

基于改进 DenseNet 和空谱注意力机制的高光谱图像分类

王欣*, 樊彦国

中国石油大学(华东)海洋与空间信息学院, 山东 青岛 266500

摘要 针对高光谱图像维度高、训练样本少以及训练带来的过拟合、参数过多问题,提出了一种基于改进密集连接网络(DenseNet)和空谱注意力机制网络(MDSSAN)的高光谱图像分类方法。首先,对高光谱图像进行主成分分析,并将中心像素的空间邻域输入改进的网络模型中。然后,对三维DenseNet进行改进,将模型中的三维卷积块分解成空间维和光谱维的采样卷积。最后,在空间维上引入空间注意力机制,在光谱维上引入通道注意力机制,以减少模型的训练参数,提取更具判别力的空谱联合特征。实验结果表明,MDSSAN模型在Indian Pines、Pavia University和KSC数据集上的总体分类精度分别为99.43%、99.74%、98.98%,相比其他对比模型,该模型的收敛速度更快,分类性能更好。

关键词 图像处理; 高光谱图像; 密集连接网络; 空间注意力机制; 通道注意力机制

中图分类号 P407.8

文献标志码 A

doi: 10.3788/LOP202259.0210014

Hyperspectral Image Classification Based on Modified DenseNet and Spatial Spectrum Attention Mechanism

Wang Xin*, Fan Yanguo

*College of Oceanography and Spatial Information, China University of Petroleum (East China),
Qingdao, Shandong 266500, China*

Abstract Aiming at the problems of hyperspectral image with high dimension, a few training samples, over fitting and too many training parameters, we propose an modified dense connection network (DenseNet) combined with spatial spectrum attention mechanism network (MDSSAN). First, the hyperspectral images are analyzed by principal component analysis, and the spatial neighborhoods of the central pixels are input into the modified network model. Then, three-dimensional DenseNet is improved, and the three-dimensional convolution block in the model is decomposed into the sampling convolution of the spatial dimension and the spectral dimension. Finally, the spatial attention mechanism is introduced in the spatial dimension, and the channel attention mechanism is introduced in the spectral dimension to reduce the training parameters of the model and extract more discriminative space-spectrum joint features. Experimental results show that the overall classification accuracy of the MDSSAN model on the Indian Pines, Pavia University, and KSC data sets are 99.43%, 99.74%, and 98.98%, respectively. Compared with other comparison models, the model has faster convergence speed and better classification performance.

Key words image processing; hyperspectral image; dense connection network; spatial attention mechanism; channel attention mechanism

收稿日期: 2021-01-21; 修回日期: 2021-02-27; 录用日期: 2021-03-15

基金项目: 国家自然科学基金(62071492)、山东省重点研发计划(2019GHY112017)

通信作者: *3166588225@qq.com

1 引言

高光谱遥感图像一般由数十甚至上百个窄波段组成,具有较高的光谱分辨率,相比全色和多光谱遥感图像,高光谱图像的每个像元都可反映为一条连续的光谱响应曲线。此外,高光谱图像还包含丰富的空间信息,这种“图谱合一”的特性有效提高了地物目标的识别精度,使其被广泛应用于农业、环境监测、地球科学、测绘学等领域^[1-2]。但高光谱图像的训练样本较少,使其分类问题面临着一系列挑战。

深度学习具有强大的特征提取能力,各类深度学习网络模型逐渐被应用到高光谱图像的分类领域中^[3]。Chen 等^[4]将深度学习引入高光谱图像分类中,利用自动编码器提取高光谱图像的光谱特征,相比机器学习方法,分类精度有明显提升,但该方法只利用了高光谱图像的光谱信息,忽略了其空间信息。卷积神经网络(CNN)可提取高光谱图像的光谱特征、空间特征以及光谱空间联合特征,被广泛应用于高光谱图像特征的提取和分类中^[4-5]。但 CNN 只能分开提取高光谱图像的空间、光谱信息,网络计算冗余,且不能充分提取高光谱图像的复杂信息,破坏了高光谱数据的三维结构。因此,人们将三维 CNN(3D-CNN)应用到高光谱图像分类中,在不依赖任何复杂的预处理及后处理,且不破坏高光谱图像数据结构的前提下,有效提取了高光谱图像的空谱联合特征^[6-7]。为了解决模型加深导致的过拟合、梯度消失问题,人们提出了残差网络^[8]及密集连接网络(DenseNet)^[9]的思想,并在此基础上提出了一系列应用于高光谱图像分类的模型。Zhong 等^[10]提出了一种空谱残差三维卷积神经网络(SSRN)分类模型,通过光谱空间连续残差块依次提取高光谱图像的空谱联合特征,有效提高了分类精度。Li 等^[11]利用三维密集连接网络(3D-DenseNet)进行高光谱图像分类,并将注意力机制嵌入网络的浅层、中层、高层阶段(3D-SE-DenseNet),降低了模型的训练成本,并提高了模型的收敛速度,有效避免了模型在小样本数据集上的过拟合问题。Li 等^[12]提出的深度多层特征融合密集连接网络(MFDN)基于不同的样本输入大小同时提取空间和光谱特征,并通过三维密集块将空间特征和光谱特征融合在一起,有效增强了分类效果。针对模型加深造成的参数过多问题,郑姗姗等^[13]提出了一种改进的多尺度三维残差 CNN

(M3RCNN),对多尺度滤波器组和残差单元进行改进,充分提取了图像的深层局部空间-光谱联合特征。虽然基于 CNN 的高光谱图像分类方法已经取得了较好的效果,但高光谱图像的分类依然面临着训练样本少、特征提取不充分、模型参数过多等一系列问题。

基于上述问题,本文提出了一种基于改进 DenseNet 和空谱注意力机制网络(MDSSAN)的高光谱图像分类方法。首先,对高光谱图像进行主成分分析(PCA),降低图像特征的维数。然后,设计神经网络模型,将 3D-DenseNet 模型的三维卷积模块分解成空间维度和光谱维度的采样卷积,减少模型的训练参数。最后,在空间维度上引入空间注意力机制,在光谱维度上引入通道注意力机制,增强判别性特征,提高网络的学习能力。设置网络模型的训练参数,通过指数衰减法调整学习率,减少模型的训练时间,加快收敛速度,并在 Indian Pines、Pavia University 和 KSC 三个数据集上验证了该模型的有效性。

2 实验原理

介绍了 MDSSAN 方法的高光谱图像分类思想,包括改进 3D-DenseNet 模型的基本原理以及适用于高光谱分类的空谱注意力机制,最后,介绍了 MDSSAN 分类方法的实现原理。

2.1 改进的 3D-DenseNet 模型

2.1.1 3D-DenseNet 模型

3D-DenseNet 是一种深层次的网络结构,旨在增强特征传输,鼓励特征重用,以密集连接结构改善网络中的信息流^[14]。此外,通过使用瓶颈层、过渡层减少模型的参数,有效抑制过拟合并减少梯度消失现象。与残差网络不同的是,DenseNet 通过逐层连接,使每层的输入特征都接收来自之前每一层输出特征在通道维度上的叠加^[15],可表示为

$$x_l = H\left(\left[x_0, \dots, x_{l-1}\right]\right), \quad (1)$$

式中, x_l 为第 l 层的输出, $\left[x_0, \dots, x_{l-1}\right]$ 表示将输入层到 $l-1$ 层的特征图在通道维度上进行叠加, $H(\cdot)$ 为非线性转化函数,包括卷积(Conv)、归一化、非线性激活等操作。

基本的 3D-DenseNet 模型包括多个密集连接块(Dense_Block)以及过渡层(Transition)。在多个密集连接层中,假设首层输入的特征图数量为 k_0 ,密集连接层每层输出的特征图数量为 k ,则第 l 层的输

入特征图通道数可表示为

$$k_l = k_0 + (l - 1)k. \quad (2)$$

Dense_Block 中的每个密集连接层 (Dense_Layer) 都接受来自前面所有层的特征图, 层与层之间相互传递, 从而实现特征传播以及梯度传播, 加强了特征重用, 解决了高光谱图像的小样本分类问题以及网络训练过程中产生的梯度消失、过拟合问题。过渡层主要包括一个 $1 \times 1 \times 1$ 卷积层和一个 $2 \times 2 \times 2$ 池化层, 用来连接两个 Dense_Block, 并减少特征图数量。经过过渡层后特征图数量压缩为 θm , 其中, $0 \leq \theta \leq 1$ 为压缩因子, 通过设置 θ 的大小, 可实现特征图的压缩, 减少计算量, m 为 Dense_Block 输出的特征图数量。

2.1.2 改进的 3D_DenseNet 模型

三维卷积块可直接对高光谱图像数据块进行卷积, 无须预处理操作, 且能同时提取具有判别性的深层空谱联合特征, 充分利用三维高光谱图像的数据特征。三维卷积操作可表示为

$$v_{ij}^{xyz} = f \left(\sum_m \sum_{h=0}^{H_l-1} \sum_{w=0}^{W_l-1} \sum_{r=0}^{R_l-1} k_{ijm}^{hwr} v_{(l-1)m}^{(x+h)(y+w)(z+r)} + b_{ij} \right), \quad (3)$$

式中, H_l 、 W_l 为空间维卷积核的尺寸, R_l 为光谱维卷积核的尺寸, l 为当前层, j 为该层特征图的数量, v_{ij}^{xyz} 为 (x, y, z) 处第 l 层的第 j 个特征图, k_{ijm}^{hwr} 为

(h, w, r) 与第 $l-1$ 层第 m 个特征相连接的 l 层第 j 个特征图的权重, b 为偏置, $f(\cdot)$ 为激活函数。

深度三维卷积块对计算成本和存储的需求较高, 为了减少模型的参数和训练时间, 郑姗姗等^[13]将三维卷积块分解为光谱卷积块和空间卷积块, 即将 $v_1 \times v_2 \times 1$ 与 $1 \times 1 \times v_3$ 两个卷积块串联, 以模拟 $v_1 \times v_2 \times v_3$ 三维卷积块, 如图 1 所示。




图 1 改进的三维卷积模块

Fig. 1 Modified three-dimensional convolution module

借鉴郑姗姗等^[13]的改进思想, 对 3D_DenseNet 模型进行改进。将模型中的三维卷积块用串联的光谱卷积块和空间卷积块代替, 并将光谱卷积块与下一层的输出相连接, 改进的 Dense_Layer 如图 2 所示。将密集连接层中的 $3 \times 3 \times 3$ 卷积用串联的两个 $3 \times 3 \times 1$ 与 $1 \times 1 \times 3$ 卷积代替, 并在其前添加批量归一化 (BN) 层、线性整流单元 (ReLU) 激活函数及 $1 \times 1 \times 1$ 卷积, 得到 $4k$ 个特征图。经过 BN 层、ReLU 层、 $3 \times 3 \times 1$ 卷积以及 $1 \times 1 \times 3$ 卷积, 特征图的数量变为 k , 通过设置 k 的值, 可极大降低特征图的数量, 提升计算效率。将多个密集连接层相连接, 组成基本的 Dense_Block 结构, 从而加强特征重用, 降低模型的训练参数, 加快模型的收敛速度。

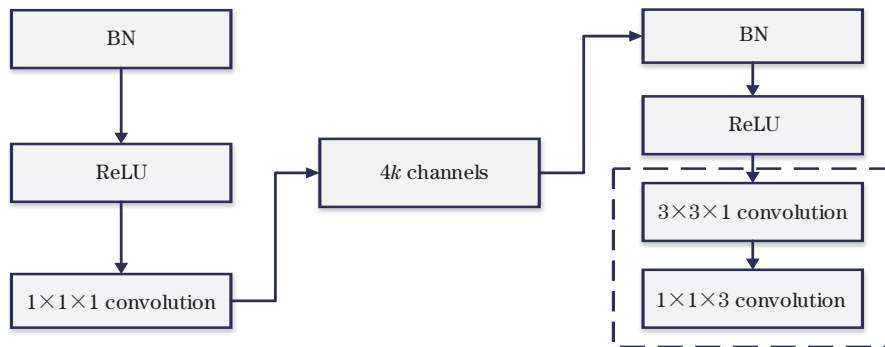


图 2 改进 Dense_Layer 的结构

Fig. 2 Structure of the modified Dense_Layer

2.2 空谱注意力机制

随着深度学习在高光谱图像分类中的普及, 计算机视觉领域的注意力机制也逐渐被作为辅助工具引入深度学习高光谱图像的分类任务中^[16]。注意力机制通过模拟人眼观察事物自觉接受感兴趣区域的思想, 从众多特征中忽略与当前任务无关的信息, 关注与当前任务有关的信息^[17]。将注意力机

制应用到高光谱图像分类中, 可通过赋予判别性特征更高的权重提高网络的学习能力。常用的注意力机制模型包括空间注意力机制和通道注意力机制。空间注意力机制是为同一特征图的空间信息重新分配权重, 获取包含不同空间权重信息的特征图; 通道注意力机制是在通道维度上为特征图重新分配权重, 获取不同通道的权重特征图^[18]。本方法

基于通道注意力和空间注意力机制的特点,将其与改进的 3D_DenseNet 模型相结合,以减少模型计算参数,增强模型的学习能力。

通道注意力机制(CA)模型与空间注意力机制(SA)模型如图 3 所示。对于一个给定的特征图 $X(L, H, W, C)$,其中, (L, H, W) 为特征图的空间维度, C 为通道数。其通道注意力机制可表示为

$$X_{CA} = \sigma \left\{ X_{FC} \left\{ \delta \left\{ X_{FC} \left[X_{MP}(X) \right] \right\} \right\} + X_{FC} \left\{ \delta \left\{ X_{FC} \left[X_{AP}(X) \right] \right\} \right\} \right\} X, \quad (4)$$

式中, σ 为 Sigmoid 激活函数, δ 为 ReLU 激活函数, $X_{FC}(\cdot)$ 为全连接(FC)层, $X_{MP}(\cdot)$ 为空间方向上的全局最大池化(MP), $X_{AP}(\cdot)$ 为全局平均池化(AP)。空间注意力机制可表示为

$$\sigma \left\{ \text{Conv} \left[\text{Concat} \left(X_{MP}, X_{AP} \right) \right] \right\}, \quad (5)$$

式中, $\text{Conv}(\cdot)$ 为卷积操作, $\text{Concat}(\cdot)$ 为通道方向上的级联操作。

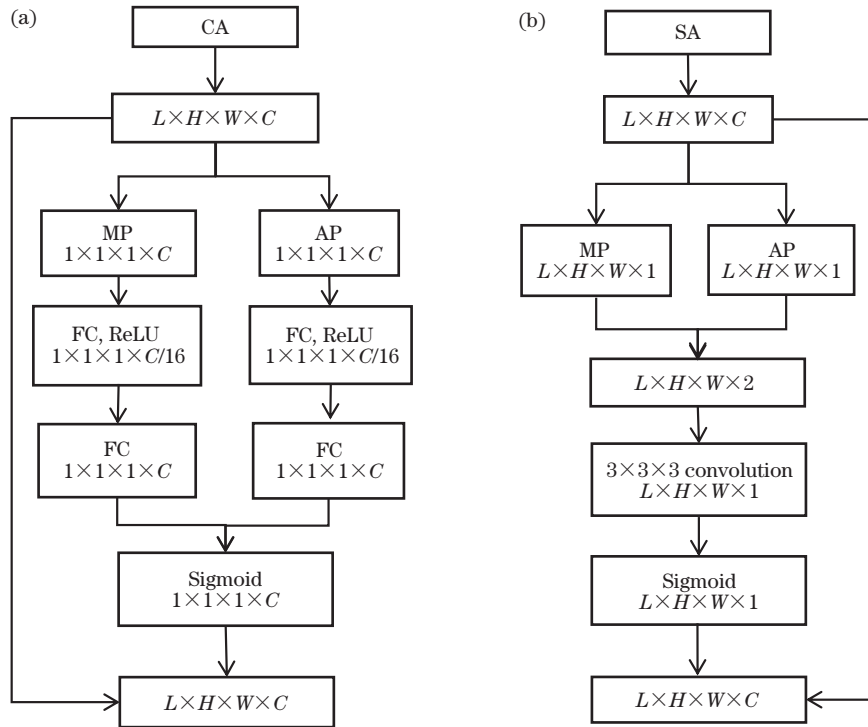


图 3 空谱注意力机制的模型。(a)通道注意力机制;(b)空间注意力机制

Fig. 3 Model of the spatial spectrum attention mechanism. (a) Channel attention mechanism; (b) spatial attention mechanism

2.3 改进的 DenseNet 联合注意力机制

将改进的 3D_DenseNet 模型与空间、通道注意力机制相结合,提出了一种基于改进 3D_DenseNet 模型和空谱注意力机制的高光谱图像分类方法,分别用空间注意力机制、通道注意力机制提取三维空间卷积块与三维光谱卷积块的判别信息,使其在空

间维度及光谱维度上分别获得特征权重,加强特征信息,增强模型的学习能力。Dense_Layer 的结构如图 4 所示。

高光谱图像具有高维度特性,在训练过程中容易产生过拟合现象。因此,先对两种数据集进行主成分分析,保留前 d 个波段,取尺寸为 $s \times s \times d$ 的




图 4 Dense_Layer 的结构

Fig. 4 Structure of the Dense_Layer

空间邻域块作为网络的输入。其中, $s \times s$ 为邻域块的尺寸。将该邻域块输入网络, 先通过第一个三维卷积层, 该卷积层以串联的 $7 \times 7 \times 1$ 与 $1 \times 1 \times 7$ 卷积代替 $7 \times 7 \times 7$ 三维卷积块。然后通过密集连接块, 将 $3 \times 3 \times 3$ 卷积替换为 $3 \times 3 \times 1$ 与 $1 \times 1 \times 3$ 卷积的串联模式, 并在 $3 \times 3 \times 1$ 卷积后添加空间注意力模块, 在 $1 \times 1 \times 3$ 卷积后添加通道注意力模块, 分别在空间维和光谱维上提取与分类相关的信息, 降低模型参数。在两个密集连接块之间

添加一个过渡层, 包括一个 $1 \times 1 \times 1$ 卷积层和一个平均池化层, 以减少特征图的数量, 缩小特征维度。在最后一个密集连接块之后用全局平均池化层代替全连接层, 有效防止了过拟合现象。最后将输出经过 Softmax 层赋予每个像素分类标签, 获得分类结果, 完成对高光谱图像的分类。上述所有卷积层都包含 BN 层和 ReLU 激活函数, 分类损失函数采用交叉熵损失函数, 具体的网络模型结构如图 5 所示。

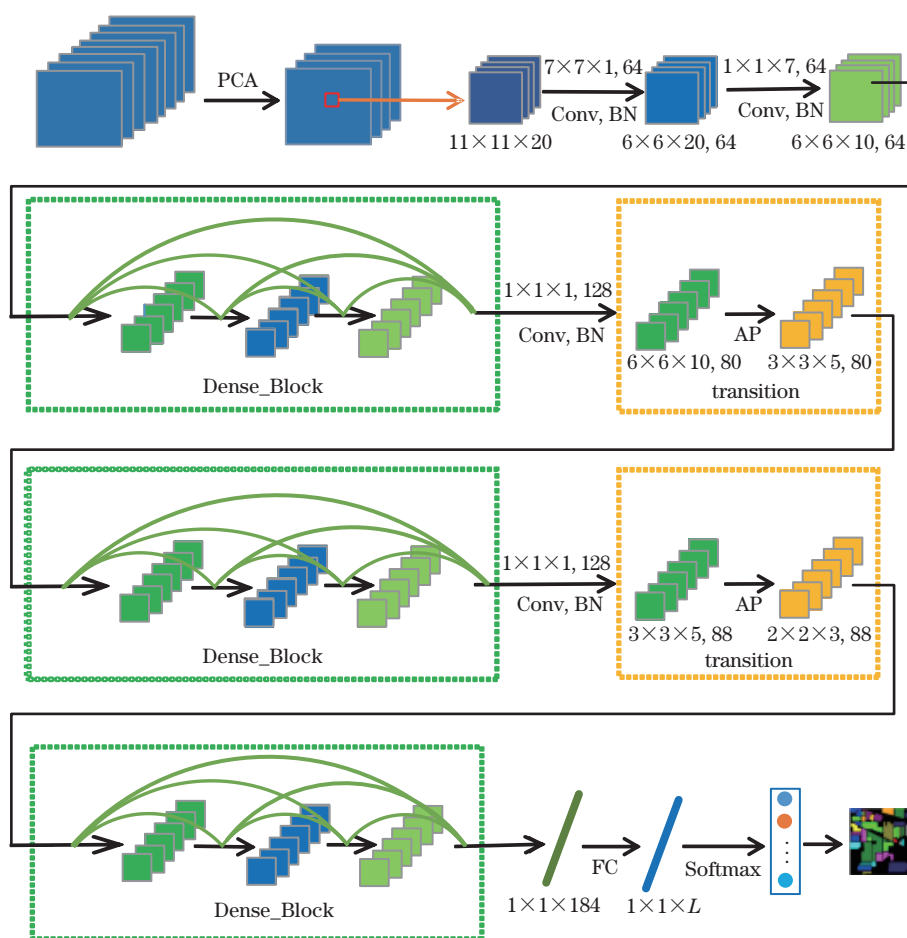


图 5 MDSSAN模型的结构

Fig. 5 Structure of the MDSSAN model

3 实验结果与分析

3.1 数据集介绍

Indian Pines 数据是机载可视红外成像光谱仪 (AVIRIS) 对美国印第安纳州一片印度松树的成像结果, 图像尺寸为 $145 \text{ pixel} \times 145 \text{ pixel}$ 。AVIRIS 的成像波长范围为 $0.4 \sim 2.5 \mu\text{m}$, 空间分辨率约为 20 m , 剔除 20 个不能被水反射的波段后, 剩余波段数为 200。该数据的每个波段图像包含 21025 个像素,

其中, 地物像素为 10249 个, 其余 10776 个像素为背景像素, 共包含 16 类地物类型, 大部分是农作物、植物等自然景观, 样本的分布极不均匀, 如图 6 所示。

Pavia University 数据是德国机载反射光学光谱成像仪 (ROSIS-03) 对意大利帕维亚城的成像结果。该光谱成像仪的波长范围为 $0.43 \sim 0.86 \mu\text{m}$, 空间分辨率为 1.3 m , 剔除 12 个受噪声影响的波段后剩余 103 个波段。数据集中的图像尺寸为 $610 \text{ pixel} \times 340 \text{ pixel}$, 每个波段包含 2207400 个像素, 其中, 地



图 6 Indian Pines 数据集和标签。(a) Indian Pines 数据集；(b) 标签

Fig. 6 Indian Pines data set and label. (a) Indian Pines data set; (b) label

物像素有 42776 个,共包含 9 类地物,包括树、沥青道路、砖块、牧场等,如图 7 所示。

KSC 数据由 AVIRIS 在佛罗里达州肯尼迪太空中心于 1996 年 3 月 23 日拍摄。AVIRIS 的成像波长范围为 0.4~2.5 μm,共包含 224 个波段,去除低信噪比波段后,剩余 176 个波段,空间分辨率为 18 m,图像尺寸为 512 pixel×614 pixel,共 13 个类别,包含山地和湿地等,如图 8 所示。

从三个数据集的每个类别中随机选取 20% 的样本作为训练集,剩余样本作为验证集和测试集,训练集、验证集和测试集的样本数量比例为 2:1:7。不同数据集选取的训练集、验证集和测试集的样本数量如表 1、表 2、表 3 所示。

3.2 参数设定

实验设置的数据集批处理大小为 32,优化器为




图 7 Pavia University 数据集和标签。(a) Pavia University 数据集;(b) 标签

Fig. 7 Pavia University data set and label. (a) Pavia University data set; (b) label




图 8 KSC 数据集和标签。(a) KSC 数据集;(b) 标签

Fig. 8 KSC data set and label. (a) KSC data set; (b) label

RMSprop,采用指数衰减学习率的方法提升网络性

表 1 Indian Pines 数据集选取的训练集、验证集、测试集样本数量

Table 1 Number of samples of training set, verification set and test set selected from Indian Pines data set

No.	Category	Training set	Verification set	Test set
1	alfalfa	11	4	34
2	corn-notill	284	141	1009
3	corn-min	167	100	572
4	corn	58	28	163
5	grass/pasture	103	75	320
6	grass/trees	148	70	530
7	grass/pasture-mowed	13	11	25
8	hay-windrowed	106	51	345
9	oats	12	12	23
10	soybeans-notill	202	111	689
11	soybeans-min	509	242	1737
12	soybeans-clean	126	73	430
13	wheat	55	26	163
14	woods	250	155	902
15	building-grass-trees-drives	85	55	291
16	stone-steel towers	35	28	78
Total		2164	1182	7311

表 2 Pavia University 数据集选取的训练集、验证集、测试集样本数量

Table 2 Number of samples of training set, verification set and test set selected from Pavia University data set

No.	Category	Training set	Verification set	Test set
1	asphalt	1306	691	4637
2	meadows	3730	1902	13023
3	gravel	400	225	1483
4	trees	626	336	2114
5	sheets	244	155	961
6	bare soil	1033	474	3540
7	bitumen	282	128	941
8	bricks	714	405	2587
9	shadows	179	92	703
Total		8514	4408	29989

表 3 KSC 数据集选取的训练集、验证集、测试集样本数量

Table 3 Number of samples of training set, verification set and test set selected from KSC data set

No.	Category	Training set	Verification set	Test set
1	scrub	172	70	522
2	willow swamp	50	32	167
3	camping hammock	52	28	185
4	slash pine	66	26	172
5	oak/broadleaf	39	19	118
6	hardwood	49	32	166
7	swap	23	24	79
8	graminoid marsh	81	62	312
9	spartina marsh	106	55	386
10	cattail marsh	88	44	302
11	salt marsh	90	58	304
12	mud flats	103	66	370
13	water	203	107	656
Total		1122	623	3739

能。其中,初始学习率为 0.01,衰减率为 0.93,衰减步长为 16。训练迭代次数为 100,正则化比率为 0.5。实验采用的计算机硬件为 Intel(R) Core(TM) i5-10400F CPU 2.90 GHz、内存为 16.0 GB,软件环境为 PyCharmTensorFlow2.0。采用三组高光谱图像数据集验证本方法的有效性,并通过平均精度(AA)、总体精度(OA)、Kappa 系数评价分类结果。

多次实验最终确定的三个数据集邻域输入尺寸为 $11 \times 11 \times 20$,首先,将该邻域块输入第一层卷积层及第二层卷积层,步长分别设置为 (2, 2, 1)、(1, 1, 2),经过 64 个 $7 \times 7 \times 1$ 卷积层以及 64 个 $1 \times 1 \times 7$ 卷积层将特征图尺寸变换为 $6 \times 6 \times 10$ (64 通道)。然后,经过第一个改进的三层密集连接层,将特征图的尺寸从 $6 \times 6 \times 10$ (64 通道)变换为 $6 \times 6 \times 10$ (160 通道)。其中,每层密集连接层的输出通

道数为 32,经过第一个过渡层的卷积层以及池化层,特征图的维度缩小为 $3 \times 3 \times 5$ (80 通道),压缩因子设定为 0.5。依次经过模型的第二个密集连接层、过渡层、第三个密集连接层,得到特征图的维度为 $2 \times 2 \times 3$ (184 通道)。最后,用全局平均池化层代替全连接层,输出的特征维度为 $1 \times 1 \times 184$,并经过 Softmax 层完成高光谱图像的分类。

3.3 实验结果与分析

3.3.1 实验结果

为了验证本方法的有效性,选取几种经典的分类方法进行对比分析,对比方法包括 2D_CNN^[18]、3D_CNN^[6]、M3RCNN^[9]、3D_DenseNet^[8]。为了保证实验结果的公平性,每次实验均在相同环境中进行,设定的参数与参考文献相同。为了验证改进三维卷积模块的优势,将其与原始 3D_DenseNet 模型

的参数以及分类精度进行了对比,其中,各种参数的设定及输入尺寸均相同。不同方法在不同数据集中的分类结果如图 9、图 10、图 11 所示,分类结果的评价指标如表 4、表 5、表 6 所示,改进前后三维模块的对比结果如表 7 所示。

3.3.2 实验结果分析

从表 4、表 5、表 6 可以发现,MDSSAN 方法在五种方法中的分类效果最好。对于 Indian Pines 数据集,Oats 地物的分类效果较差,原因是该地物的训练样本较少,导致模型无法精确学习该地物的特征。相比 M3RCNN 及 3D_CNN 的分类结果,3D_DenseNet 的 OA、Kappa 系数、AA 分别提高了 4.70 个百分点、5.39、4.43 个百分点和 4.73 个百分点、5.37、-1.29 个百分点。相比 3D_DenseNet,MDSSAN 方法的 OA、Kappa 系数、AA 分别提高 0.84 个百分点、0.95、3.38 个百分点。对于 Pavia University 数据集,五种方法的分类精度均有明显提升,原因是该数据集不存在小样本地物,可利用的训练样本较多,MDSSAN 方法的分类效果也较好。相比 3D_DenseNet,MDSSAN 方法的 OA、

Kappa 系数、AA 分别提高了 0.20 个百分点、0.27、0.22 个百分点。对于 KSC 数据集,相比 2D_CNN,3D_CNN 的 OA、Kappa 系数与 AA 分别提高了 2.09 个百分点,2.33,0.67 个百分点;相比 2D_CNN、3D_CNN、M3RCNN,3D_DenseNet 的 OA 分别提高了 4.59、2.50、0.21 个百分点,这表明 3D_DenseNet 在高光谱图像分类中的效果良好。此外,MDSSAN 方法的 OA 达到了 98.98%,比 3D_DenseNet 高 1.32 个百分点,且各类别的分类精度均达到了 93% 以上,分类性能稳定。从模型运行时间上看,MDSSAN 方法比 3D_DenseNet 和 M3RCNN 的运行时间短,比 2D_CNN 与 3D_CNN 长,原因是 2D_CNN 与 3D_CNN 的结构简单、训练参数较少。但提高分类精度,必然会增加模型的复杂度。从图 9、图 10、图 11 的分类结果可以发现,本方法的分类结果稳定,杂碎斑点较少,对三个数据集的分类结果也表明,本方法的适应性较强、收敛速度快,能提取深层且更具判别性的特征。

为了进一步验证本方法的有效性,表 7 对改进

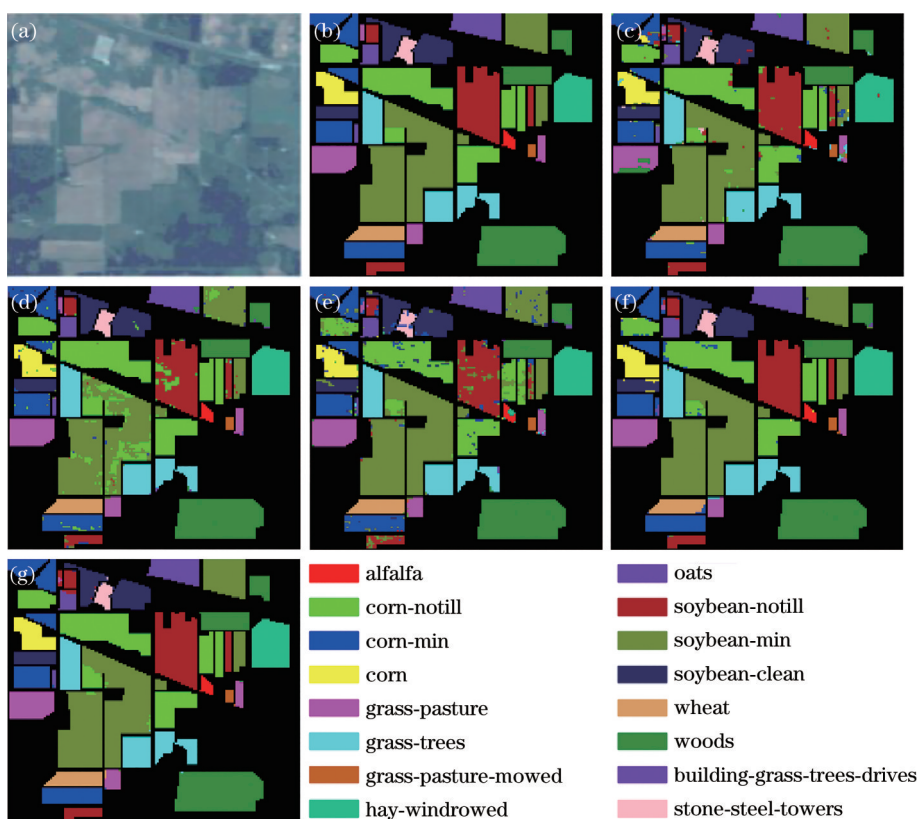


图 9 Indian Pines 数据集的分类结果。(a) Indian Pines 数据集;(b) 标签;(c) 2D_CNN;(d) 3D_CNN;(e) M3RCNN;(f) 3D_DenseNet;(g) MDSSAN

Fig. 9 Classification results of the Indian Pines data set. (a) Indian Pines data set; (b) label; (c) 2D_CNN; (d) 3D_CNN; (e) M3RCNN; (f) 3D_DenseNet; (g) MDSSAN




图 10 Pavia University 数据集的分类结果。(a) Pavia University 数据集;(b) 标签;(c) 2D_CNN;(d) 3D_CNN;
(e) M3RCNN;(f) 3D_DenseNet;(g) MDSSAN

Fig. 10 Classification results of the Pavia University data set. (a) Pavia University data set; (b) label; (c) 2D_CNN;
(d) 3D_CNN; (e) M3RCNN; (f) 3D_DenseNet; (g) MDSSAN

前后三维模块的参数和分类精度进行了对比。可明显发现,对于 Indian Pines、Pavia University、KSC 数据集,改进后的参数比改进前降低了 620877,OA 分别提高了 0.73、0.57、3.05 个百分点。这表明本方法能缓解高光谱图像分类的小样本问题,在训练过程中能有效抑制过拟合问题,同时大大减少模型训练的参数量及训练时间,收敛速度较快。

4 结 论

针对高光谱图像维度高、样本少,模型训练带来的过拟合、参数多的问题,提出了一种基于改进密集连接网络和空谱注意力机制的网络模型。该模型将三维卷积块分解成空间维和光谱维的采样卷积,并在空间维卷积后添加空间注意力机制,在光谱维卷积后添加通道注意力机制,以注意对分类有用的判别性特征,忽略无关特征,增强网络的学习能力。该方法在 Indian Pines、Pavia University 和 KSC 三个数据集上的总体分类精度分别达到了 99.43%、99.74% 及 98.98%,性能明显优于 2D_CNN、3D_CNN、M3RCNN、3D_DenseNet 方法;且该方法的训练参数较少,收敛速度较快,有效解决了过拟合及小样本问题。后续研究中,可针对高光谱图像的小样本问题,将网络模型与扩增样本的方法相结合,进一步提高分类精度。

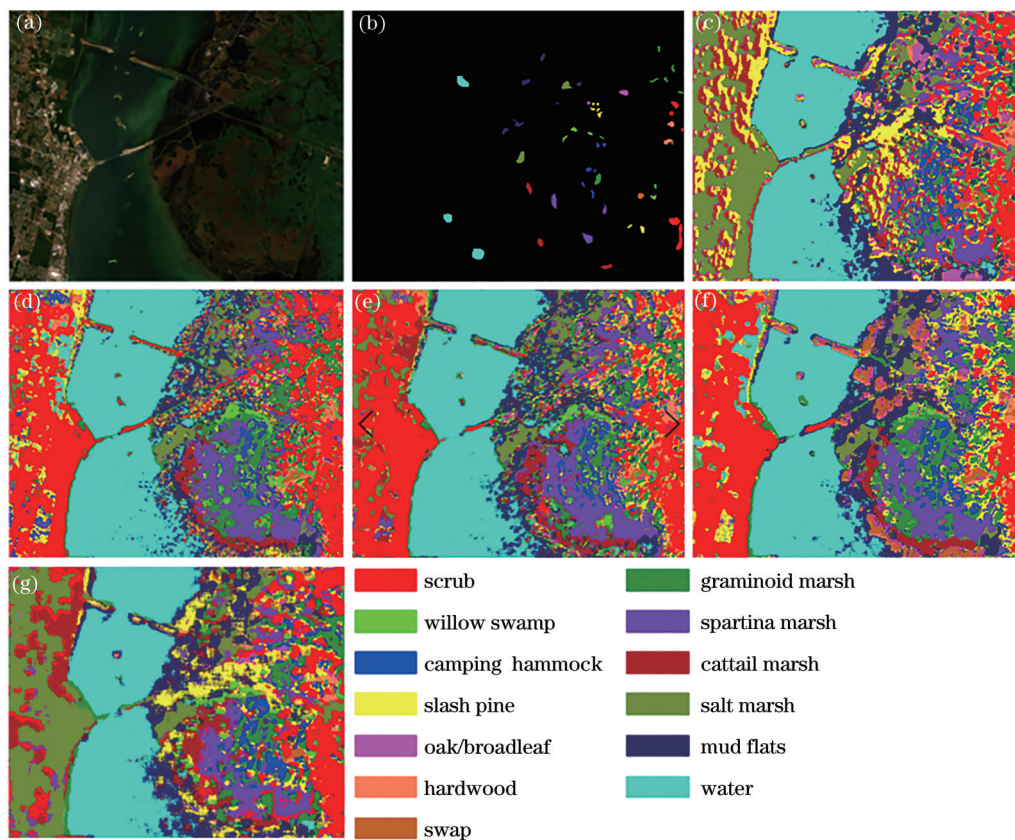


图 11 KSC 数据集的分类结果图。(a) KSC 数据集;(b) 标签;(c) 2D_CNN;(d) 3D_CNN;(e) M3RCNN;(f) 3D_DenseNet;
(g) MDSSAN

Fig. 11 Classification result diagram of the KSC data set. (a) KSC data set; (b) label; (c) 2D_CNN; (d) 3D_CNN; (e) M3RCNN;
(f) 3D_DenseNet; (g) MDSSAN

表 4 Indian Pines 数据集的分类结果
Table 4 Classification results of the Indian Pines data set

Classification	2D_CNN	3D_CNN	M3RCNN	3D_DenseNet	MDSSAN
Alfalfa / %	93.48	100.00	71.74	97.83	97.83
Corn-notill / %	95.87	99.86	85.92	95.59	98.32
Corn-min / %	93.13	90.84	93.86	100.00	99.76
Corn / %	92.83	94.09	92.41	99.58	100.00
Grass/pasture / %	81.78	98.55	93.37	95.65	99.79
Grass/trees / %	98.49	98.77	98.49	99.73	99.86
Grass/pasture-mowed / %	89.29	100.00	100.00	100.00	100.00
Hay-windrowed / %	99.58	100.00	100.00	100.00	100.00
Oats / %	90.00	85.00	55.00	40.00	80.00
Soybeans-notill / %	95.88	89.51	83.54	99.59	99.38
Soybeans-min / %	98.21	83.95	97.84	99.96	99.76
Soybeans-clean / %	96.46	98.48	93.76	97.64	99.49
Wheat / %	98.05	100.00	99.51	94.15	100.00
Woods / %	99.60	99.60	98.97	99.45	99.92
Building-grass-trees-drives / %	97.93	98.19	97.15	99.22	98.45
Stone-steel towers / %	97.85	98.92	82.80	96.77	96.77
OA / %	96.43	93.86	93.89	98.59	99.43
AA / %	94.90	95.99	90.27	94.70	98.08
Kappa coefficient	95.93	93.03	93.01	98.40	99.35
Time / min	1.89	5.38	32.27	18.07	12.43

表 5 Pavia University 数据集的分类结果
Table 5 Classification results of the Pavia University data set

Classification	2D_CNN	3D_CNN	M3RCNN	3D_DenseNet	MDSSAN
Asphalt / %	98.97	99.40	99.26	98.66	99.82
Meadows / %	99.43	99.65	99.98	99.92	99.96
Gravel / %	97.28	94.33	97.14	99.29	97.76
Trees / %	99.71	97.78	99.61	98.47	99.45
Sheets / %	99.70	98.88	100.00	100.00	99.93
Baresoil / %	99.64	99.98	87.09	100.00	99.96
Bitumen / %	84.21	98.87	98.87	99.02	99.32
Bricks / %	97.91	99.35	99.57	100.00	99.78
Shadows / %	91.66	99.89	100.00	97.99	99.37
OA / %	98.53	99.18	98.12	99.54	99.74
AA / %	96.50	98.68	97.95	99.26	99.48
Kappa coefficient	98.05	98.92	97.49	99.39	99.66
Time / min	6.61	7.21	73.92	76.10	19.58

表 6 KSC 数据集的分类结果
Table 6 Classification results of the KSC data set

Classification	2D_CNN	3D_CNN	M3RCNN	3D_DenseNet	MDSSAN
Scrub / %	97.77	99.74	99.74	98.16	100.00
Willow swamp / %	78.60	99.18	93.42	88.48	95.06
CP hammock / %	87.89	93.75	98.83	98.83	100.00
Slash pine / %	70.24	58.33	86.51	88.89	95.24
Oak/broadleaf / %	78.88	80.12	85.09	93.17	93.79
Hardwood / %	93.89	80.34	93.01	92.14	100.00
Swap / %	98.10	78.10	97.14	100.00	100.00
Graminoid marsh / %	89.33	99.54	98.84	99.07	98.84
Spartina marsh / %	90.77	98.65	100.00	99.81	99.62
Cattail marsh / %	90.84	99.26	100.00	100.00	98.51
Salt marsh / %	99.76	100.00	99.52	99.76	100.00
Mud flats / %	99.40	97.02	94.63	97.22	98.81
Water / %	99.89	100.00	99.89	100.00	100.00
OA / %	93.07	95.16	97.45	97.66	98.98
AA / %	90.41	91.08	95.89	96.58	98.45
Kappa coefficient	92.28	94.61	97.16	97.39	98.87
Time / min	1.11	1.74	18.04	11.25	8.19

表 7 改进前后三维卷积模块的效果
Table 7 Effect of three-dimensional convolution module before and after the improvement

Data set	Model parameter		OA / %	
	Before improvement	After improvement	Before improvement	After improvement
Indian Pines	1186044	565167	98.70	99.43
Pavia University	1184749	563872	99.17	99.74
KSC	1185489	564612	95.93	98.98

参 考 文 献

[1] Lu B, Dao P D, Liu J, et al. Recent advances of hyperspectral imaging technology and applications in agriculture[J]. Remote Sensing, 2020, 12(16): 2659-2702.

[2] Khan M J, Khan H S, Yousaf A, et al. Modern trends in hyperspectral image analysis: a review[J]. IEEE Access, 2018, 6: 14118-14129.

[3] Li S H. Hyperspectral image classification based on deep learning[D]. Xi'an: Xidian University, 2019: 7-15.
李诗卉. 基于深度学习的高光谱图像分类[D]. 西安: 西安电子科技大学, 2019: 7-15.

[4] 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.

[5] Yang J X, Zhao Y Q, Chan J C W. Learning and transferring deep joint spectral-spatial features for hyperspectral classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(8): 4729-4742.

[6] Qi Y F, Chen J, Huo Y L, et al. Hyperspectral image classification algorithm based on multiscale convolutional neural network[J]. Infrared Technology, 2020, 42(9): 855-862.
齐永锋, 陈静, 火元莲, 等. 基于多尺度卷积神经网络的高光谱图像分类算法[J]. 红外技术, 2020, 42(9): 855-862.

[7] Yue J, Zhao W Z, Mao S J, et al. Spectral-spatial classification of hyperspectral images using deep convolutional neural networks[J]. Remote Sensing Letters, 2015, 6(6): 468-477.

[8] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[J]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: