-光谱判别特征，进一步提升了分类性能，在 3 个真实高光谱图像的数据集

上的实验结果证明，所提方法在小样本条件下可以获得更优秀的分类结果。

下一步研究将引入注意力机制，对近端特征进行权重配比，进一步优化所获取的近端特征拼接图，从而提升网络的整体性能。

参考文献：

- [1] ZHANG L F, ZHANG L P, TAO D C, et al. Hyperspectral remote sensing image subpixel target detection based on supervised metric learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(8): 4955-4965.
- [2] 张亚光, 陈建平, 李诗. 高光谱遥感在土壤重金属污染监测中的应用[J]. 地质学刊, 2019, 43(3): 491-498.
- [3] 王新忠, 卢青, 张晓东, 等. 基于高光谱图像的黄瓜种子活力无损检测[J]. 江苏农业学报, 2019, 35(5): 1197-1202.
- [4] SANDIDGE J C, HOLYER R J. Coastal bathymetry from hyperspectral observations of water radiance[J]. Remote Sensing of Environment, 1998, 65(3): 341-352.
- [5] SAMANIEGO L, BARDOSSY A, SCHULZ K. Supervised classification of remotely sensed imagery using a modified K-NN technique[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(7): 2112-2125.
- [6] 肖博林. 基于支持向量机的高光谱遥感影像分类[J]. 科技创新与应用, 2020(4): 22-24.
- [7] XIAO B L. Hyperspectral remote sensing image classification based on support vector machin[J]. Technology Innovation and Application, 2020(4): 22-24.
- [8] WANG Q, LIN J Z, YUAN Y. Salient band selection for hyperspectral image classification via manifold ranking[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 27(6): 1279-1289.
- [9] LICCIARDI G, MARPU P R, CHANUSSOT J, et al. Linear versus nonlinear PCA for the classification of hyperspectral data based on the extended morphological profiles[J]. IEEE Geoscience and Remote Sensing Letters, 2012, 9(3): 447-451.
- [10] GAO W, PENG Y. Ideal kernel-based multiple kernel learning for spectral-spatial classification of hyperspectral image[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(7): 1051-1055.
- [11] CHEN Y, NASRABADI N M, TRAN T D. Hyperspectral image classification via kernel sparse representation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(1): 217-231.
- [12] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [13] 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.
- [14] LIU P, ZHANG H, EOM K B. Active deep learning for classification of hyperspectral images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(2): 712-724.

- [14] CHEN Y S, JIANG H L, LI C Y, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(10): 6232-6251.
- [15] LI Y, ZHANG H K, SHEN Q, et al. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network[J]. Remote Sensing, 2017, 9(1): 67.
- [16] 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. Piscataway: IEEE Press, 2016: 770-778.
- [17] 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.
- [18] SONG W W, LI S T, FANG L Y, et al. Hyperspectral image classification with deep feature fusion network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(6): 3173-3184.
- [19] 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.
- [20] 王莹. 改进的基于 CNN 的高光谱遥感图像分类办法[J]. 现代商贸工业, 2019, 40(35): 204-206.
WANG Y. Improved hyperspectral remote sensing image classification method based on CNN[J]. Modern Business Trade Industry, 2019, 40(35): 204-206.
- [21] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2015: 1-9.
- [22] LEE H, KWON H. Going deeper with contextual CNN for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2017, 26(10): 4843-4855.
- [23] ZHANG C J, LI G D, DU S H. Multi-scale dense networks for hyperspectral remote sensing image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(11): 9201-9222.

[作者简介]




高红民（1983-），男，江苏仪征人，博士，河海大学教授，主要研究方向为深度学习等智能计算方法、图像大数据与人工智能、遥感影像处理等。



曹雪莹（1994-），女，江苏睢宁人，河海大学硕士生，主要研究方向为深度学习与图像处理等。



陈忠昊（1997-），男，安徽马鞍山人，河海大学硕士生，主要研究方向为深度学习与高光谱图像处理等。



花再军（1983-），男，江苏姜堰人，河海大学实验师，主要研究方向为机器学习及图像处理等。



李臣明（1969-），男，内蒙古通辽人，河海大学教授，主要研究方向为智能信息处理、遥感技术与系统等。



陈月（1995-），女，江苏扬州人，河海大学硕士生，主要研究方向为高光谱遥感影像分类。