

基于 CNN 的双边融合网络在高光谱图像分类中的应用

高红民, 曹雪莹, 杨耀, 花再军, 李臣明

(河海大学计算机与信息学院, 江苏 南京 211100)

摘 要: 针对基于深度卷积神经网络的高光谱图像分类算法中存在的空间分辨率下降、池化操作引发特征丢失从而导致分类精度下降的问题, 设计了一种由双边融合块构成的双边融合块网络。1×1 卷积与超链接构成双边融合块上结构, 传递局部空间特征, 池化、卷积、反卷积、上采样组成下结构, 强化高效判别特征。在 3 个基准高光谱图像数据集上的实验结果表明, 该模型优于其他同类分类模型。

关键词: 卷积神经网络; 高光谱图像分类; 转置卷积; 上采样; 超链接

中图分类号: TP302

文献标识码: A

doi: 10.11959/j.issn.1000-436x.2020238

Application of bilateral fusion model based on CNN in hyperspectral image classification

GAO Hongmin, CAO Xueying, YANG Yao, HUA Zaijun, LI Chenming

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

Abstract: Aiming at the issues of decreasing spatial resolution and feature loss caused by pooling operation in depth CNN-based hyperspectral image classification algorithm, a bilateral fusion block network (DFBN) composed of bilateral fusion blocks was designed. The upper structure of bilateral fusion block was constituted by 1×1 convolution and hyperlink, which was used to transfer local spatial characteristics. The lower structure was constituted by pooling layer, convolutional layer, deconvolution layer and upsampling to enhance the characteristics of efficient discrimination. Experimental results on three benchmark hyperspectral image data sets illustrate that the model is superior to other similar classification models.

Key words: convolutional neural network, hyperspectral images classification, transpose-convolution, upsampling, hyperlink

1 引言

近年来, 高光谱图像 (HSI, hyperspectral image) 引起了人们的广泛关注, 在各种遥感领域, 如农业监测、环境监测、海洋遥感等^[1-4]中都有应用。由于数百条光谱波段为地物信息的识别与分类提供了极为丰富的光谱信息, 在早期的研究中, 利用光谱

信息进行分类成为一个热门方向^[5-7], 其中, 特征选择和降维^[8-13]的方法常被用于缓和光谱维的高维性。随着研究的深入, 高光谱图像复杂的空间、光谱特征分布成为困扰高光谱图像分类的主要问题, 许多研究者选择加入空间局部联系性来提升模型的性能^[14-17], 并取得了一定的效果。但这些方法大多基于手工特征和浅层模型, 不仅高度依赖专

收稿日期: 2020-07-07; 修回日期: 2020-09-07

通信作者: 李臣明, lcm@hhu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61701166); 中央高校基本科研业务费基金资助项目 (No.B200202183); 江苏省研究生科研与实践创新计划基金资助项目 (No.SJCX20_0181); 国家重点研发计划基金资助项目 (No.2018YFC1508106)

Foundation Items: The National Natural Science Foundation of China (No.61701166), The Fundamental Research Funds for the Central Universities of China (No.B200202183), Postgraduate Research & Practice Innovation Program of Jiangsu Province (No.SJCX20_0181), The National Key Research and Development Program of China (No.2018YFC1508106)

家知识，而且泛化力差，难以提取具有代表性的判别特征。

深度学习^[18]是目前最热门的算法之一，它的出现使计算机技术在图像分类^[19]、目标探测^[20]等方面取得了巨大的进展。与传统的机器学习算法相比，它可以自动从原始输入数据中由浅到深地提取特征，其学习过程完全自动化，且适应力强。Chen 等^[21]将深度学习引入高光谱图像分类算法中，构建了一种基于堆叠自编码器的深度模型来提取高级特征。Liu 等^[22]提出一种利用深度置信网络提取特征，再结合主动学习对这些特征进行迭代的分类框架。虽然这些光谱分类器已经取得了较好的分类结果，但研究证明，将空间特征合并到分类器中会进一步提升分类精度^[23]。因此，许多研究者将目光转向了在图像识别领域具有核心地位的深度卷积神经网络^[24]。Zhong 等^[25]设计了一种以原始的三维立方体作为输入数据的端到端光谱空间残差网络。Feng 等^[26]设计了一个 3D-2D 深度卷积神经网络 (CNN, convolutional neural network) 模型，利用残差学习和深度可分离卷积来学习深层次光谱空间特征。残差学习^[27]等方法虽然可以解决模型向深度进发时所引发的过拟合等问题，但在解决 CNN 向深层进发时所引起特征图分辨率下降、细节特征丢失，进而导致最终分类精度下降的问题上仍有进一步提升空间。针对这一问题，Li 等^[28]结合反卷积与全卷积来增强空间分辨率，Mou 等^[29]提出一种由全卷积和反卷积搭建的无监督光谱空间特征学习网络结构。这类方法往往需要在反卷积前设置最大池化层来去除冗余，减少计算负担，但最大池化层同样会带来特征丢失的问题，以往的方法往往无法有效克服这种信息丢失，从而导致最终分类结果下降。另一方面，Ma 等^[30]提出一种带有跳跃结构的端到端反卷积网络来学习频谱空间特征，该方法通过超链接来融合深浅层判别特征，从而弥补损失的

特征信息并进一步提升性能。但其面临的一大问题是无法精准地找出最优深浅融合层，同时，过多的跳跃结构也会增加模型过拟合的风险。另一种提取有效判别特征的传统策略是基于特征融合的宽网络，如 Lee 等^[31]提出的利用多尺度滤波器的空间光谱特征融合的分类方法和 Gao 等^[32]提出的多分支融合分类方法。但这些宽网络往往只是对某一特征图进行优化，而对其他特征图优化不足。

为了解决这些问题，本文提出了一种双边融合块网络 (DFBN, bilateral fusion block network) 对高光谱图像进行分类，与以往的高光谱图像分类算法模型通过增加深度或广度来获取更为丰富的特征相比，它更加注重挖掘已被提取的特征信息，即将同一特征图内更具有代表性的判别特征与其他特征相分离，并采取不同方法进行处理，从而完成对特征图的优化。在结构方面，它由上下 2 个结构组成，常规卷积、转置卷积、上采样和最大池化层为下结构， 1×1 卷积层和超链接为上结构。下结构负责对更具代表性判别特征进行强化处理，上结构负责传递被丢失的局部空间联系性信息。所有结构共同作用，以达成更高效的分类精度。

2 提出方法

2.1 双边融合块网络

图 1 展示了双边融合块网络高光谱分类框架的总体流程。从图 1 可以看出，为缓和维性、节约计算成本，首先应用主成分分析法 (PCA, principal component analysis) 抽象出高光谱图像中最具有信息量的波段子集；然后建立以标记像素为中心的图像块，并传送给双边融合块网络进行训练；最后对待测像素的标签进行预测。其中，双边融合块网络主体由双边融合块、全连接以及 sigmoid 分类函数构成，双边融合块的个数与高光谱图像的复杂程度相关。

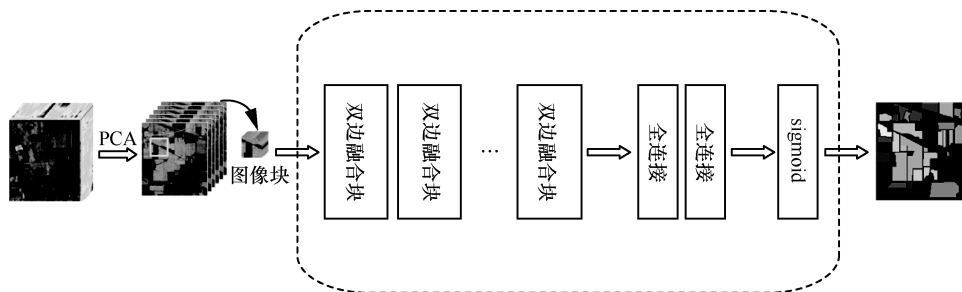


图 1 双边融合块网络高光谱分类框架的总体流程

2.2 双边融合块

图 2 展示了双边融合块的整体结构，它由上下 2 个结构组成。上结构负责传递原始局部空间联系性，由一个带有 1×1 卷积的超链接构成；下结构负责提取更具代表性的判别特征并强化，由 2 个卷积层、一个最大池化层，以及带有上采样层和转置卷积层的双层结构共同组成。下面以基准数据集 IP (Indian Pines) 的参数设置为例，展示双边融合块的具体设置。

首先，将输入图像块的大小设置为 $15, 21 \times 21$ (表示空间尺寸为 21 像素 \times 21 像素，图层共计 15 层)，并将第一卷积层中的滤波器尺寸设置为 $16, 5 \times 5$ ，步长设置为 $(1, 1)$ ，输入图像块与滤波器卷积后得到尺寸为 $16, 21 \times 21$ 的新特征图。然后，利用缩小比例因数为 $(3, 3)$ 的池化层对该特征图进行最大特征提取，以此得到一个尺寸为 $16, 7 \times 7$ 的特征图。包含转置卷积和上采样的双层结构将会对该特征图进行强化处理，将前者的滤波器尺寸设置为 $16, 3 \times 3$ ，步长设置为 $(3, 3)$ ，后者则沿着特征图的行和列分别将这些最大特征重复 3 次，二者所得特征图结合为一个 $32, 21 \times 21$ 的融合特征图。该融合特征图被传递给滤波器尺寸为 $64, 5 \times 5$ 的第二卷积层，并在 Relu 处理前，与上结构中经 $64, 1 \times 1$ 的滤波器处理后得到的尺寸为 $64, 21 \times 21$ 的特征图相融合，进而得到最终输出特征图谱。本文还为每层卷积添加了批量归一化 (BN, batch normalization) 和 Relu 函数加快训练过程，提高泛化能力。

池化层在提取优质特征，去除噪声冗余和抑制过拟合等方面有着出色的表现。在本设计中，池化操作将提取特征图内最优特征，双层结构负责对最优特征进行强化，即利用转置卷积重构最优特征的特征图谱，扩展其空间分辨率；利用上采样将最优

特征复制到一定空间范围内。最后将二者的输出拼接，得到更具代表性的判别特征强化图。

图 3 展示了转置卷积和上采样的原理。转置卷积层可以将单个输入特征与多个输出特征相关联。上采样将池化层提取出的最大特征值直接复制到附近位置上，从而扩充特征图谱。




图 3 转置卷积与上采样原理

3 实验结果与分析

3.1 高光谱图像设置

本文将在 IP、PU (University of Pavia)、SA (Salina) 这 3 个基准数据集上对所提双边融合块网络进行测试，以验证其有效性。

IP 数据集是由 AVIRIS 传感器在印第安纳州西北部上空拍摄的。它在空间域上由 $145 \text{ 像素} \times 145 \text{ 像素}$ 组成；在光谱域上则由 224 个光谱反射率波段组成，其波长范围为 $0.4 \sim 2.45 \mu\text{m}$ 。其中，可用的地面真相为 16 个类，本文的实验中去掉 20 个吸水带，最终选用数据集光谱波段总数为 200 条。

PU 数据集是由 ROSIS 传感器在意大利北部上

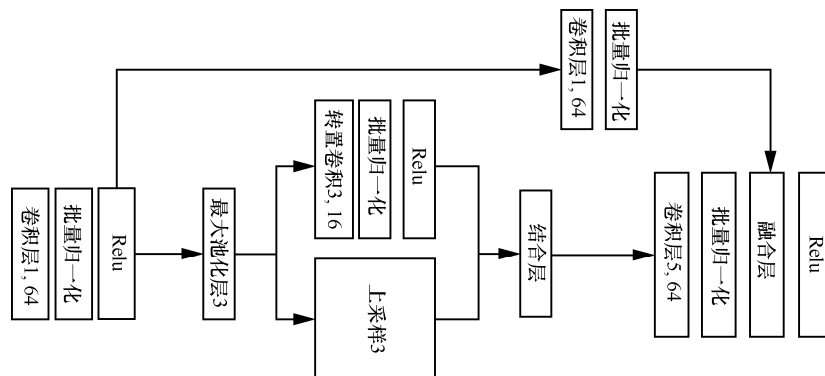


图 2 双边融合块结构

空拍摄的，它在空间域上由 610 像素×340 像素组成；去掉吸水带后，光谱域上由 103 个光谱波段构成，光谱覆盖范围为 430~860 nm。其中，地面真相为 9 个类，本文实验中使用的数据集光谱波段总数为 103 条。

SA 数据集是由 AVIRIS 传感器在加利福尼亚州上空拍摄的，它在光谱域上具有 224 个波段，空间域上则是由 512 像素×217 像素组成，它还具有高空分辨率（3.7 米/像素）的特点。去掉 20 个吸水带后，实验数据集波段总数为 204 条，其可用的地面真相为 16 个类。

图 4 展示了上述数据集相应参考数据的色彩合成以及每个分类的样本集的数量。

3.2 实验设置

本文所提双边融合块网络基于 Python 语言与 keras 深度学习框架。实验环境为 64 位 Windows10 操作系统，RAM 16 GB 和 NVIDIA GeForce GTX 1660 Ti 6 GB GPU。为了防止不同的训练样本所带

来的偏差，本文实验取相同条件下 20 个以上的实验结果的平均值进行分析。本模型采用随机梯度下降法更新权重，学习率为 0.01，全连接中的 Dropout 层断开的神经元比例设置为 0.3，激活函数为 Relu。本文还对双边融合块网络进行了小批量梯度下降的训练，训练样本设置为 16 个，epoch 设置为 200。

对于 IP 数据集，随机选取 10%作为训练样本，并将剩余 90%作为测试样本。对于 PU 数据集，随机选取 2%作为训练样本，并将剩余 98%作为测试样本。对于 SA 数据集，随机选取 0.5%作为训练样本，并将剩余 99.5%作为测试样本。

为了更好地衡量分类准确度，采用总体精度 OA 表示被正确分类的类别像元数与总的类别个数的比值，Kappa 系数 KA 表示分类与完全随机的分类产生错误减少的比例，平均精度 AA 表示各类别的平均准确率。

3.3 模型合理性测试

双边融合块网络的最优参数如表 1 所示。



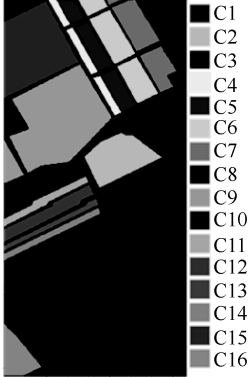
IP数据集			PU数据集			SA数据集		
								
类别	名称	样本数/个	类别	名称	样本数/个	类别	名称	样本数/个
C1	Alfalfa	46	C1	Asphalt	6 631	C1	Brocoli_green_weeds_1	2 009
C2	Corn-notill	1 428	C2	Meadows	18 649	C2	Brocoli_green_weeds_2	3 726
C3	Corn-mintill	830	C3	Gravel	2 099	C3	Fallow	1 976
C4	Corn	237	C4	Trees	3 064	C4	Fallow_rough_plow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

图 4 IP、PU 和 SA 数据集的样本设置

表 1 双边融合块网络最优参数

层	内核	输出尺寸		
		IP 数据集	PU 数据集	SA 数据集
图像块	—	21 像素×21 像素, 15 层	21 像素×21 像素, 15 层	33 像素×33 像素, 21 层
卷积层 1	5×5	21 像素×21 像素, 16 层	21 像素×21 像素, 24 层	33 像素×33 像素, 16 层
最大池化层	3×3	7 像素×7 像素, 16 层	7 像素×7 像素, 24 层	11 像素×11 像素, 16 层
转置卷积和上采样	3×3	21 像素×21 像素, 16 层	21 像素×21 像素, 24 层	33 像素×33 像素, 16 层
结合层	—	21 像素×21 像素, 32 层	21 像素×21 像素, 48 层	33 像素×33 像素, 32 层
卷积层 2	5×5	21 像素×21 像素, 64 层	21 像素×21 像素, 96 层	33 像素×33 像素, 64 层
1×1 卷积	1×1	21 像素×21 像素, 64 层	21 像素×21 像素, 96 层	33 像素×33 像素, 64 层
融合层	—	21 像素×21 像素, 64 层	21 像素×21 像素, 96 层	33 像素×33 像素, 64 层
全连接 1	Relu		128	
全连接 2	Relu		64	
训练参数	—	3 924 928	5 922 401	9 074 528
双边融合块个数	—	4	3	2

为了印证双边融合块中各个层的有效性, 本文以 IP 数据集为代表, 对设置不同层的合理性进行分析, 结果如表 2 所示。从表 2 中可以看出, 当不采用转置卷积、上采样和超链接时, OA 仅为 97.78%, 分别加入上述 3 种优化手段后, OA 均有不同程度的提升。当同时使用上采样和转置卷积时, OA 达到 98.37%, 明显优于单一采用转置卷积或上采样的 98.15%和 98.29%。超链接结构的加入也使 OA 提升, 这是因为引入了原始局部空间相关性。同时采用上述 3 种优化手段, OA 达到 98.45%。

表 2 利用 IP 数据集对双边融合块网络进行层设置分析

超链接	上采样	转置卷积	OA	AA	KA
×	×	×	97.78%	91.19%	97.46%
×	×	√	98.15%	95.53%	97.89%
×	√	×	98.29%	96.61%	98.05%
√	×	×	97.83%	95.46%	97.53%
×	√	√	98.37%	96.82%	98.14%
√	√	×	98.39%	96.58%	98.17%
√	×	√	98.35%	95.33%	98.12%
√	√	√	98.45%	96.12%	98.23%

3.4 小样本测试

小样本问题是现有 HSI 分类方法中普遍存在的问题。为了评估双边融合块网络在小训练集下的分类性能, 本文从各类中随机抽取一定比例的样本作为训练集, 剩下的样本作为测试集。对于 IP 数据集, 本文随机选取了 1%、3%、5%、7%、10%的训练样本进行测试; 对于 PU 数据集, 随机选取 0.5%、1%、2%、3%、5%的训练样本进行测试; 对于 SA 数据

集, 随机选取 0.1%、0.5%、1%、2%、3%的训练样本进行测试。测试结果如表 3~表 5 所示。可以看出, 双边融合块网络具有非常好的小样本分类性能, 对 SA 数据集分类表现最佳, 0.5%的训练样本 OA 即可达到 98.71%; 其次是 PU 数据集, 2%的训练样本的 OA 为 98.74%; 在 IP 数据集的表现上, 10%的训练样本 OA 可达 98.45%。

表 3 IP 数据集在小样本情况下的分类结果

训练样本占比	KA	OA	AA
1%	59.53%	64.97%	46.41%
3%	84.88%	86.81%	73.92%
5%	94.03%	94.78%	85.37%
7%	96.70%	97.11%	91.97%
10%	98.23%	98.45%	96.12%

表 4 PU 数据集在小样本情况下的分类结果

训练样本占比	KA	OA	AA
0.5%	86.57%	89.99%	81.53%
1%	95.10%	96.41%	92.82%
2%	98.33%	98.74%	97.74%
3%	99.09%	99.31%	98.56%
5%	99.53%	99.65%	99.14%

表 5 SA 数据集在小样本情况下的分类结果

训练样本占比	KA	OA	AA
0.1%	80.32%	82.46%	76.41%
0.5%	98.56%	98.71%	98.64%
1%	99.68%	99.71%	99.62%
2%	99.86%	99.87%	99.80%
3%	99.91%	99.92%	99.91%

3.5 与其他模型的比较

为了评价所提双边融合块网络的性能，本文将与 5 种经典的基于卷积神经网络的高光谱图像分类模型进行对比，包括 RPCA-CNN(randomized principal component analysis convolutional neural network)模型^[13]、带有多尺度滤波器的深度网络 DCNN(contextual deep convolutional neural network)模型^[31]、反卷积增强网络 FCNN(full convolutional neural network)模型^[28]、利用空谱特征进行分类的 3D 网络 SSRN(spectral-spatial-residual network)模型^[25]和具有 16 层卷积的 2D 经典残差网络 DRN(deep residual network)模型^[27]。为了使所有的性能评估基于相同的条件，DCNN 模型、FCNN 模型、SSRN 模型与 DRN 模型均采用了批量归一化层优化训练过程，批尺寸为 16 个。RPCA-CNN 批尺寸为 32 个。为了更好地与传统残差网络进行对比，DRN 模型的训练集与双边融合块网络相同。其余参数参考相关文献设置。

本文测试了训练样本大小固定的情况下，各种模型的性能。在 IP 数据集中随机选取 10% 的样本进行训练，其余 90% 的样本进行测试。图 5 展示了不同模型分类效果。从图 5 中可以看出，RPCA-CNN 模型分类效果最差，其分类图中具有相当大的噪声，这是因为其模型深度不够，不能提取到具有代表性的判别特征，同时对训练过程中出现的过拟合、分辨率下降等现象没有做出相应优化调整。而在另外 4 种经典分类模型中，注重增加网络深度的

算法模型(SSRN 模型、DRN 模型、DFBN 模型)所取得分类结果要明显优于其他对比模型。此外，与 SSRN 模型和 DRN 模型相比，所提 DFBN 模型能够更准确地对近边缘区域的像素进行分类，并提供与参考图(图 4)更加相似的结果。表 6 和表 7 给出了针对 IP 数据集的定量分析结果。RPCA-CNN 模型所取得的定量分析结果最差，所提 DFBN 模型在 OA、KA 上均取得了最优的结果，而在 AA 上略低于 SSRN 模型，这是由于在 IP 数据集中存在类别样本极度不均衡的现象，而基于 3D 卷积神经网络的 SSRN 模型在加入了原始高光谱图像的光谱上下文联系后，克服了这一缺点，但其忽略了卷积神经网络在向深处进发所引发的空间分辨率下降，以及对已提取到特征的利用，所以在精度方面的综合评价上，本文所提 DFBN 模型取得了最优结果。

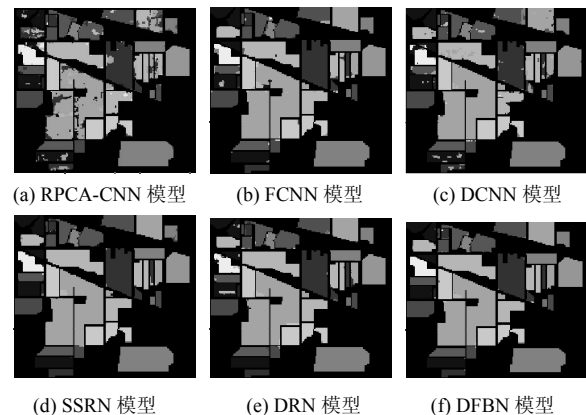


图 5 不同方法对 IP 在标记像素上的分类结果

表 6 在 IP 数据集下与其他分类模型的比较

类别	RPCA-CNN 模型	FCNN 模型	DCNN 模型	SSRN 模型	DRN 模型	DFBN 模型
Alfalfa	34.88%	90.12%	43.66%	93.41%	90.37%	96.10%
Corn-notill	60.91%	93.11%	89.91%	97.59%	94.30%	95.54%
Corn-mintill	57.19%	97.03%	93.68%	98.71%	96.14%	99.35%
Corn	54.32%	93.92%	82.86%	91.22%	85.12%	98.99%
Grass-pasture	92.08%	96.34%	97.31%	99.79%	98.31%	98.77%
Grass-trees	97.63%	97.60%	99.09%	99.70%	98.86%	99.06%
Grass-pasture-mowed	79.20%	99.00%	91.20%	98.60%	93.80%	96.20%
Hay-windrowed	99.93%	99.30%	99.91%	99.84%	99.95%	99.97%
Oats	57.22%	82.78%	69.17%	95.28%	78.06%	73.89%
Soybean-notill	76.05%	97.49%	93.69%	99.25%	98.13%	98.63%
Soybean-mintill	63.95%	98.28%	94.14%	96.30%	99.04%	99.51%
Soybean-clean	48.16%	91.83%	91.22%	97.21%	92.36%	96.47%
Wheat	99.30%	96.32%	99.76%	99.78%	98.57%	97.49%
Woods	94.79%	99.78%	98.78%	99.73%	99.73%	99.93%
Buildings-Grass-Trees-Drives	77.59%	93.78%	85.46%	95.26%	96.71%	98.90%
Stone-Steel-Towers	99.82%	87.20%	96.13%	98.75%	89.17%	89.11%

表 7 针对 IP 数据集的分类结果

分类模型	KA	OA	AA
RPCA-CNN 模型	70.08%	73.65%	74.56%
FCNN 模型	96.15%	96.63%	94.62%
DCNN 模型	93.05%	93.91%	89.12%
SSRN 模型	97.64%	97.93%	97.53%
DRN 模型	96.75%	97.15%	94.29%
DFBN 模型	98.23%	98.45%	96.12%

第二和第三个实验分别在 PU 数据集和 SA 数据集上进行。对 PU 数据集，随机选取 2% 作为训练样本，剩余的样本作为测试样本。对于 SA 数据集，选取 0.5% 作为训练样本，剩余样本作为测试样本。图 6 和图 7 给出了由不同分类方法得到的分类图，表 8~表 11 为相应的定量分析结果。同样地，在视觉效果上，本文所提方法在 2 个数

据集上所展示的地物分类图拥有最少的噪声且与图 4 所展示的地物分类参考图最为相近；在定量分析中，DFBN 模型在 PU 数据集和 SA 数据集上的 OA 分别达到了 98.45% 和 98.74%，OA、KA 及 AA 均高于其他对比方法。所提 DFBN 模型在 IP 数据集、PU 数据集和 SA 数据集上均有较好的性能。

表 9 针对 PU 数据集的分类结果

分类模型	KA	OA	AA
RPCA-CNN 模型	75.39%	80.94%	85.15%
FCNN 模型	84.91%	88.74%	78.32%
DCNN 模型	92.40%	94.30%	89.42%
SSRN 模型	97.88%	98.40%	97.60%
DRN 模型	96.30%	97.21%	95.16%
DFBN 模型	98.33%	98.74%	97.74%




图 6 不同方法对 PU 在标记像素上的分类结果

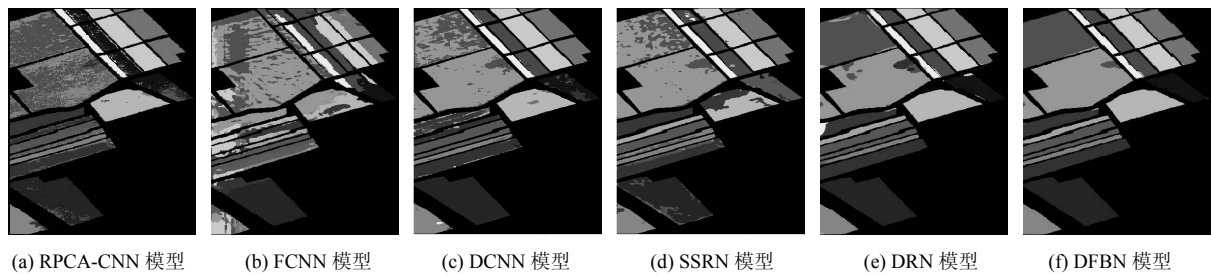


图 7 不同方法对 SA 数据集在标记像素上的分类结果

表 8 在 PU 数据集下与其他分类模型的比较

类别	RPCA-CNN 模型	FCNN 模型	DCNN 模型	SSRN 模型	DRN 模型	DFBN 模型
Asphalt	70.04%	86.46%	96.79%	97.40%	97.42%	98.16%
Meadows	84.28%	98.41%	99.23%	99.89%	99.75%	99.86%
Gravel	88.17%	65.25%	67.98%	88.64%	89.02%	96.11%
Trees	92.97%	71.72%	97.03%	97.08%	95.81%	96.60%
Painted metal sheets	100.00%	84.11%	96.50%	99.91%	94.94%	97.22%
Bare Soil	75.27%	91.61%	92.10%	99.54%	99.73%	99.61%
Bitumen	95.69%	61.62%	67.64%	99.55%	94.93%	98.81%
Self-Blocking Bricks	60.09%	86.58%	88.08%	96.44%	88.13%	97.52%
Shadows	99.88%	59.14%	99.41%	99.98%	96.75%	95.78%

表 10 在 SA 数据集下与其他分类模型的比较

类别	RPCA-CNN 模型	FCNN 模型	DCNN 模型	SSRN 模型	DRN 模型	DFBN 模型
Brocoli_green_weeds_1	99.99%	57.71%	77.03%	95.48%	97.36%	99.45%
Brocoli_green_weeds_2	81.90%	78.83%	98.25%	97.97%	99.34%	99.96%
Fallow	22.50%	85.04%	82.33%	87.17%	94.87%	99.97%
Fallow_rough_plow	91.23%	81.69%	98.76%	97.45%	93.77%	98.34%
Fallow_smooth	59.10%	97.54%	92.29%	95.11%	93.54%	98.57%
Stubble	99.53%	93.73%	99.94%	99.90%	98.23%	99.81%
Celery	93.05%	77.67%	98.40%	98.79%	98.16%	99.48%
Grapes_untrained	36.76%	78.56%	69.84%	80.93%	95.05%	96.78%
Soil_vinyard_develop	72.10%	97.90%	99.12%	99.55%	99.70%	100.00%
Corn_senesced_green_weeds	73.37%	98.07%	91.87%	93.60%	97.35%	99.77%
Lettuce_romaine_4wk	60.86%	84.15%	25.40%	86.31%	92.99%	98.25%
Lettuce_romaine_5wk	22.66%	96.44%	98.61%	91.50%	89.96%	99.71%
Lettuce_romaine_6wk	41.34%	84.12%	98.98%	98.09%	89.46%	93.87%
Lettuce_romaine_7wk	97.60%	91.01%	88.94%	93.96%	92.79%	95.75%
Vinyard_untrained	63.91%	55.72%	74.50%	72.31%	89.33%	98.62%
Vinyard_vertical_trellis	86.25%	39.11%	93.87%	94.39%	97.75%	99.87%

表 11 针对 SA 数据集的分类结果

分类模型	KA	OA	AA
RPCA-CNN 模型	61.45%	64.70%	68.48%
FCNN 模型	77.87%	80.21%	81.08%
DCNN 模型	84.00%	85.60%	86.76%
SSRN 模型	88.64%	89.79%	92.66%
DRN 模型	94.87%	95.39%	95.15%
DFBN 模型	98.56%	98.71%	98.64%

4 结束语

本文提出了一种基于卷积神经网络的高光谱图像分类模型 DFBN。作为一种新的提取判别特征的模型，它有效克服了空间分辨率下降和特征信息丢失所带来的精度下降问题，此外，它提供了一种新的提取更具代表性判别特征的思路。在 3 个真实的 HSI 上的实验结果表明，所提模型在分类图的视觉质量和定量指标上均有出色的表现。

虽然双边融合块网络在性能方面非常优异，但仍缺乏对上、下结构所获得的特征图进行权重分配的研究。在未来的工作中，将引入注意力机制，系统地分配 2 个特征图占比，进一步提高分类精度。

参考文献：

- [1] LUO B, YANG C H, CHANUSSOT J, et al. Crop yield estimation based on unsupervised linear unmixing of multivariate hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(1): 162-173.
- [2] YUEN P W T, RICHARDSON M. An introduction to hyperspectral imaging and its application for security, surveillance and target acquisition [J]. Imaging Science Journal, 2010, 58(5): 241-253.
- [3] SANDIDGE J C, HOLYER R J. Coastal bathymetry from hyperspectral observations of water radiance [J]. Remote Sensing of Environment, 1998, 65(3): 341-352.
- [4] 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.
- [5] 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.
- [6] SAMANIEGO L, BARDOSSY A, SCHULZ K. Supervised classification of remotely sensed imagery using a modified KNN technique[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(7): 2112-2125.
- [7] 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.
- [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] JIA S, TANG G H, ZHU J S et al. A novel ranking-based clustering approach for hyperspectral band selection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(1): 88-102.
- [10] 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.
- [11] VILLA A, BENEDIKTSSON J A, CHANUSSOT J, et al. Hyperspectral image classification with independent component discriminant analysis[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(12): 4865-4876.
- [12] LIU X, ZHANG B, GAO L R, et al. A maximum noise fraction transform with improved noise estimation for hyperspectral images[J]. Science in China Series F-information Sciences, 2009, 52(9): 1578-1587.
- [13] MAKANTASIS K, KARANTZALOS 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. Piscataway: IEEE Press, 2015: 4959-4962.
- [14] GHAMISI P, PLAZA J, CHEN Y S, et al. Advanced spectral classifiers for hyperspectral images: a review[J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(1): 8-32.
- [15] 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.
- [16] 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.
- [17] CHEN P, NELSON J D B, TOURNERET J Y. Toward a sparse Bayesian Markov random field approach to hyperspectral unmixing and classification[J]. IEEE Transactions on Image Processing, 2017, 26(1): 426-438.
- [18] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [19] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [20] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2014: 580-587.
- [21] 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.
- [22] 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.
- [23] GHAMISI P, MAGGIORI E, LI S T, et al. New frontiers in spectral-spatial hyperspectral image classification the latest advances based on mathematical morphology, Markov random fields, segmentation, sparse representation, and deep learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(3): 10-43.
- [24] LI S T, SONG W W, FANG L Y, et al. Deep learning for hyperspectral image classification: an overview[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(9): 6690-6709.
- [25] ZHONG Z L, LI J, LUO Z M, et al. Spectral-spatial residual network for hyperspectral image classification: a 3D deep learning framework[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(2): 847-858.
- [26] FENG F, WANG S T, WANG C Y, et al. Learning deep hierarchical spatial-spectral features for hyperspectral image classification based on residual 3D-2D CNN[J]. Sensors, 2019, 19(23): 5276.
- [27] 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.
- [28] LI J J, ZHAO X, LI Y S, et al. Classification of hyperspectral imagery using a new fully convolutional neural network[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(2): 292-296.
- [29] MOU L C, GHAMISI P, ZHU X X. Unsupervised spectral-spatial feature learning via deep residual conv-deconv network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(1):391-406.
- [30] MA X R, FU A Y, WANG J, et al. Hyperspectral image classification based on deep deconvolution network with skip architecture[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(8): 4781-4791.
- [31] LEE H, KWON H. Going deeper with contextual CNN for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2017, 26(10): 4843-4855.
- [32] GAO H M, YANG Y, LEI S, et al. Multi-branch fusion network for hyperspectral image classification[J]. Knowledge-Based Systems, 2019, 167: 11

[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。

杨耀 (1995-)，男，江西宜春人，河海大学硕士生，主要研究方向为深度学习与图像处理等。

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。