



(12) 发明专利申请

(10) 申请公布号 CN 113963182 A

(43) 申请公布日 2022. 01. 21

(21) 申请号 202111230835.2

G06K 9/62 (2022.01)

(22) 申请日 2021.10.22

G06N 3/04 (2006.01)

(71) 申请人 河海大学

地址 211100 江苏省南京市江宁开发区佛城西路8号

(72) 发明人 杨琪

(74) 专利代理机构 北京百年育人知识产权代理有限公司 11968

代理人 张鹭丝

(51) Int. Cl.

G06V 10/58 (2022.01)

G06V 10/77 (2022.01)

G06V 10/774 (2022.01)

G06V 10/776 (2022.01)

G06V 20/00 (2022.01)

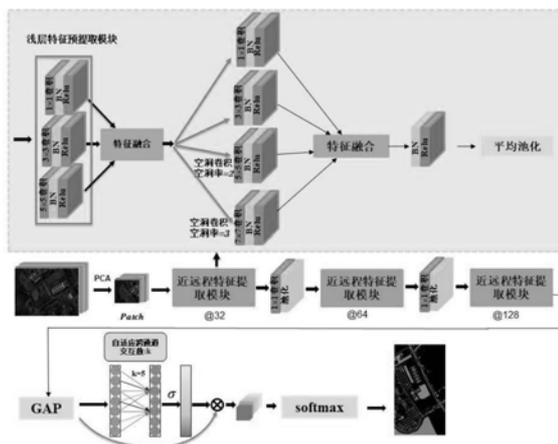
权利要求书1页 说明书9页 附图3页

(54) 发明名称

基于多尺度空洞卷积注意力网络的高光谱影像分类方法

(57) 摘要

本发明公开了一种基于多尺度空洞卷积注意力网络的高光谱影像分类方法,可以高效提取高光谱影像的特征,显著提高地物分类的精度。且分类性能较传统的2D-CNN与3D-CNN等模型相比,在遥感影像分类上有明显的优势。传统的高光谱图像分类算法(如2D-CNN、3D-CNN等)不能充分利用光谱-空间的有效信息,反而在提取特征时误用干扰冗余信息,而基于多尺度空洞卷积注意力网络模型,通过引入浅层特征预提取模块、多尺度滤波器、空洞卷积和注意力模块,可以获取更丰富的空间-光谱判别特征,且将特征图的注意力集中在那些包含大量有用信息的特征上,为高层次特征提供更好的像素级注意,极大提高了模型的分类精度。



1. 基于多尺度空洞卷积注意力网络的高光谱影像分类方法, 其特征在于: 包括以下步骤:

S1: 采用PCA技术对高光谱影像的光谱维进行降维处理, 将实验中的原始数据集的光谱维使用PCA方法压缩至3维, 在保留有效光谱信息的基础上大大减少数据量, 从而达到减少训练时间的目的, 之后将已降维数据进行标准差归一化处理, 如公式(1)所示

$$x' = \frac{x - \mu}{\sigma} \quad (1)$$

其中 x' 为进行标准差归一化后输出值, x 为降维后的输入数据值, μ 为数据集样本均值, σ 为标准差;

S2: 将上述标准差归一化后的数据作为待分类像元, 而后以待分类像元为中心, 提取出相应尺寸的待分类图像块(Patch), 这些图像块将会被输送到多尺度空洞卷积注意力网络模型中, 此模型在传统多尺度CNN模型基础上进行了改进, 它包含近远程特征提取模块及通道注意力模块, 具体模型架构如图1所示, 近-远程特征提取模块包含浅层特征预提取模块和多尺度特征提取模块, 如图2所示, 其中浅层特征提取模块为卷积核大小为 $1 \times 1, 3 \times 3, 5 \times 5$ 的集合, 且每个卷积层都配置了批量归一化层(BN, BatchNormalization)和激活函数ReLU做加速训练和非线性化处理, 在兼顾运算量与分类精度的前提下, 多尺度特征提取模块选取堆叠4个尺寸不同滤波器来获得图像丰富的深层特征信息, 其中图像的近程特征信息通过卷积核大小为 1×1 和 3×3 的普通卷积捕获, 图像的远程特征信息由卷积核大小为 5×5 (空洞率为2)和 7×7 (空洞率为3)获取, 最后通过特征融合的方式来获得图像丰富的特征信息, 近-远程特征提取模块充分利用了各级卷积层提取的特征图, 最大程度上避免有效信息的丢失, 加入空洞卷积降低了训练参数, 使得整体模型更加轻量化, 本方法将3个近-远程特征提取模块的卷积核数目依次设置为32, 64, 128, 借鉴DenseNet中transition layer的思想, 在相邻特征图之间加入 1×1 卷积层进行特征提取层之间的连接, 在保证特征信息完整传输的同时大大减少了网络的运算量, 1×1 卷积层之后添加卷积核尺寸为 2×2 的平均池化层抑制过拟合现象, 并维持较低的训练参数, 最后将最后一个近远程特征提取模块得到的特征图输入到通道注意力模块中来重构特征信息, 使特征图中每个像素点的特征信息更具判别力;

S3: 进行模型的训练, 将训练样本输入到上述模型中, 本方法训练过程中使用dropout方法随机隐藏全连接层中的部分神经元(隐藏概率为0.5), 该方法可以有效地抑制过拟合现象, 一定程度上实现了正则化, 增加了对激活函数输出数据的掌控力;

S4: 待多尺度空洞卷积注意力网络经过样本训练之后, 将测试样本输入到网络中进行测试样本的分类, 本方法中每个卷积层之后均添加BN层和Relu激活函数, 并通过Softmax分类器产生最终标签, 模型选用交叉熵作为损失函数, 使用SGD with momentum优化算法, 确保损失迅速收敛至全局最小。

基于多尺度空洞卷积注意力网络的高光谱影像分类方法

技术领域

[0001] 本发明涉及高光谱遥感影像分类领域,特别是涉及基于多尺度空洞卷积注意力网络的遥感影像分割算法。

背景技术

[0002] 近年来,深度学习研究受到了众多学者的重视。深度学习是机器学习的一个领域,随着计算机计算能力的提高、相对更加优化的算法提出与可用数据量的增加,深度学习领域内多种方法的性能得到了很大的提升,在很多领域得到了广泛应用。同时,深度学习在图像分类、图像分割等计算机视觉任务中表现出更高的有效性和更强的鲁棒性,在高光谱遥感图像分类领域也引起研究浪潮。堆叠式自动编码器(SAEs),深度信念网络(DBNs),卷积神经网络(CNNs),递归神经网络(RNNs),andGANs逐渐应用于HSIC领域。

[0003] 卷积神经网络(CNNs)可以利用空间像素点及其邻域的信息,能有效地从原始数据中提取特征并进行高级抽象以实现优良的分类结果,因此多个基于2D-CNN的高光谱分类算法被提出用来处理HSIC任务,这些算法通过提高HSI空间信息利用率使分类性能得到提高。然而当2D-CNN网络深度增加时,网络面临退化问题,这对分类结果造成了一定的影响。因此结构更加优化更深层的卷积神经网络模型ResNet、DenseNets被提出,这些网络可以有效缓解过拟合现象引起图像分类领域的广泛关注,成为目前HSI分类领域研究应用较为广泛的几个模型。Song等人研究了基于残差学习的2D-CNN特征融合,为高光谱数据分类任务建立了一个更具鉴别能力的网络。然而,2D-CNN网络在完成高光谱遥感影像分类任务问题上存在丢失有效光谱信息的问题,这甚至可能在某些复杂场景下影响分类性能,因此研究者试图将3D-CNN网络应用于HSIC任务中。Zilong Zhong等人提出的SSRN算法将残差网络与3-D CNN结合,对HSI图像不做任何预处理直接输入SSRN中同时提取空-光谱特征进行分类任务,可以达到了很好的分类效果,但该方法设计的网络不仅计算量大,而且其对于HSI图像的光谱特征信息进行了一致的处理。Mou等人提出了一种基于残差学习的完全conv-deconv网络,旨在实现端到端的无监督光谱空间特征学习。除过拟合问题之外,HSIC还面临标记样本不足的问题。无论是2D-CNN还是3D-CNN,基本的CNN模型在探索光谱-空间域的HSI时往往直接找到模式的内在表征,而卷积层处理的特征可能包含许多无用或干扰的信息,如果这些无用的特征不经过任何处理直接发送到下一层,随着网络的不断深入,网络的学习效率会降低,最终会影响分类性能。因此,如何对卷积层后的特征图进行处理,并将注意力集中在那些包含大量有用信息的特征上,是HSI分类任务的另一个关键。

发明内容

[0004] 发明目的:本发明的目的是提供一种能够解决现有技术中存在的缺陷的基于多尺度空洞卷积注意力网络的高光谱影像分类方法。

[0005] 技术方案:本发明所述的基于多尺度空洞卷积注意力网络的高光谱影像分类方法,包括以下步骤:

[0006] S1:采用PCA技术对高光谱影像的光谱维进行降维处理,将实验中的原始数据集的光谱维使用PCA方法压缩至3维,在保留有效光谱信息的基础上大大减少数据量,从而达到减少训练时间的目的。之后将已降维数据进行标准差归一化处理。如公式(1)所示

$$[0007] \quad x' = \frac{x-\mu}{\sigma} \quad (1)$$

[0008] 其中 x' 为进行标准差归一化后输出值, x 为降维后的输入数据值, μ 为数据集样本均值, σ 为标准差。

[0009] S2:将上述标准差归一化后的数据作为待分类像元,而后以待分类像元为中心,提取出相应尺寸的待分类图像块(Patch)。这些图像块将会被输送到多尺度空洞卷积注意力网络模型中,此模型在传统多尺度CNN模型基础上进行了改进。它包含近远程特征提取模块及通道注意力模块。具体模型架构如图1所示。近-远程特征提取模块包含浅层特征预提取模块和多尺度特征提取模块,如图2所示。其中浅层特征提取模块为卷积核大小为 $1 \times 1, 3 \times 3, 5 \times 5$ 的集合,且每个卷积层都配置了批量归一化层(BN, Batch Normalization)和激活函数ReLU做加速训练和非线性化处理。在兼顾运算量与分类精度的前提下,多尺度特征提取模块选取堆叠4个尺寸不同滤波器来获得图像丰富的深层特征信息。其中图像的近程特征信息通过卷积核大小为 1×1 和 3×3 的普通卷积捕获,图像的远程特征信息由卷积核大小为 5×5 (空洞率为2)和 7×7 (空洞率为3)获取,最后通过特征融合的方式来获得图像丰富的特征信息。近-远程特征提取模块充分利用了各级卷积层提取的特征图,最大程度上避免有效信息的丢失,加入空洞卷积降低了训练参数,使得整体模型更加轻量化。本方法将3个近-远程特征提取模块的卷积核数目依次设置为32,64,128,借鉴DenseNet中transition layer的思想,在相邻特征图之间加入 1×1 卷积层进行特征提取层之间的连接,在保证特征信息完整传输的同时大大减少了网络的运算量。 1×1 卷积层之后添加卷积核尺寸为 2×2 的平均池化层抑制过拟合现象,并维持较低的训练参数。最后将最后一个近远程特征提取模块得到的特征图输入到通道注意力模块中来重构特征信息,使特征图中每个像素点的特征信息更具判别力。

[0010] S3:进行模型的训练,将训练样本输入到上述模型中。本方法训练过程中使用dropout方法随机隐藏全连接层中的部分神经元(隐藏概率为0.5),该方法可以有效地抑制过拟合现象,一定程度上实现了正则化,增加了对激活函数输出数据的掌控力。

[0011] S4:待多尺度空洞卷积注意力网络经过样本训练之后,将测试样本输入到网络中进行测试样本的分类。本方法中每个卷积层之后均添加BN层和Relu激活函数,并通过Softmax分类器产生最终标签。模型选用交叉熵作为损失函数,使用SGD with momentum优化算法,确保损失迅速收敛至全局最小。

[0012] 有益效果:

[0013] 有效地降低特征维数,通过自适应地增强对分类任务提供有用特征信息的作用,提取到丰富且有效的特征信息,在小样本情况下分类性能更为出色,且就模型的分分类能力和分类精度较传统的2D-CNN、3D-CNN模型相比,有明显优势。

附图说明

[0014] 图1为多尺度空洞卷积注意力网络(PMACNN)架构;

[0015] 图2为近-远程特征提取模块示意图;

[0016] 图3为设置不同初始学习率(lr)下的三个数据集分类结果示意图;

[0017] 图4为设置不同Patch大小下的三个数据集分类结果示意图;

[0018] 图5中,5a为Indian数据集地物灰度图;5b为SVM对Indian Pines数据集的分类结果图;5c为2D-CNN对Indian Pines数据集的分类结果图;5d为3D-CNN对Indian Pines数据集的分类结果图;5e为HybridSN对Indian Pines数据集的分类结果图;5f为RSSAN对Indian Pines数据集的分类结果图;5g为PMACNN对Indian Pines数据集的分类结果图;

[0019] 图6中,6a为Pavia University数据集地物灰度图;6b为SVM对Pavia University数据集的分类结果图;6c为2D-CNN对Pavia University数据集的分类结果图;6d为3D-CNN对Pavia University数据集的分类结果图;6e为HybridSN对Pavia University数据集的分类结果图;6f为RSSAN对Pavia University数据集的分类结果图;6g为PMACNN对Pavia University数据集的分类结果图;

[0020] 图7中,7a为Salinas数据集地物灰度图;7b为SVM对Salinas数据集的分类结果图;7c为2D-CNN对Salinas数据集的分类结果图;7d为3D-CNN对Salinas数据集的分类结果图;7e为HybridSN对Salinas数据集的分类结果图;7f为RSSAN对Salinas数据集的分类结果图;7g为PMACNN对Salinas数据集的分类结果图;

[0021] 图8中,8a为Indian Pines数据集下不同训练样本数量对分类结果的影响图;8b为University数据集下不同训练样本数量对分类结果的影响图;8c为Salinas数据集下不同训练样本数量对分类结果的影响图;

具体实施方式

[0022] 下面结合具体实施方式和附图,对本发明的技术方案作进一步的介绍。

[0023] 本具体实施方式公开了一种基于多尺度空洞卷积注意力网络的高光谱影像分类方法,如图1所示,包括以下步骤:

[0024] S1:采用PCA技术对高光谱影像的光谱维进行降维处理,将实验中的原始数据集的光谱维使用PCA方法压缩至3维,在保留有效光谱信息的基础上大大减少数据量,从而达到减少训练时间的目的。之后将已降维数据进行标准差归一化处理。如公式(1)所示

$$[0025] \quad x' = \frac{x-\mu}{\sigma} \quad (1)$$

[0026] 其中 x' 为进行标准差归一化后输出值, x 为降维后的输入数据值, μ 为数据集样本均值, σ 为标准差。

[0027] S2:将上述标准差归一化后的数据作为待分类像元,而后以待分类像元为中心,提取出相应尺寸的待分类图像块(Patch)。这些图像块将会被输送到多尺度空洞卷积注意力网络模型中,此模型在传统多尺度CNN模型基础上进行了改进。它包含近远程特征提取模块及通道注意力模块。具体模型架构如图1所示。近-远程特征提取模块包含浅层特征预提取模块和多尺度特征提取模块,如图2所示。其中浅层特征提取模块为卷积核大小为 $1 \times 1, 3 \times 3, 5 \times 5$ 的集合,且每个卷积层都配置了批量归一化层(BN, Batch Normalization)和激活函数ReLU做加速训练和非线性化处理。在兼顾运算量与分类精度的前提下,多尺度特征提取模块选取堆叠4个尺寸不同滤波器来获得图像丰富的深层特征信息。其中图像的近程特征信息通过卷积核大小为 1×1 和 3×3 的普通卷积捕获,图像的远程特征信息由卷积核大小为

5×5(空洞率为2)和7×7(空洞率为3)获取,最后通过特征融合的方式来获得图像丰富的特征信息。近-远程特征提取模块充分利用了各级卷积层提取的特征图,最大程度上避免有效信息的丢失,加入空洞卷积降低了训练参数,使得整体模型更加轻量化。本方法将3个近-远程特征提取模块的卷积核数目依次设置为32,64,128,借鉴DenseNet中transition layer的思想,在相邻特征图之间加入1×1卷积层进行特征提取层之间的连接,在保证特征信息完整传输的同时大大减少了网络的运算量。1×1卷积层之后添加卷积核尺寸为2×2的平均池化层抑制过拟合现象,并维持较低的训练参数。最后将最后一个近远程特征提取模块得到的特征图输入到通道注意力模块中来重构特征信息,使特征图中每个像素点的特征信息更具判别力。

[0028] S3:进行模型的训练,将训练样本输入到上述模型中。本方法训练过程中使用dropout方法随机隐藏全连接层中的部分神经元(隐藏概率为0.5),该方法可以有效地抑制过拟合现象,一定程度上实现了正则化,增加了对激活函数输出数据的掌控力。

[0029] S4:待多尺度空洞卷积注意力网络经过样本训练之后,将测试样本输入到网络中进行测试样本的分类。本方法中每个卷积层之后均添加BN层和Relu激活函数,并通过Softmax分类器产生最终标签。模型选用交叉熵作为损失函数,使用SGD with momentum优化算法,确保损失迅速收敛至全局最小。

[0030] 下面对实验仿真过程和结果进行介绍。

[0031] 1、实验图像

[0032] 实验所需的高光谱遥感影像选用Indian Pines、Pavia University、Salinas三种数据集。实验的测试环境是Intel Core i5-7200U CPU、64-bit Windows 10操作系统、GPU时Tesla T4。使用的仿真实验工具是于Keras的深度学习框架,Python版本号为3.6.6。

[0033] 2、实验过程

[0034] 实验中,选择使用Indian Pines(IN)、Pavia University(PU)、Salinas(SA)三种数据集。表1为三种数据集的基本信息。

[0035] 表1数据集特征

	数据集	尺寸	光谱带(原)	类别数	捕获仪器
[0036]	Indian Pines	145×145	200(224)	16	AVIRIS
	Pavia University	610×340	102(115)	9	ROSIS
	Salinas	512×217	204(224)	16	AVIRIS

[0037] 表2-1,2-2,2-3分别为各数据集的训练样本与测试样本的数目,对于Indian Pines数据集,我们从总样本中选取10%为训练样本,90%为测试样本。对于Pavia University和Salinas数据集,我们从总样本中选取5%为训练样本,95%为测试样本。

[0038] 表2-1 Indian Pines数据集的训练集与测试集数量

	类别名称	训练集	测试集	总样本数
	1 Alfalfa	5	41	46
	2 Corn-notill	143	1285	1428
	3 Corn-mitill	83	747	830
	4 Corn	24	213	237
	5 Grass-pasture	48	435	483
	6 Grass-trees	73	657	730
	7 Grass-pasture-mowed	3	25	28
	8 Hay-windrowed	48	430	478
[0039]	9 Oats	4	16	20
	10 Soybean-notill	97	875	972
	11 Soybean-mintill	245	2210	2455
	12 Soybean-clean	59	534	593
	13 Wheat	21	184	205
	14 Woods	126	1139	1265
	15 Buildings-Grass-Trees- Drives	39	347	386
	16 Stone-Steel-Towers	9	84	93
	# Total	1027	9222	10249

[0040] 表2-2 University of Pavia数据集的训练集与测试集数量

	类别名称	训练集	测试集	总样本数
	1 Asphalt	332	6299	6631
	2 Meadows	932	17717	18649
	3 Gravel	105	1994	2099
	4 Trees	153	2911	3064
	5 Painted metal sheets	67	1278	1345
[0041]	6 Bare Soil	251	4778	5029
	7 Bitumen	66	1264	1330
	8 Self-Blocking Bricks	184	3498	3682
	9 Shadows	47	900	947
	# Total	2137	40639	42776

[0042] 表2-3 Salinas数据集的训练集与测试集数量

	类别名称	训练集	测试集	总样本数
	1 Brocoli_green_weeds_1	100	1909	2009
	2 Brocoli_green_weeds_2	186	3090	3726
	3 Fallow	99	1877	1976
	4 Fallow_rough_plow	70	1324	1394
	5 Fallow_smooth	134	2544	2678
	6 Stubble	198	3761	3959
	7 Celery	179	3400	3579
	8 Grapes_untrained	564	10707	11271
[0043]	9 Soil_vinyard_develop	310	5893	6203
	10 Corn_senesced_green_weeds	164	3114	3278
	11 Lettuce_romaine_4wk	53	1015	1068
	12 Lettuce_romaine_5wk	96	1831	1927
	13 Lettuce_romaine_6wk	46	870	916
	14 Lettuce_romaine_7wk	53	1017	1070
	15 Vinyard_untrained	363	6905	7268
	16 Vinyard_vertical_trellis	90	1717	1807
	# Total	2705	51424	54129

[0044] 在实验参数选择上,分析了几个影响网络训练及最终分类性能的几个因素,包括学习率的设置、Patch大小的选择和训练数据集的数量。首先,设置初始学习率分别为{0.01,0.03,0.001,0.003,0.0001,0.0003}来进行实验,实验结果如图3所示,可见初始学习率 $lr=0.01$ 时分类效果最好,因此本文中选择 $lr=0.01$ 完成在三个数据集上的实验。之后,选择Patch大小分别为5,11,17,21,25来进行实验,实验结果如图4所示,可以发现,随着Patch尺寸的增加,三幅高光谱图像数据集的整体分类精度均逐步增加再减少,Patch大小为25时分类效果最好,因此后续在三个数据集的实验中选择输入图像的大小Patch=25来进行对比实验。

[0045] 为了突出本方法的先进性,我们将与其他四种典型方法在定量分类结果进行对比。四种典型方法分别为支持向量机(SVM)、2-D CNN(为证明本文所设计网络的优越性,此2-D CNN网络结构除未添加通道注意力模块外其他设置与PMACNN网络相同)、3D-CNN、HybridSN、RSSAN。为了保证对比试验的准确性,2-D CNN,3D-CNN,HybridSN和RSSAN的输入Patch尺寸及参数选取均与所提多尺度空洞卷积注意力网络(PMACNN)保持相同。其余设置均参考上述相关资料进行设置。在三幅高光谱图像中,我们均测试了在训练样本大小固定的情况下,各类方法的性能。

[0046] 在Indian Pines的比较实验中,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5展示了6种方法的分类图以及地物灰度图(GT,ground truth),图5中清晰地显示SVM的分类图效果最差,且存在大量噪音,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,可以发现,PMACNN,RSSAN,3D-CNN,2D-CNN等深度学习算法的分类性能均优于传统的SVM算法,这是因为SVM仅能提取空间特征,无法将光谱信息特征与空间信息特征结合,导致从图像中其提取的特征不充分。2D-CNN,3D-CNN仅从空间维度提取了空间-光谱特征信息,提取的特征表达能力不强,导致该分

类算法的分类精度并不高。HybridNet可以比较有效地同时提取图像的空谱特征信息与光谱特征信息,可以达到较好的分类效果,但缺点是该方法设计的网络不仅计算量大,而且其对于HSI图像的光谱特征信息进行一致的处理,然而不同光谱对不同地物的贡献率不同,这在一定程度上也削弱了HybridNet模型的分类性能,RSSAN在SSRN的基础上加入了注意力机制,使得模型效果得到了一定程度的提高。与RSSAN相比,PMACNN在特征提取网络采用普通卷积与空洞卷积结合的网络来同时捕获空间特征的近远程信息,并且在网络中采用不同大小的卷积核对图像提取不同的特征,并将这些特征在光谱维度上融合后得到多层次且特征丰富的特征图。最后的通道注意力模块增强了有用特征信息的表征作用,这使整个模型分类效果体现出明显的优势,实验证明本模型对HSIC任务的分类效果最优。由表3可知,较目前此领域内领先的分类模型RSSAN相比,在OA、AA、Kappa三个评价指标上PMACNN的分类精度均提高了0.66%、0.61%、9.87%。可见,PMACNN是一个比较优越的算法模型。

[0047] 表3 Indian Pines数据集上六种方法分类结果(%)

类别	SVM	2D-CNN	3-DCNN	HybridSN	RSSAN	PMACNN
[0048] OA(%)	78.45	85.48	97.89	97.85	98.56	99.22
AA(%)	72.03	83.24	97.83	95.38	98.35	98.96
KAPPA	75.96	77.33	97.68	97.55	89.22	99.09
1	70.67	81.23	93.67	99.92	98.38	100
2	96.55	95.56	100	99.66	98.32	96.81
3	89.08	95.77	100	99.89	98.19	99.87
4	50.73	92.49	96.23	99.87	97.99	100
5	93.46	94.72	98.72	95.46	98.61	99.77
6	95.07	95.66	98.88	98.39	98.47	99.70
7	35.34	63.73	96.23	100	98.25	100
[0049] 8	87.06	86.97	100	100	100	100
9	29.97	87.68	100	100	97.51	100
10	91.99	83.46	99.21	95.21	98.08	99.77
11	94.68	80.43	95.95	97.33	98.32	99.68
12	65.21	79.99	96.88	96.89	97.83	97.94
13	91.02	86.71	99.56	96.43	98.68	98.37
14	89.68	85.32	99.47	99.21	98.42	100
15	75.02	84.95	99.00	99.42	96.75	100
16	80.73	83.47	90.59	89.96	91.07	94.04

[0050] 在University of Pavia和Salinas数据集上进行的比较实验则随机选用了5%和5%的训练样本,剩余百分之95%和95%的样本作为测试样本。图6和图7展示了不同分类方法得到的分类图以及上述两个数据集的地物灰度图,而表4和表5则给出了各类方法的定量分析结果。在这两个数据集对比试验中,本方法(PMACNN)在PU和SA数据集上的OA精度分别达到了99.73%和99.97%,在所有比较方法中精度最高。总体上,PMACNN在IN,PU和SA数据集上的三个指标性能均取得了最优精度。

[0051] 表4 University of Pavia数据集上六种方法分类结果(%)

类别	SVM	2D-CNN	3-DCNN	HybridSN	RSSAN	PMACNN
OA(%)	87.87	98.31	99.14	99.25	99.37	99.73
AA(%)	85.79	96.28	97.76	98.29	99.12	99.18
KAPPA	84.68	97.76	98.86	99.01	99.21	99.68
1	88.22	99.98	100	100	99.31	100
2	87.86	99.90	99.98	99.98	99.68	100
3	80.98	93.73	97.89	99.15	100	100
4	94.76	88.21	94.02	96.8	98.99	99.13
5	92.09	96.52	94.91	99.29	99.87	99.67
6	88.74	99.83	100	99.92	99.99	100
7	90.21	96.93	100	99.76	98.88	99.66
8	80.55	98.84	99.88	96.88	98.20	99.55
9	92.26	92.67	93.2	92.89	99.43	94.83

[0052] 表5 Salinas数据集上六种方法分类结果(%)

类别	SVM	2D-CNN	3-DCNN	HybridSN	RSSAN	PMACNN
OA(%)	90.45	97.92	99.26	99.85	99.90	99.97
AA(%)	88.03	95.24	99.13	99.74	99.81	99.96
KAPPA	89.44	95.55	99.22	99.66	99.79	99.97
1	89.43	98.23	100	100	100	100
2	92.21	99.81	100	100	100	100
3	92.33	98.87	100	100	100	100
4	87.90	95.49	98.56	100	100	100
5	93.47	96.72	99.07	99.90	99.61	99.56
6	95.22	98.66	99.64	99.75	99.67	99.97
7	86.03	95.73	98.58	100	100	99.91
8	92.00	97.97	100	100	100	100
9	89.67	96.68	99.88	99.69	99.51	100
10	95.88	97.22	100	100	100	100
11	83.75	97.39	99.54	100	100	100
12	87.85	95.87	98.86	99.69	99.83	100
13	91.02	98.62	99.99	100	100	100
14	89.68	98.58	100	100	100	100
15	91.02	99.91	99.82	100	100	100
16	89.73	97.47	98.67	100	99.97	100

[0056] 为验证本方法在小样本情况下的性能,对IN数据集分别选取5%、7%、10%、15%的样本作为训练集,剩余样本作为测试集;对PU和SA数据集随机划分了0.5%、1%、2%和5%的样本数据作为训练集进行实验。在IN,PU和SA数据集上得到的实验结果分别如图8(a)、(b)、(c)所示。

[0057] 由图可知,在三个数据集上,随训练样本数量增加,不同分类方法的分类精度均呈增长趋势。而当训练样本足够多时,分类精度上升的速度会逐渐变缓,分类结果趋于稳定。除此之外图8显示在小样本情况下,PMACNN分类效果最好。

[0058] 此外,为验证本方法中浅层特征预提取模块的效果,我们选择浅层特征预提取模块分别为a:3x3卷积,b:1x1卷积,c:1x1卷积、3x3卷积及5x5卷积核的组合(本文所采用的模块)和d:不添加任何一种浅层特征预提取模块来进行对比实验,由表6可知,c:1x1卷积、3x3卷积及5x5卷积核的组合(本文所采用的模块)作为浅层特征预提取模块可使多尺度特征提取模块发挥的作用最好,两者结合能使模型分类性能最优。

[0059] 表6不同浅层特征预提取模块对分类结果的影响

	OA (%)	a	b	c	d
[0060]	IN	99.13	99.18	99.25	99.05
	PU	99.67	99.66	99.73	99.13
	SA	99.94	99.92	99.97	99.38

[0061] 为验证本方法中通道注意力模块的有效性,我们在模型中不同位置(分别在三个近、远程特征提取模块之后)加入注意力模块来测试并记录分类结果,结果如表7所示。

[0062] 表7不同位置通道注意力模块对分类结果的影响

	网络模型	模块 1	模块 2	模块 3	OA(%)
[0063]	None	×	×	×	99.13
	ECA1	√	×	×	99.14
	ECA2	×	√	×	99.16
	ECA3	×	×	√	99.22

[0064] 可以看出,加入注意力模块后,模型的分类性能优于未加注意力模块的模型,且在最后一个特征提取模块之后加入注意力模块分类结果最优,这是因为图像通过第三个特征提取模块之后,网络已提取出图像中更为具象的特征,并且特征表达更充分。此时加入注意力模块,会将特征图的注意力集中在那些包含大量有用信息的特征上,为高层次特征提供更好的像素级注意,从而有效地提高算法的分类精度。

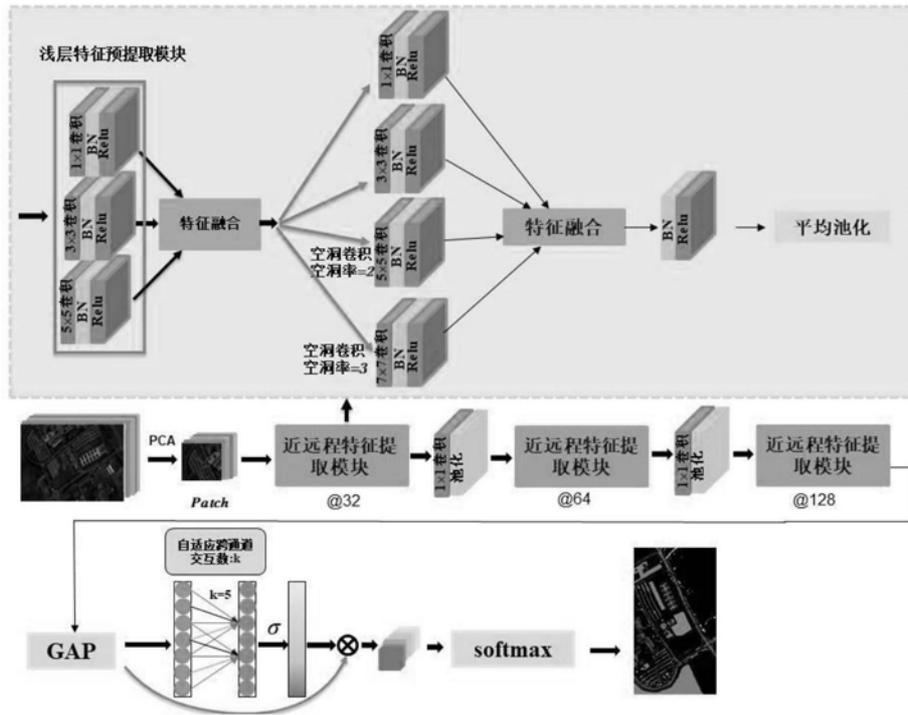


图1

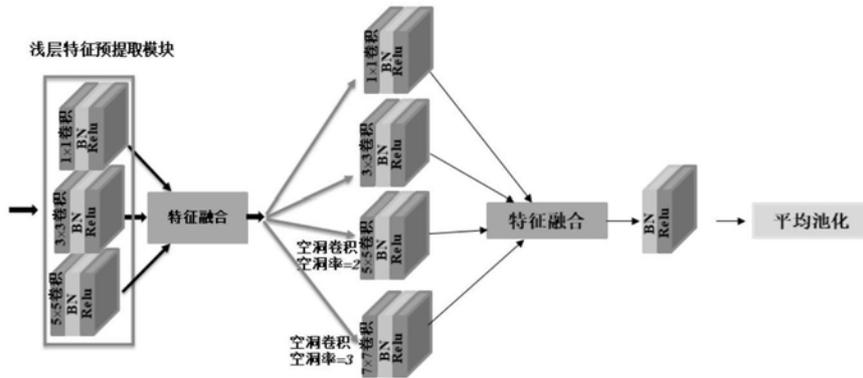


图2

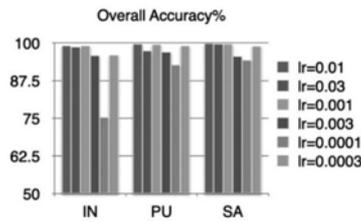


图3

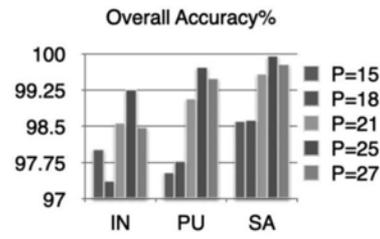


图4

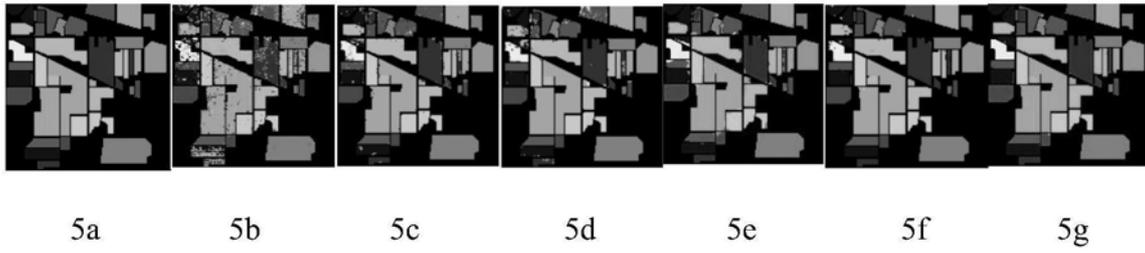


图5

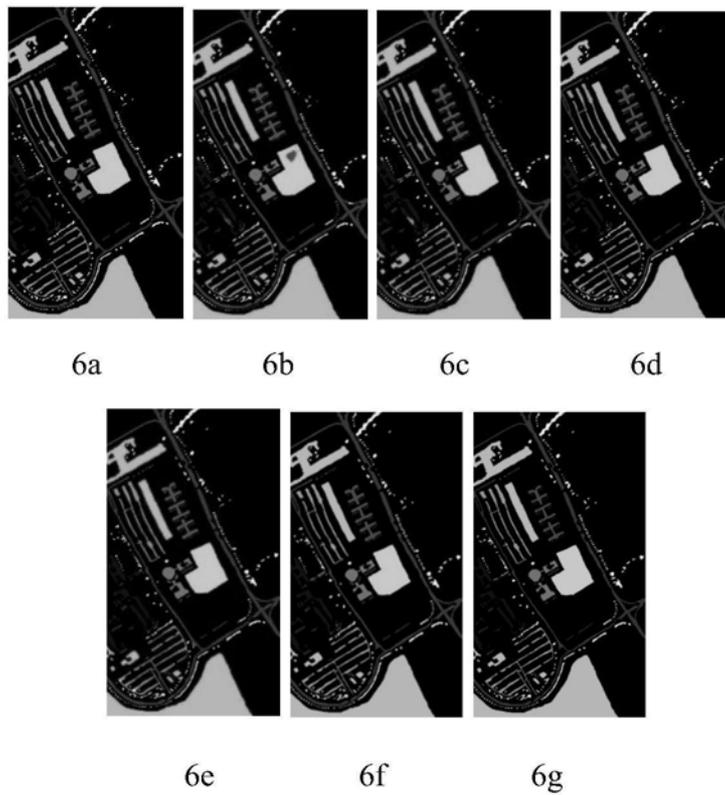


图6

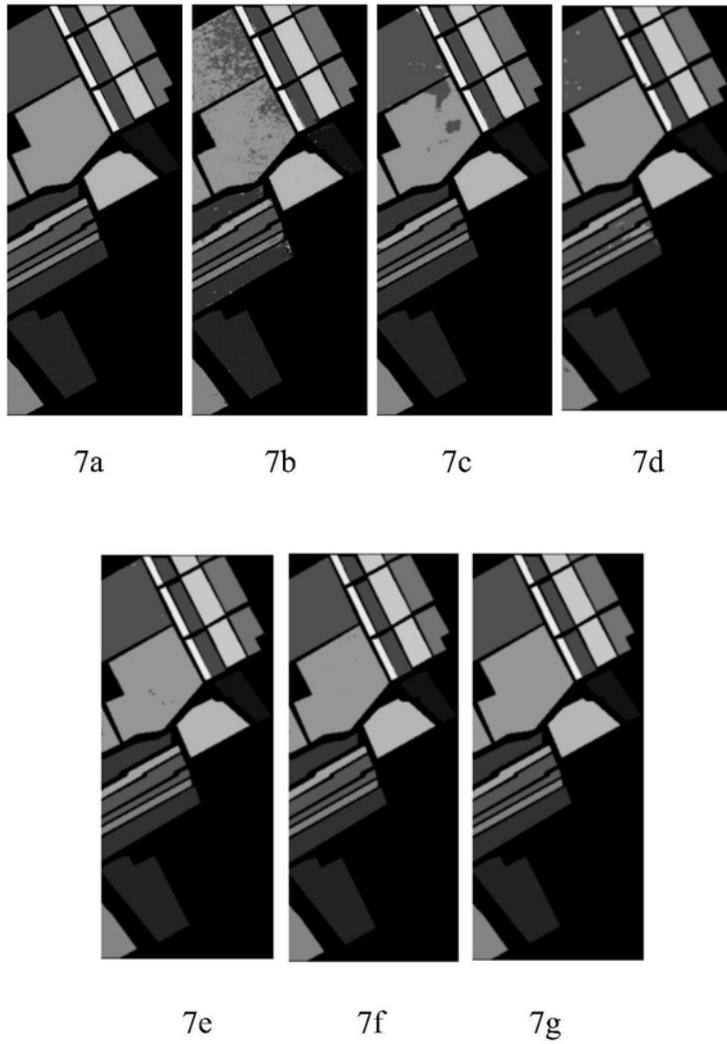


图7

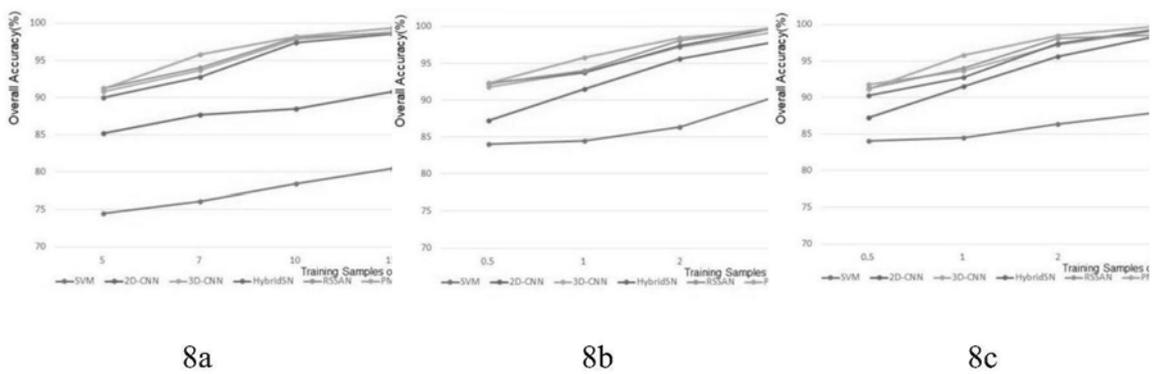


图8