

边缘保护滤波和深度残差网络结合的高光谱影像分类

吕欢欢^{1,2}, 王琢璐¹, 张辉^{2*}¹辽宁工程技术大学软件学院, 辽宁 葫芦岛 125105;²湖州师范学院信息工程学院, 浙江 湖州 313000

摘要 针对高光谱影像波段间相关度高、光谱和空间结构复杂性高和训练样本数量有限等问题, 提出一种边缘保护滤波和深度残差网络结合的分类方法。首先采用联合双边滤波增强地物的边缘结构以提取出高质量的空间特征, 将空间特征与光谱特征融合得到原始空谱特征; 然后构建二维卷积神经网络, 在卷积层中加入跳层连接将模型改进为一种深度残差网络模型; 最后采用该模型提取影像的深层空谱特征并将其输入到 Softmax 分类器完成影像分类。实验在两个数据集上与相关先进方法比较, 结果表明, 本文方法考虑到了地物边缘结构的重要作用, 缓解了卷积神经网络分类中的过拟合现象, 显著提高了高光谱影像的分类精度。

关键词 成像系统; 高光谱遥感影像; 空谱特征; 联合双边滤波; 卷积神经网络; 残差网络

中图分类号 TP751

文献标志码 A

DOI: 10.3788/LOP202259.1611005

Hyperspectral Image Classification Based on Edge-Preserving Filter and Deep Residual Network

Lü Huanhuan^{1,2}, Wang Zhuolu¹, Zhang Hui^{2*}¹School of Software, Liaoning Technical University, Huludao 125105, Liaoning, China;²School of Information Engineering, Huzhou University, Huzhou 313000, Zhejiang, China

Abstract Herein, we proposed a hyperspectral image classification method using an edge-preserving filter and deep residual network due to the characteristics of the strong correlation between hyperspectral image bands, high complexity of spectral and spatial structures, and a limited number of training samples. First, we applied joint bilateral filtering to enhance the edge structure of ground objects and extract high-quality spatial features. The extracted spatial features were fused with spectral features to obtain the spatial-spectral features. Furthermore, we constructed a two-dimensional convolutional neural network and improved the model to a deep residual network model by adding a hop layer connection in the convolutional layer. Then, the model was used to extract the deep spatial-spectral features and input them to the Softmax classifier. We compare the experiment with related state-of-the-art methods on two datasets, and the results show that the proposed method alleviates the overfitting phenomenon in the convolutional neural network classification and considers the important role of the edge structure of ground objects, which significantly improves the classification accuracy of the hyperspectral images.

Key words imaging systems; hyperspectral remote sensing image; spatial-spectral feature; joint bilateral filtering; convolutional neural network; residual network

1 引言

高光谱遥感影像中含有丰富的光谱信息和空间信息, 已广泛应用于目标检测^[1]、精细农业^[2]、矿物填图^[3]等领域。高光谱影像分类是实现众多应用的关键步骤, 然而高光谱影像波段间相关度高、光谱和空间结构

复杂性高和训练样本数量有限等特点给分类任务带来了巨大的挑战, 如维数灾难、空间同质性与异质性问题^[4]。

支持向量机^[5]、高斯混合模型^[6]、随机森林^[7]和稀疏表达^[8]等分类模型的提出促进了高光谱遥感影像分类的发展, 然而传统的分类方法仅利用了影像的光谱

收稿日期: 2021-07-18; 修回日期: 2021-08-11; 录用日期: 2021-08-23

基金项目: 国家自然科学基金(61540056)、辽宁省自然科学基金(20180550450)

通信作者: *wangzl2019@126.com

信息导致分类结果不够理想。因此,研究人员提出了空-谱特征融合的高光谱遥感影像分类方法。Zhao等^[9]首先利用局部保持投影保留原始影像的局部结构并去除冗余,然后通过局部二值模式(LBP)获取局部结构中的纹理特征,最后将特征输入到宽度学习系统中实现影像分类。Zhang等^[10]首先采用主成分分析(PCA)提取影像的若干主成分,然后分别通过Gabor滤波和LBP提取影像特征并与原始特征融合,最后将融合后的特征输入到深度网络中进行分类。在空间特征提取时的过度平滑容易导致地物边缘处的错分问题,Soomro等^[11]和陈志坤等^[12]采用双边滤波提取空间纹理信息用于高光谱影像分类,获得了较好的分类效果,然而双边滤波中的权值并不稳定,在影像边缘邻域内易出现翻转现象。Qiao等^[13]通过联合双边滤波在高光谱影像空间特征提取时实现了边缘模糊度的最小化,并且从理论和实验上验证了和传统双边滤波相比,联合双边滤波能够更好地改善图像质量,特别是那些低对比度的图像波段。由此可见,联合双边滤波在空间特征提取方面显示了其突出的能力,因其对影像边缘信息有明显的保护效果而受到关注。

深度学习通过多层神经网络的训练可以很好地获取更深层次的特征表达,近年来广泛应用于高光谱遥感影像分类领域中。Chen等^[14]率先采用堆栈式自编码器(SAE)提取高光谱影像深层特征完成分类,由于SAE固有的网络结构导致需要对大量参数寻优,给模型效率带来了不利的影响。此外,卷积神经网络(CNN)^[15]、递归神经网络(RNN)^[16]和深度置信网络(DBN)^[17]等深度学习技术也被应用于高光谱影像分类中,其中CNN作为一种监督学习方法可以通过其权值共享、局部连接等特性减少模型参数,提高分类性能。Liu等^[18]使用了一个具有六层结构的三维卷积神

经网络(3D-CNN)提取影像的空谱特征;Ahmad等^[19]提出了小规模卷积神经网络(2D/3D-CNN)模型,首先在原始影像中提取一个空间大小为 $9 \times 9 \times 15$ 的数据块,然后将其输入到由三个三维卷积层、一个二维卷积层和两个全连接层构成的网络模型中进行训练并实现影像分类。上述方法在提高分类精度方面取得了一定的成效,但是CNN固有的特点导致现有的高光谱影像分类方法普遍存在一定的局限性:一方面,当训练样本过少时,CNN往往会产生过拟合现象,另一方面,过多的网络层数会引起梯度消失、网络退化的问题。

针对以上问题,本文提出一种边缘保护滤波和深度残差网络结合的高光谱影像分类方法(JBF-Res-2DCNN)。本文方法在空间特征提取时采用联合双边滤波增强影像中地物的边缘结构,可以很好地增加样本的多样性,在有限样本条件下进一步减少了CNN训练过程中的过拟合问题。同时为避免由网络层数增加导致的网络退化和梯度消失问题对模型性能的影响,引入残差网络来实现通过跳层连接在保持参数量不变的同时提升网络性能。因此,本文方法在顾及边缘信息的基础上能够充分提取和利用影像的深层空谱特征,有效提高了高光谱影像的地物分类精度。

2 本文方法

本文方法的总体流程如图1所示。首先,采用PCA对高光谱影像进行降维;其次,取前三主成分作为输入图像,将第一主成分作为引导图像利用联合双边滤波对降维后的影像进行处理,提取影像中各像素的空间邻域信息结合光谱特征构造影像的空谱特征;然后,构建一种深度残差网络模型,并将提取的空谱特征输入到所构建的模型中获得深层空谱特征;最后,通过Softmax逻辑回归实现影像分类。




图1 本文方法的总体流程

Fig. 1 Overall flow of the proposed method

2.1 联合双边滤波

联合双边滤波是一种典型的边缘保护滤波方法,其主要思想是在值域的计算过程中引入另一幅图像来得到值域距离权重,针对影像中的像素点对其周围的

像素进行加权平均计算,在保留边缘信息的基础上实现了对图像的平滑。近年来边缘保护滤波已经在计算机视觉领域受到广泛关注并应用到许多方面,如图像去噪、图像增强、图像融合等。

假设输入高光谱影像表示为 V , 引导图像表示为 \tilde{V} , i 和 j 为像素索引, 输入影像中第 i 个像素 V_i 经滤波后对应的输出像素值 J_i 表示为

$$J_i = \frac{1}{K_i} \sum_{V_j \in \eta(V_i)} f_{\delta_c}(V_i, V_j) g_{\delta_s}(\tilde{V}_i, \tilde{V}_j) O_j, \quad (1)$$

式中: 在以像素 V_i 为中心的邻域范围 η 内的空间近邻点表示为 $V_j [V_j \in \eta(V_i)]$; \tilde{V}_i 和 \tilde{V}_j 是在引导图像中对应像素的灰度值; O_j 为像素点 V_j 的邻域像素加权; K_i 为归一化因子。 K_i 表示为

$$K_i = \sum_{V_j \in \eta(V_i)} f_{\delta_c}(V_i, V_j) g_{\delta_s}(\tilde{V}_i, \tilde{V}_j), \quad (2)$$

式中: f_{δ_c} 和 g_{δ_s} 分别表示空域距离权重和值域距离权重。其计算公式为

$$f_{\delta_c}(V_i, V_j) = \exp\left(-\frac{\|V_i - V_j\|^2}{2\delta_c^2}\right), \quad (3)$$

$$g_{\delta_s}(\tilde{V}_i, \tilde{V}_j) = \exp\left(-\frac{\|\tilde{V}_i - \tilde{V}_j\|^2}{2\delta_s^2}\right), \quad (4)$$

式中: δ_c 为滤波核窗口的大小, 即空域距离高斯函数的标准差; δ_s 为随相似度差异变化像素值减小的比例, 即值域距离高斯函数的标准差; δ_c 和 δ_s 共同决定了滤波效果。

对于高光谱原始影像数据, 首先通过 PCA 变换对影像数据进行降维处理^[20-21], 由于前三主成分保留了原始影像中绝大部分信息, 采用前三主成分作为联合双边滤波的输入图像, 第一主成分不仅包含原始影像中最主要的信息, 而且保护了影像绝大部分的边缘信息, 将其作为引导图像。然后通过联合双边滤波进行滤波处理后得到输出影像表示为 J , 并以影像中每个像素为中心构建影像 J 的空谱特征, 提取邻域大小为 $M \times M \times d$ 的高光谱数据立方体及其标签 l 作为训练样本, 其中, 空间邻域表示为 $M \times M$, 根据 Liu 等^[22] 的实验, 将 M 的大小设置为 9; d 表示波段数目, 其值为 3, 将数据立方体输入到深度残差网络中进行下一阶段的深层空谱特征提取。

2.2 深度残差网络

2D-CNN 是一种典型的卷积神经网络, 它可以在

网络输入层直接对高维图像提取特征, 同时有利于处理复杂的分类和识别问题, 在高光谱影像分类领域中取得了很好的效果。网络的第 p 个卷积层的第 q 个特征图在 (a, b) 处的特征值 v_{pq}^{ab} 表示为

$$v_{pq}^{ab} = f \left[\sum_t \sum_{m=0}^{M_p-1} \sum_{n=0}^{N_q-1} \sigma_{pqt}^{mn} v_{(p-1)t}^{(a+m)(b+n)} + b_{pq} \right], \quad (5)$$

式中: t 为第 $p-1$ 层中特征图的个数; M_p 和 N_q 分别为卷积核的长度和宽度; σ_{pqt}^{mn} 为与 (m, n) 处相连的第 t 个特征图的权值; b_{pq} 为第 p 层中第 q 个特征图的偏置; $f(\cdot)$ 为激活函数。

Szegedy 等^[23] 的研究表明, 深层网络可以更好地处理复杂特征的结构。然而, 网络深度的增加会引起梯度爆炸或弥散问题, 导致分类准确率达到饱和状态。受 He 等^[24] 的启发, 可以通过在卷积层中加入跳层连接来解决该问题。跳层连接有助于梯度绕过权重层, 形成残差单元之间的快捷连接。其网络结构如图 2 所示。




图 2 残差单元结构图

Fig. 2 Structure diagram of residual element

残差单元中第 i 层的输入 x_i 和输出 $H(x_i)$ 的关系可表示为

$$H(x_i) = F(x_i) + x_i. \quad (6)$$

将残差模块中的权重矩阵 $\{W_i\}$ 引入式 (6), 在忽略偏差的前提下, 残差映射 $F(x)$ 可表示为

$$F(x, \{W_i\}) = w_2 \mu(W_1 x), \quad (7)$$

式中: μ 为 ReLU 激活函数。则输出结果可表示为

$$z = F(x, \{W_i\}) + x, \quad (8)$$

式中: x 和 $F(x, \{W_i\})$ 需要保持相同的维数。在维数不不同时, 引入线性投影 W_j 保持维数的一致, 即:

$$z = F(x, \{W_i\}) + W_j x. \quad (9)$$

本文构建的深度残差网络如图 3 所示, 该网络由

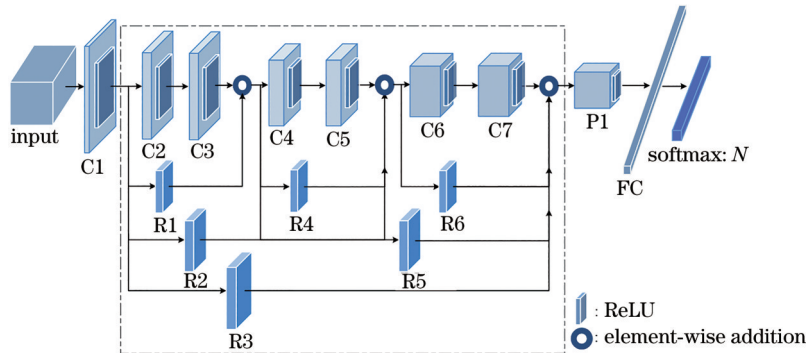


图 3 深度残差网络模型结构

Fig. 3 Model structure of depth residual network

一个卷积层、一个残差学习模块(包含六个卷积层)、一个池化层、一个全连接层和一个 Softmax 层组成。以高光谱数据 Indian Pines 为例,深度残差网络的特征图尺寸和参数变化情况见表 1(卷积核数量确定具体讨论见 3.3 节)。

表 1 深度残差网络的特征图尺寸和参数变化
Table 1 Feature map size and parameter quantities of depth residual network

Input layer	Layer	Feature map size	Params
	Input	9, 9, 3	0
Input	C1	7, 7, 16	448
C1	C2	7, 7, 32	4640
C2	C3	7, 7, 32	9248
C1	R1	7, 7, 32	4640
C3,R1	Add1	7, 7, 32	0
Add1	Activation1	7, 7, 32	0
Activation1	C4	7, 7, 64	18496
C4	C5	7, 7, 64	36928
C1	R2	7, 7, 64	9280
Activation1	R4	7, 7, 64	18496
C5,R2,R4	Add2	7, 7, 64	0
Add2	Activation2	7, 7, 64	0
Activation2	C6	7, 7, 128	73856
C6	C7	7, 7, 128	147584
C1	R3	7, 7, 128	18560
Add1	R5	7, 7, 128	36992
Add2	R6	7, 7, 128	73856
C7,R3,R5,R6	Add3	7, 7, 128	0
Add3	Activation3	7, 7, 128	0
Activation3	P1	5, 5, 128	0
P1	Flatten1	3200	0
Flatten1	FC	256	819456
FC	Dropout	256	0
Dropout	Softmax	16	4112
Total number of parameters			1276592

在构建的深度残差网络模型中,C1~C7、R1~R6 表示卷积核步长为 1、大小为 3×3 的卷积层,P1 表示步长为 1、池化窗口大小为 3×3 的最大池化层,FC 表示全连接层, N 表示类别总数。激活函数可以提高网络的非线性映射能力,由于 ReLU 激活函数^[18]相比于 Sigmoid、Tanh 激活函数的收敛速度更快,所构建模型中卷积层均采用 ReLU 作为网络的激活函数。假设 x 为输入数据,则 ReLU 激活函数可定义为

$$f(x) = \max(0, x) \quad (10)$$

图 3 中虚线框内为一个残差学习模块,用于连接不同卷积层输出的特征图,该模块可以在保持参数量

不变的基础上有效解决高光谱影像数据信息利用不足的问题,提升网络性能。为了减少计算量,本文构建的网络模型在残差学习模块后引入一个池化层 P1。将 P1 输出的特征图转换成一维向量后与全连接层 FC 相连,同时在全连接层 FC 后采用 Dropout 正则化方法随机丢弃一定比例的节点避免过拟合的风险,最终输出一个 256 维的向量 D 。网络的输出层采用 Softmax 线性分类器进行逻辑回归分类,选择最大概率值所对应的类别作为最终结果。

在输出类别标签后使用分类交叉熵函数构造目标函数,通过自适应矩估计优化器对网络进行优化,初始学习率设置为 0.001^[25]。

3 实验与结果分析

3.1 实验数据

为验证本文方法有效性,选取 Indian Pines 和 Pavia University 高光谱遥感影像数据集进行分类实验。

1) Indian Pines 数据集。该数据是由 AVIRIS 传感器在美国印第安纳西北部地区拍摄的植被种植情况,包含 16 类地物,10249 个样本。其影像大小为 $145 \text{ pixel} \times 145 \text{ pixel}$,去除受水气噪声影响的波段后,保留剩余的 200 个波段用于分类,波长范围为 400~2500 nm,空间分辨率为 20 m。该区域的伪彩色图(合成波段为 140、80 和 50)如图 4(a)所示,地面参考图如图 4(b)所示。

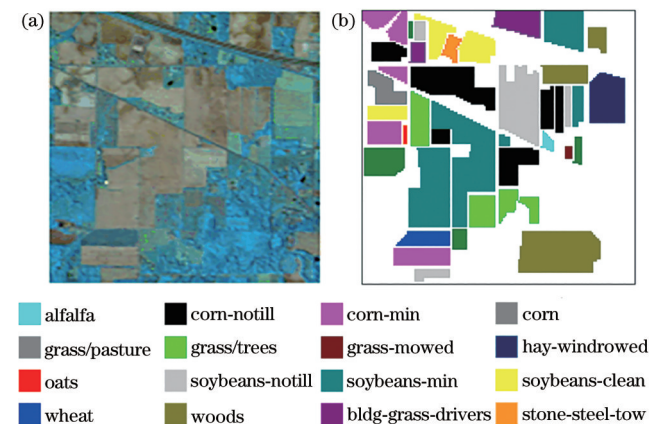


图 4 Indian Pines 数据集。(a) 伪彩色图;(b) 地面参考图
Fig. 4 Indian Pines dataset. (a) False color image;
(b) real ground data

2) Pavia University 数据集。该数据是由 ROSIS 传感器在 Pavia 大学拍摄的校园建筑与环境情况,包含 9 类地物,42776 个样本。其影像大小为 $610 \text{ pixel} \times 340 \text{ pixel}$,去除受水气噪声影响的波段后,保留剩余的 103 个波段用于分类,波长范围为 430~860 nm,空间分辨率为 1.3 m。该区域的伪彩色图(合成波段为 90、60 和 30)如图 5(a)所示,地面参考图如图 5(b)所示。

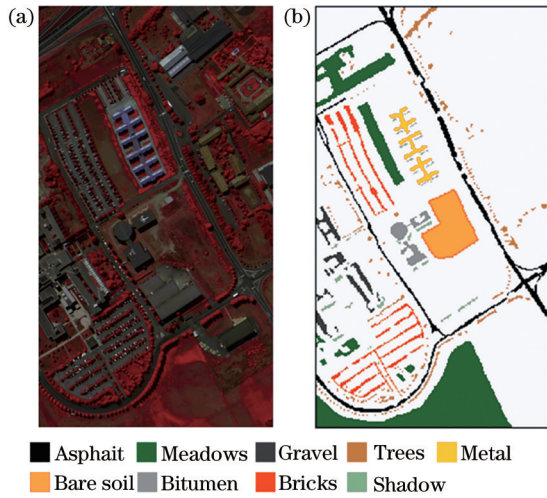


图5 Pavia University 数据集。(a)伪彩色图;(b)地面参考图
Fig. 5 Pavia University dataset. (a) False color image;
(b) real ground data

3.2 对比方法和评价指标

为测试本文方法的性能,选择其他7种相关方法分8组实验对两幅高光谱影像数据分类结果进行对比,分别是:

- 1) 直接利用原始光谱特征进行支持向量机分类(SP-SVM);
- 2) 与本文网络结构相同但未加入残差结构的二维卷积神经网络的分类方法(2DCNN);
- 3) 刘冰等^[26]提出的深度残差网络的分类方法(Res-3DCNN);
- 4) Chen等^[27]提出的双通道卷积神经网络的分类方法(S2FEF-CNN);
- 5) 魏祥坡等^[28]提出的局部二值模式和一维卷积神经网络结合的分类方法(LBP-1DCNN);
- 6) 与本文网络结构相同但未加入联合双边滤波的分类方法(Res-2DCNN);
- 7) 联合双边滤波和与本文网络结构相同但未加入残差结构的二维卷积神经网络结合的分类方法(JBF-2DCNN);
- 8) 本文提出的分类方法(JBF-Res-2DCNN)。

本文采用的评价指标包括总体分类精度(OA)、平均分类精度(AA)和Kappa系数。为提高实验的可靠性和精确度,每种实验条件下重复进行10次实验,将10次实验结果的平均值作为最终结果。

3.3 参数设置分析

影响本文方法的参数包括深度残差网络结构参数和空间特征提取时联合双边滤波中的参数,其中:深度残差网络结构参数有卷积核的数量、dropout概率值和网络迭代次数 epoch;联合双边滤波中的参数有邻域大小 η 、空域距离高斯函数的标准差 δ_c 和值域距离高斯函数的标准差 δ_s 。本文首先在 $\eta = 2$ 、 $\delta_c = 1$ 和 $\delta_s = 0.5$ 时分析深度残差网络结构参数对分类结果的影响,确定

最优网络结构后分析不同 η 、 δ_c 和 δ_s 的取值对分类结果的影响,从中选择最佳参数。随机在每类地物样本中选取50个样本(地物总数量不足50时,选取一半)作为训练样本,剩余样本作为测试样本。

1) 卷积核数量对分类结果的影响

本文网络结构中卷积核个数的设置参照了计算机视觉领域CNN设计的一般经验,即卷积层数越高则卷积核数量越多,例如在第一个卷积层中如果使用8个卷积核,则第二层采用16个卷积核。一个残差单元中所有的卷积层使用相同个数的卷积核以确保其维度一致。表2给出了不同数据集在 dropout=0.5 和 epoch=200 的情况下,第一个卷积层使用不同数量的卷积核对分类精度的影响。由表2可知,随着卷积核数量的增加分类精度会在某个数量的卷积核处达到最优,此后如果继续增加卷积核数量将会加剧网络泛化能力的退化,导致分类精度下降。对于 Indian Pines 数据集,当第一个卷积层卷积核数量为16时分类精度最优,OA为92.16%,Kappa系数为91.06%;对于 Pavia University 数据集,当第一个卷积层卷积核数量为32时分类精度最优,OA为93.53%,Kappa系数为92.98%。

表2 不同卷积核数量对应的分类精度

Table 2 Classification accuracy corresponding to different numbers of convolution kernels

Number of convolution kernels	Indian Pines		Pavia University	
	OA / %	Kappa / %	OA / %	Kappa / %
8	88.54	86.94	90.34	88.92
16	92.16	91.06	92.53	91.57
32	91.29	90.08	93.53	92.98
64	90.75	89.62	91.01	89.92

2) dropout 概率值对分类结果的影响

在网络训练中,dropout层通过随机丢弃一些神经元的参数值来防止模型过于依赖某些局部特征,在增强模型鲁棒性的同时避免过拟合现象的产生。图6给出了不同 dropout 取值对分类精度的影响。由图6可知:对于 Indian Pines 数据集,当 dropout 的值为0.65时分类精度最优,OA为94.51%,Kappa系数为93.75%;对于 Pavia University 数据集,当 dropout 的值为0.6时分类精度最优,OA为95.76%,Kappa系数为94.98%。

3) 迭代次数 epoch 对分类结果的影响

迭代次数能够影响网络模型的泛化能力。图7分别给出了在不同数据集中不同迭代次数 epoch 对应的训练集损失函数和测试集总体分类精度的变化关系。由图7可知:对于 Indian Pines 数据集,当 epoch 的值为200时分类精度达到最优,OA为94.57%;对于 Pavia University 数据集,当 epoch 的值为150时分类精度达到最优,OA为96.01%。

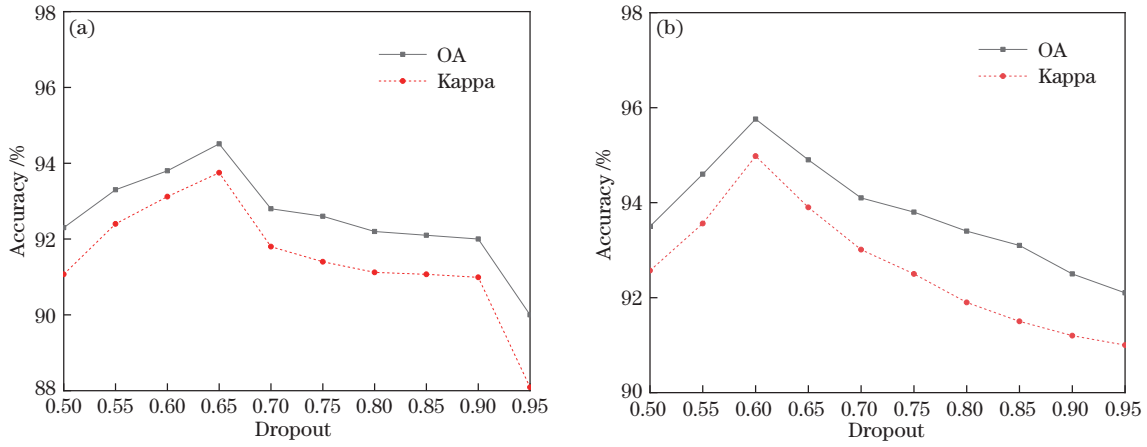


图 6 不同 dropout 值的分类精度。(a) Indian Pines; (b) Pavia University
 Fig. 6 Classification accuracy of different dropout values. (a) Indian Pines; (b) Pavia University

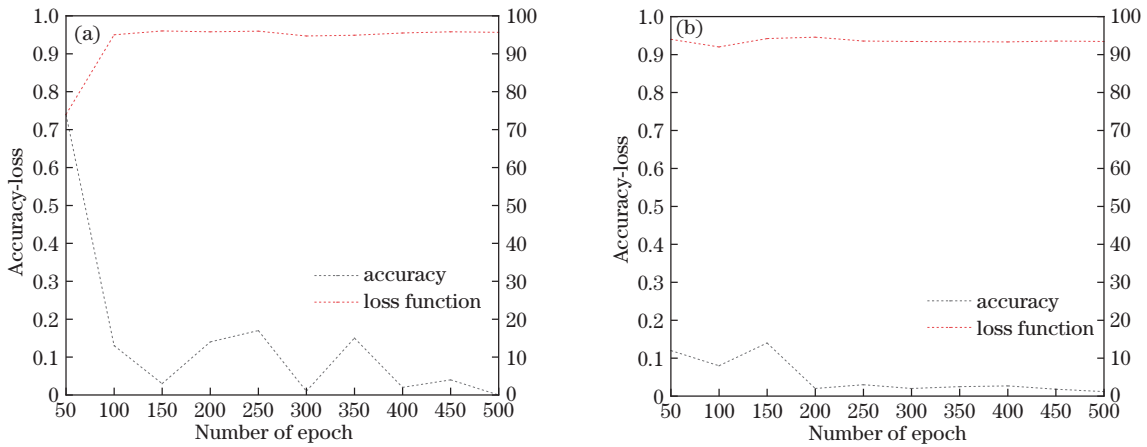


图 7 不同 epoch 值的损失函数与总体分类精度。(a) Indian Pines; (b) Pavia University
 Fig. 7 Loss function and overall classification accuracy of different epoch values. (a) Indian Pines; (b) Pavia University

4) 联合双边滤波中的参数对分类精度的影响

联合双边滤波中的参数能够决定高光谱影像的空间特征提取能力。图 8 给出了在 $\delta_c=1$ 和 $\delta_s=0.5$ 情况下不同窗口值 η 对分类精度的影响。由图 8 可知,分类精度随着窗口半径 η 的增加而不断提高,但是随着 η 的

增加空间信息达到饱和状态后出现了信息冗余,导致分类精度不再提高甚至有下降的趋势。对于 Indian Pines 数据集,当 $\eta=5$ 时分类精度最优,OA 为 95.12%, Kappa 系数为 94.62%; 对于 Pavia University 数据集,当 $\eta=4$ 时分类精度最优,OA 为 96.43%, Kappa 系数为

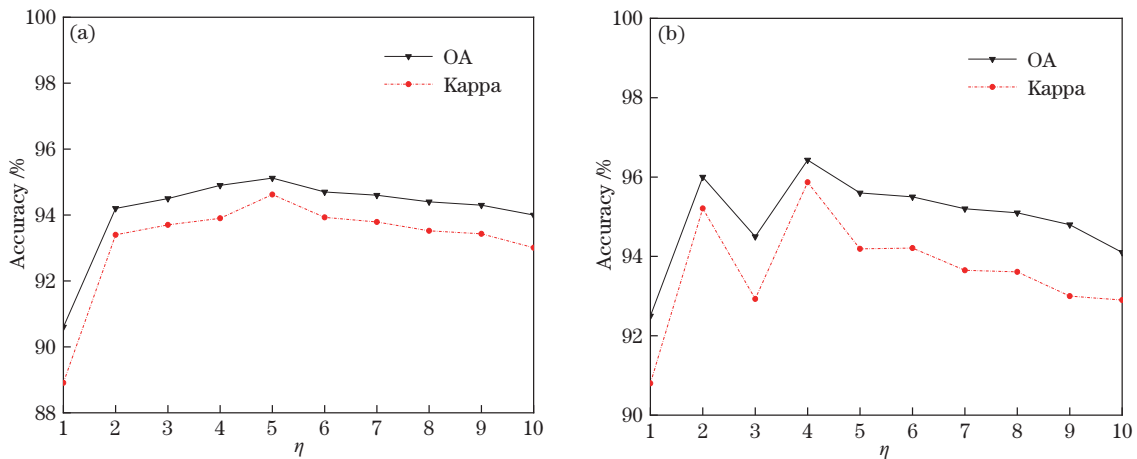


图 8 不同 η 值的分类精度。(a) Indian Pines; (b) Pavia University
 Fig. 8 Classification accuracy of different η values. (a) Indian Pines; (b) Pavia University

95.87%。图 9 分别给出了 Indian Pines 数据集和 Pavia University 数据集在 η 值为最优时不同 δ_c 和 δ_s 值对总体分类精度的影响。由图 9 可知:对于 Indian Pines 数据

集,当 $\delta_c=4$ 和 $\delta_s=0.6$ 时分类精度最优,OA 为 96.49%;对于 Pavia University 数据集,当 $\delta_c=3$ 和 $\delta_s=0.5$ 时分类精度最优,OA 为 97.83%。

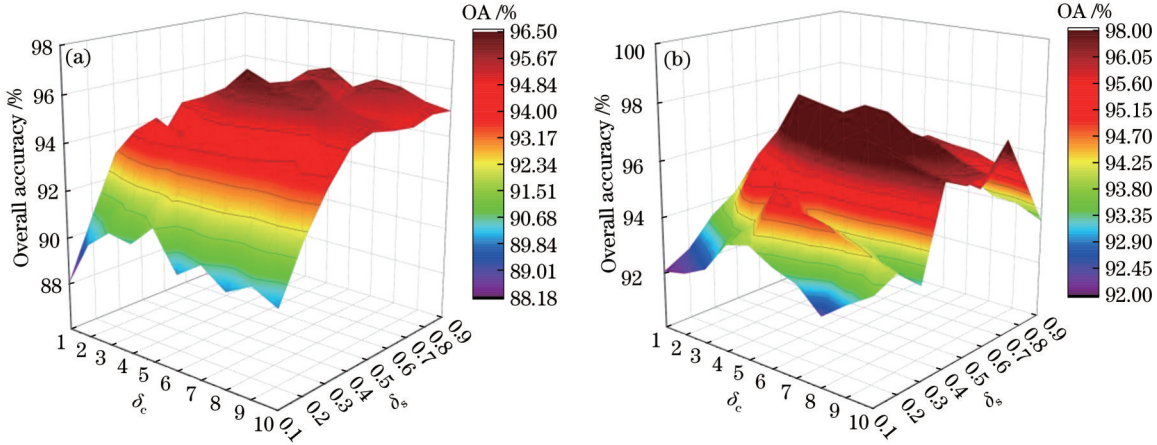


图 9 不同 δ_c 值和 δ_s 值的总体分类精度。(a) Indian Pines; (b) Pavia University

Fig. 9 Overall classification accuracy of different δ_c values and δ_s values. (a) Indian Pines; (b) Pavia University

3.4 Indian Pines 数据集的实验结果及评价

在每类地物样本中随机选取 10% 个样本作为训练样本,剩余样本作为测试样本。表 3 为实验中各方法对应的各类地物的分类精度、OA、AA 和 Kappa 系数。由表 3 可知, JBF-Res-2DCNN 相比 SP-SVM、2DCNN、Res-3DCNN、S2FEF-CNN、LBP-1DCNN、Res-2DCNN 和 JBF-2DCNN 方法的分类结果均有所

提高,OA 分别提高了约 17.31%、14.16%、6.09%、4.70%、3.04%、1.95% 和 1.25%,AA 分别提高了约 18.62%、12.01%、7.81%、8.63%、7.43%、5.1% 和 1.46%,Kappa 系数分别提高了约 19.81%、16.18%、6.94%、5.36%、3.46%、2.11% 和 1.43%,同时获取了 13 个最佳类别的地物分类精度。

表 3 不同算法在 Indian Pines 数据集的分类结果

Table 3 Classification results of different algorithms in the Indian Pines dataset

unit: %

Class	SP-SVM	2DCNN	Res-3DCNN	S2FEF-CNN	LBP-1DCNN	Res-2DCNN	JBF-2DCNN	JBF-Res-2DCNN
Alfalfa	60.86	81.81	71.42	82.60	88.37	100.00	97.43	100.00
Corn-notill	76.43	78.35	91.25	90.98	94.88	98.40	98.75	96.87
Corn-min	72.89	84.26	89.79	92.65	95.29	95.04	96.58	97.36
Corn	57.56	64.95	82.43	89.04	89.37	91.54	98.03	100.00
Grass/pasture	90.11	90.42	92.80	91.87	92.93	98.57	95.55	99.08
Grass/trees	87.84	94.94	93.40	98.94	99.24	96.60	99.84	100.00
Grass-mowed	87.50	100.00	88.00	77.41	75.00	90.00	96.00	100.00
Hay-windrowed	93.18	96.57	94.05	99.53	100.00	100.00	100.00	100.00
Oats	50.00	87.50	90.90	50.00	52.17	43.47	87.50	90.00
Soybeans-notill	75.08	79.77	88.53	91.06	93.20	93.87	96.50	98.06
Soybeans-min	78.52	81.88	94.96	94.57	96.76	97.47	96.39	99.77
Soybeans-clean	83.40	81.97	88.69	91.49	92.91	96.24	97.70	97.55
Wheat	97.29	94.32	100.00	100.00	100.00	100.00	100.00	100.00
Woods	93.11	93.37	98.57	99.29	99.11	98.94	99.38	99.91
Bldg-grass-drives	77.94	75.95	89.94	93.87	94.66	96.50	95.22	99.71
Stone-steel-towes	98.57	100.00	98.61	96.92	95.52	100.00	100.00	100.00
OA	81.56	84.71	92.78	94.17	95.83	96.92	97.62	98.87
AA	80.02	86.63	90.83	90.01	91.21	93.54	97.18	98.64
Kappa	78.90	82.53	91.77	93.35	95.25	96.60	97.28	98.71

图 10 给出了随机一次的分类结果图,以免耕大豆为例,图 11 给出了 Indian Pines 数据集分类结果图局部放大对比。从表 3 和图 10 可以看出:由于 SP-SVM 方法仅利用了光谱特征,分类结果图中出现严重的“椒盐现象”;2DCNN、Res-3DCNN、S2FEF-CNN、LBP-1DCNN、Res-2DCNN、JBF-2DCNN 和 JBF-Res-2DCNN 方法由于引入了影像的空间特征,地物分类效果有了明显提升,其中 2DCNN 分类精度最低,这是因为在小样本情况下,CNN 能够提取有利于影像地物分类的特征,但是网络层数过多可能会引起网络退化和梯度消失问题;Res-3DCNN 和 Res-2DCNN 对特征相近容易误分的地物类别提升效果明显,说明残差学习

可以很好地解决该问题,改善分类结果,其中 Res-2DCNN 噪点较少,说明本文提出的深度残差网络可以更好地提取影像深层特征,但在地物边缘处仍有一些错分结果;LBP-1DCNN、JBF-2DCNN 和 JBF-Res-2DCNN 采用不同的空间滤波技术对分类图的质量进行增强,有效地解决了网络过拟合的问题,提高了分类精度,其中 JBF-2DCNN 和 JBF-Res-2DCNN 的分类图中边界较清晰,这是因为联合双边滤波在对地物实现平滑的同时能够较好地保留边缘信息,增强了样本的多样性;JBF-Res-2DCNN 在提取高质量的空间特征基础上利用深度残差网络有效提升网络性能,较好地反映出地物的真实分布情况。

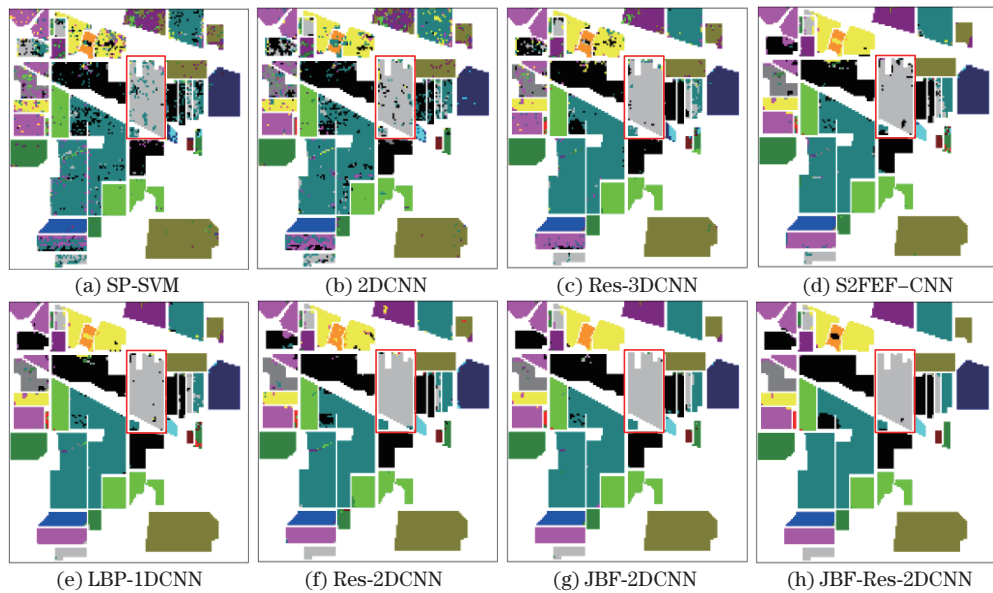


图 10 不同算法在 Indian Pines 数据集的分类结果图

Fig. 10 Classification results of different algorithms in Indian Pines dataset

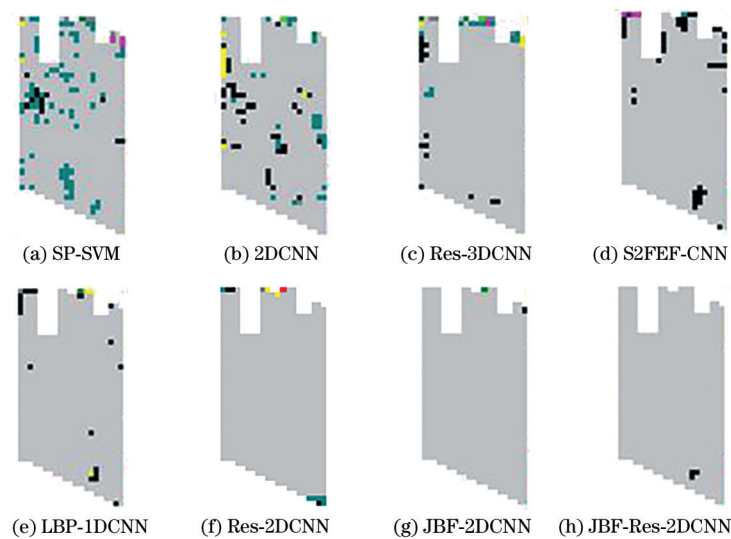


图 11 Indian Pines 数据集分类结果图局部放大对比

Fig. 11 Partial enlargement comparison of classification results of Indian Pines dataset

3.5 Pavia University 数据集的实验结果及评价

在每类地物样本中随机选取 3% 个样本作为训练样本, 剩余样本作为测试样本。表 4 为实验中各方法对应的各类地物分类精度、OA、AA 和 Kappa 系数。图 12 给出了随机一次的分类结果图, 以柏油路面为例, 图 13 给出了 Pavia University 数据集分类结果图的局部放大对比, 可以看出 JBF-Res-2DCNN 方法得到的分类结果图中噪声点更少, 地物分布更平滑。由表 4 可知, 在

Pavia University 数据集上 JBF-Res-2DCNN 相比其他 7 种方法, OA 分别提高了约 10.77%、8.49%、6.07%、3.50%、2.57%、2.21% 和 1.09%, AA 分别提高了约 8.03%、7.39%、7.13%、4.08%、3.42%、2.88% 和 1.58%, Kappa 系数分别提高了约 14.60%、11.44%、8.12%、4.65%、3.40%、2.65% 和 1.44%, 同时在 9 种地物中有 8 种地物的分类精度为所有方法中的最高值, 进一步说明本文方法的有效性。

表 4 不同算法在 Pavia University 数据集的分类结果
Table 4 Classification results of different algorithms in Pavia University dataset unit: %

Class	SP-SVM	2DCNN	Res-3DCNN	S2FEF-CNN	LBP-1DCNN	Res-2DCNN	JBF-2DCNN	JBF-Res-2DCNN
Asphalt	81.44	89.37	93.31	95.09	96.08	97.95	98.20	99.38
Meadows	90.26	91.67	95.12	97.83	99.23	98.36	99.78	99.92
Gravel	82.63	83.31	80.16	93.27	94.96	91.80	92.18	96.32
Trees	95.65	96.74	99.91	99.24	97.74	98.18	96.78	99.45
Painted metalsheets	99.15	99.15	91.76	99.23	100.00	97.09	100.00	98.02
Bare soil	94.11	94.23	95.08	97.74	97.41	95.74	99.59	100.00
Bitumen	94.77	87.69	83.94	83.96	85.22	98.73	95.30	98.84
Self-blocking bricks	79.26	80.90	86.07	86.52	88.15	90.23	93.54	97.67
Shadows	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00
OA	88.58	90.86	93.28	95.85	96.78	97.14	98.26	99.35
AA	90.81	91.45	91.71	94.76	95.42	95.96	97.26	98.84
Kappa	84.53	87.69	91.01	94.48	95.73	96.48	97.69	99.13




图 12 不同算法在 Pavia University 数据集的分类结果图
Fig. 12 Classification results of different algorithms in Pavia University dataset




图 13 Pavia University 数据集分类结果图局部放大对比

Fig. 13 Partial enlargement comparison of classification results of Pavia University dataset

3.6 运行性能分析

为了综合比较所提出的 JBF-Res-2DCNN 方法与 SP-SVM、Res-3DCNN、S2FEF-CNN 和 LBP-1DCNN 方法的效率,本文使用 Python 和 Matlab 混合编程,实验的计算平台配置为 Intel Core i7-7700K、NVIDIA GeForce GTX 1070、32 GB 内存。表 5 给出了不同方法在 Indian Pines 和 Pavia University 两个数据集集中的训练时间与测试时间,其训练样本和测试样本数量的选取参照 3.4 和 3.5 节。由表 5 可知,相比于其他四种分类方法,本文方

法精度有明显提高。在效率方面:本文方法相比于 Res-3DCNN 和 S2FEF-CNN 方法训练测试时间短且分类效率更高;相比于仅利用原始光谱特征的 SP-SVM 方法处理时间长,这是因为本文提取的特征数量比原始图像的特征数量大;相比于浅层卷积网络 LBP-1DCNN 处理时间较长,这是因为本文设计的深度残差网络在特征提取和分类时计算量远大于浅层卷积网络,且分类精度也较 LBP-1DCNN 有明显提升。因此,从分类精度和分类效率综合比较本文方法优于另外四种方法。

表 5 不同算法的训练时间和测试时间

Table 5 Training time and test time of different algorithms

Dataset	Parameter	Algorithm				
		SP-SVM	Res-3DCNN	S2FEF-CNN	LBP-1DCNN	JBF-Res-2DCNN
Indian Pines	Training time	18.64	1507.28	1430.21	890.49	1293.52
	Test time	0.75	5.06	3.91	2.78	3.04
Pavia University	Training time	10.31	1002.79	921.52	629.46	862.95
	Test time	1.42	8.35	7.28	5.05	5.93

4 结 论

本文提出了一种适用于高光谱影像分类的 JBF-Res-2DCNN 方法。该方法利用联合双边滤波可以在顾及边缘信息的基础上充分提取影像的深层特征,然后在网络中利用深度残差网络对高光谱影像进行分类。在 Indian Pines 数据集和 Pavia University 数据集上执行实验,将本文方法与其他 7 种对比方法进行比较,结果表明:1)在训练样本较少的情况下,本文方法采用联合双边滤波在增强影像边缘结构的基础上充分提取影像的深层特征,增强样本的多样性,缓解了 CNN 分类中的过拟合问题;2)本文方法所构建的深度残差网络能够较好地解决深层网络在影像分类时的网络退化和梯度消失问题,因此,本文方法能够有效改善

高光谱影像整体分类效果。

虽然本文 JBF-Res-2DCNN 方法可以有效地改善高光谱影像的分类精度,但是由于联合双边滤波涉及到的参数较多,需要通过手动调节滤波参数进行优化,因此在未来的研究工作中将考虑如何把自适应算法结合到联合双边滤波中以获得更好的分类性能。

参 考 文 献

- [1] 李非燕, 霍宏涛, 白杰, 等. 基于稀疏表示和自适应模型的高光谱目标检测[J]. 光学学报, 2018, 38(12): 1228004.
Li F Y, Huo H T, Bai J, et al. Hyperspectral target detection based on sparse representation and adaptive model[J]. Acta Optica Sinica, 2018, 38(12): 1228004.
- [2] Wei L F, Yu M, Liang Y J, et al. Precise crop

- classification using spectral-spatial-location fusion based on conditional random fields for UAV-borne hyperspectral remote sensing imagery[J]. *Remote Sensing*, 2019, 11(17): 2011.
- [3] Ellison E T, Mayhew L E, Miller H M, et al. Quantitative microscale Fe redox imaging by multiple energy X-ray fluorescence mapping at the Fe K pre-edge peak[J]. *American Mineralogist*, 2020, 105(12): 1812-1829.
- [4] 刘嘉敏, 郑超, 张丽梅, 等. 基于图像重构特征融合的高光谱图像分类方法[J]. *中国激光*, 2021, 48(9): 0910001.
Liu J M, Zheng C, Zhang L M, et al. Hyperspectral image classification method based on image reconstruction feature fusion[J]. *Chinese Journal of Lasers*, 2021, 48(9): 0910001.
- [5] 李丹, 孔繁镨, 朱德燕. 基于局部高斯混合特征提取的高光谱图像分类[J]. *光学学报*, 2021, 41(6): 0610001.
Li D, Kong F Q, Zhu D Y. Hyperspectral image classification based on local Gaussian mixture feature extraction[J]. *Acta Optica Sinica*, 2021, 41(6): 0610001.
- [6] Lahlimi M, Morocco I T U K. Band selection by divergence distance based on Gaussian mixture model for hyperspectral image classification[J]. *International Journal of Advanced Trends in Computer Science and Engineering*, 2019, 8(5): 2330-2338.
- [7] Ghule A N, Deshmukh R R. Wavelength selection and classification of hyperspectral non-imagery data to discriminate healthy and unhealthy vegetable leaves[J]. *Current Science*, 2021, 120(5): 936-941.
- [8] Zhang Y S, Ma Y, Dai X B, et al. Locality-constrained sparse representation for hyperspectral image classification[J]. *Information Sciences*, 2021, 546: 858-870.
- [9] Zhao G X, Wang X S, Cheng Y H. Hyperspectral image classification based on local binary pattern and broad learning system[J]. *International Journal of Remote Sensing*, 2020, 41(24): 9393-9417.
- [10] Zhang T, Zhang P Z, Zhong W L, et al. JL-GFDN: a novel Gabor filter-based deep network using joint spectral-spatial local binary pattern for hyperspectral image classification[J]. *Remote Sensing*, 2020, 12(12): 2016.
- [11] Soomro B N, Xiao L, Jawaid M M, et al. A bilateral filter based post-processing approach for supervised spectral-spatial hyperspectral image classification[J]. *Mehran University Research Journal of Engineering and Technology*, 2018, 37(3): 615-630.
- [12] 陈志坤, 江俊君, 姜鑫维, 等. 一种基于改进双边滤波的鲁棒高光谱遥感图像特征提取方法[J]. *武汉大学学报·信息科学版*, 2020, 45(4): 504-510.
Chen Z K, Jiang J J, Jiang X W, et al. Robust hyperspectral image feature extraction based on improved bilateral filtering[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(4): 504-510.
- [13] Qiao T, Yang Z J, Ren J C, et al. Joint bilateral filtering and spectral similarity-based sparse representation: a generic framework for effective feature extraction and data classification in hyperspectral imaging[J]. *Pattern Recognition*, 2018, 77: 316-328.
- [14] 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.
- [15] 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.
- [16] Mou L C, Ghamisi P, Zhu X X. Deep recurrent neural networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(7): 3639-3655.
- [17] Mughees A, Tao L M. Multiple deep-belief-network-based spectral-spatial classification of hyperspectral images[J]. *Tsinghua Science and Technology*, 2018, 24(2): 183-194.
- [18] Liu X F, Sun Q Q, Meng Y, et al. Feature extraction and classification of hyperspectral image based on 3D-convolution neural network[C]//2018 IEEE 7th Data Driven Control and Learning Systems Conference, May 25-27, 2018, Enshi, China. New York: IEEE Press, 2018: 918-922.
- [19] Ahmad M, Shabbir S, Raza R A, et al. Hyperspectral image classification: artifacts of dimension reduction on hybrid CNN[EB/OL]. (2021-01-25)[2021-06-03]. <https://arxiv.org/abs/2101.10532>.
- [20] Wang Y H, Liang B X, Ding M, et al. Dual-branch dense residual network for hyperspectral imagery classification[J]. *International Journal of Remote Sensing*, 2020, 41(7): 2581-2602.
- [21] Fowler J E. Compressive-projection principal component analysis[J]. *IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society*, 2009, 18(10): 2230-2242.
- [22] Liu B, Yu X C, Zhang P Q, et al. A semi-supervised convolutional neural network for hyperspectral image classification[J]. *Remote Sensing Letters*, 2017, 8(9): 839-848.
- [23] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA. New York: IEEE Press, 2015: 1552-1560.
- [24] 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.
- [25] 颜铭靖, 苏喜友. 基于三维空洞卷积残差神经网络的高光谱影像分类方法[J]. *光学学报*, 2020, 40(16): 1628002.
Yan M J, Su X Y. Hyperspectral image classification based on three-dimensional dilated convolutional residual neural network[J]. *Acta Optica Sinica*, 2020, 40(16):

- 1628002.
- [26] 刘冰, 余旭初, 张鹏强, 等. 联合空-谱信息的高光谱影像深度三维卷积网络分类[J]. 测绘学报, 2019, 48(1): 53-63.
Liu B, Yu X C, Zhang P Q, et al. Deep 3D convolutional network combined with spatial-spectral features for hyperspectral image classification[J]. Acta Geodaetica et Cartographica Sinica, 2019, 48(1): 53-63.
- [27] Chen L L, Wei Z H, Xu Y. A lightweight spectral-spatial feature extraction and fusion network for hyperspectral image classification[J]. Remote Sensing, 2020, 12(9): 1395.
- [28] 魏祥坡, 余旭初, 张鹏强, 等. 联合局部二值模式的 CNN 高光谱图像分类[J]. 遥感学报, 2020, 24(8): 1000-1009.
Wei X P, Yu X C, Zhang P Q, et al. CNN with local binary patterns for hyperspectral images classification[J]. Journal of Remote Sensing, 2020, 24(8): 1000-1009.