

引入注意力机制的卷积神经网络高光谱图像分类

陈文豪¹, 何敬^{1*}, 刘刚^{1,2}¹成都理工大学地球科学学院, 四川 成都 610059;²成都理工大学地质灾害防治与地质环境保护国家重点实验室, 四川 成都 610059

摘要 近年来,以卷积神经网络为代表的深度学习方法因不用进行复杂的数据预处理和特征设计逐渐成为高光谱图像分类领域的研究热点。在现有的神经网络模型基础上,结合高光谱图像数据特点,提出了一种注意力卷积神经网络模型。该模型通过残差结构构建深度卷积神经网络提取空谱特征,引入通道注意力机制对提取的特征进行重标定。根据特征重要性的不同,注意力机制对不同通道上的特征赋予不同的权重,突出重要特征,抑制次要特征,从而提高分类的精度。在两个公开的高光谱数据集 Indian Pines 和 Pavia University 上进行了实验。当数据集的空间邻域大小设置为 19×19 , Indian Pines 以 3:1:6 的比例划分样本, Pavia University 以 1:1:8 的比例划分样本时,数据集的分类精度最优,平均总体分类精度为 99.55%, 平均分类精度为 99.31%, 平均 Kappa 系数为 99.45%。实验结果表明,引入残差结构的深度卷积神经网络可以提取高光谱图像的深层空谱特征,注意力机制对特征进行重新标定,强化了重要特征,从而有效提高了高光谱图像的分类精度。

关键词 成像系统; 高光谱图像; 卷积神经网络; 残差结构; 注意力机制

中图分类号 TP751.1

文献标志码 A

DOI: 10.3788/LOP202259.1811001

Hyperspectral Image Classification Based on Convolution Neural Network with Attention Mechanism

Chen Wenhao¹, He Jing^{1*}, Liu Gang^{1,2}¹College of Earth Sciences, Chengdu University of Technology, Chengdu 610059, Sichuan, China;²State Key Laboratory of Geohazard Prevention and Geoenvironmental Protection, Chengdu University of Technology, Chengdu 610059, Sichuan, China

Abstract In recent years, convolutional neural network (CNN), as a representative of the deep learning method, has gradually become a research hotspot in the field of hyperspectral image (HSI) classification because it does not require complex data preprocessing and feature design. In this paper, a deep CNN model with an attention mechanism is proposed based on an existing neural network model combined with the HSI data characteristics. The model used a residual structure to construct a deep CNN to extract spatial-spectral features and introduced a channel attention mechanism to recalibrate the extracted features. According to different importance levels of features, the attention mechanism assigned different weights to features on different channels, highlighted important features, and controlled unimportant features. Experiments were conducted at Indian Pines and Pavia University to validate the proposed technique. When the spatial size of the dataset was 19×19 , the Indian Pines and Pavia University datasets were divided into 3:1:6 and 1:1:8, respectively. Additionally, these datasets have the best classification accuracy. The average overall accuracy, average accuracy, and average Kappa coefficient obtained are 99.55%, 99.31%, and 99.45%, respectively. The experimental results show that deep CNN with residual structure can extract high spatial-spectral features of the HSI. Additionally, the attention mechanism recalibrates the features to strengthen the important features, thereby effectively enhancing the HSI's classification accuracy.

Key words imaging systems; hyperspectral image; convolution neural network; residual structure; attention mechanism

收稿日期: 2021-05-31; 修回日期: 2021-07-08; 录用日期: 2021-07-20

基金项目: 国家自然科学基金(41871303, 41602355)、地质灾害防治与地质环境保护国家重点实验室项目(SKLG2018Z010)、四川省科技计划(2021YFG0365)、四川省自然资源厅(kj-2021-3)

通信作者: *xiao00yao@163.com

1 引言

高光谱图像通过成像光谱仪可以同时获取连续的空间信息和光谱信息,从而实现了图像和光谱的统一。早期的高光谱图像分类通常只利用了地物的光谱特征,没有深入挖掘图像内部的上下文信息。例如,随机森林^[1]、最近邻^[2]、支持向量机^[3-4]等,这些方法基本是从多光谱数据的应用中移植来的。面对高光谱数据光谱维的高维性有些不适用,在分类中容易受到 Hughes 现象的影响,即由于训练样本的限制,随着波段数的增加,分类结果的精度反而降低。针对这一问题,研究人员提出了一些降维处理方案,如主成分分析^[5]、独立成分分析^[6]、线性嵌入^[7]等。这些方法将高光谱原始图像压缩至低维空间,在一定程度上解决了高光谱图像高维和信息冗余的问题,但也损失了一些光谱信息。仅利用高光谱图像的光谱信息进行分类,容易造成地物空间上的不连续,产生“椒盐”现象,使分类结果达不到理想的效果。

后来,研究人员通过引入空间信息来改善高光谱分类的结果,比如条件随机场^[8]、形态学特征^[9-11]等。通过提取空间光谱联合特征,完美地发挥了高光谱图像“图谱合一”的优势,大大提高了高光谱图像的分类精度。但这些浅层分类器只能提取高光谱图像的浅层分类特征,对高光谱图像精度的提升有一定的局限性,近年来,以卷积神经网络(CNN)为代表的深度学习为高光谱图像分类提供了另一种途径。2015年,Hu等^[12]将CNN应用于高光谱图像分类,虽然只是用一维卷积在光谱维进行了特征提取,但分类的结果明显优于传统的浅层分类器分类的结果;然后,用二维卷积提

取空间信息的2D-CNN^[13-14]和用三维卷积提取空谱信息的3D-CNN^[15-16]被广泛应用于高光谱图像分类,并取得了不错的分类精度。在网络结构上,ResNet^[17-18]和DenseNet^[19]被用于高光谱图像分类中,搭建更深的网络,提取更高层次的空谱特征,进一步提高高光谱图像的分类精度。但是这些模型忽视了卷积核提取的不同特征对分类结果的重要程度,因为并不是所有的特征都对分类结果有所贡献,因此可以通过增益重要特征的方法来提高分类精度。

基于此,本文在现有神经网络的基础上,针对高光谱通道多的特点,提出了一种引入通道注意力机制Squeeze-and-Excitation(SE)模块^[20]的三维残差卷积神经网络(SE-ResNet)。所提网络以残差结构为骨干构建深层网络,用三维卷积提取低、中、高级空谱特征,在残差结构上嵌入SE模块对提取到的特征进行重标定,学习不同通道上特征的重要程度,并赋予不同的权重,突出重要特征,忽略次要特征,以提高分类精度。

2 卷积神经网络

2.1 卷积神经网络

卷积神经网络是指一种使用卷积操作的深度神经网络,其基本结构如图1所示,通常包含若干个卷积层、池化层和全连接层等。卷积层主要进行特征提取,利用卷积核的局部感受野感知局部信息,其后常加一个激活函数以增加输出值的非线性。池化层也叫下采样层,其主要作用是特征降维,提取显著特征,提高运算速度,避免过拟合。与传统的高光谱分类方法相比,卷积神经网络不用对高光谱图像进行复杂的数据预处理,可以直接将高光谱图像输入网络,进行特征学习,实现分类。

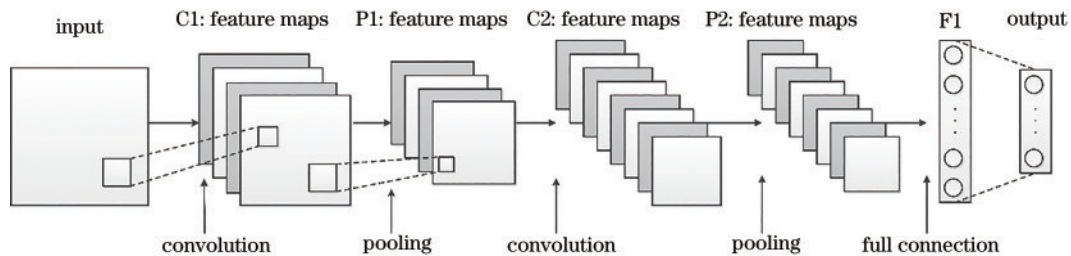


图1 卷积神经网络的基本结构

Fig. 1 Basic structure of convolutional neural network

2.2 残差结构

一般情况下,深层网络比浅层网络的效果好。但实际上深层网络很难训练,当网络搭建到一定的层数时会面临网络退化的问题,即深层结构的网络效果反而低于浅层结构。为了解决这一问题,文献[21]提出了残差结构,如图2所示。残差结构由跳跃连接实现。设 $H(x)$ 为网络期望学习到的目标函数,由几个堆叠层拟合, x 表示第1层的输入。残差结构引入恒等连接,将输入 x 传入输出中并作为下一层的输入,此时的目标函数 $F(x)=H(x)-x$,原来的函数 $H(x)=F$




图2 残差结构

Fig. 2 Residual structure

$(x)+x$ 。引入残差结构使网络不再学习一个完整的期望函数 $H(x)$, 而是学习输出与输入之间的差值 $F(x)$, 即残差。

2.3 注意力机制

注意力机制源于人类视觉系统的研究, 当人面对某一大型复杂场景时, 往往会重点关注颜色突兀或风格突变的区域, 而忽略其他的地方。计算机视觉中的注意力机制正是借鉴于此, 让网络根据当前任务从众多的信息中聚焦重要信息, 忽略不重要信息。目前, 注

意力机制可以分为通道注意力、空间注意力和自注意力, 其中 SE 模块是通道注意力方面的代表作, SE 模块的结构如图 3 所示。传统的神经网络在经过卷积操作后混合了空间和通道上的特征, 而 SE 模块则可以剥离这种混合, 使网络关注不同通道之间的特征关系。网络自己学习一组权重系数, 然后动态加权到每个特征通道上, 赋予每个特征通道不同的权重, 使网络自动学习到不同特征通道的重要程度, 从而突出重要特征, 抑制不重要特征。




图 3 SE 模块
Fig. 3 SE module

3 面向注意力机制的卷积神经网络高光光谱图像分类方法

3.1 注意力残差模块

通道注意力 SE 模块与残差结构的结合如图 4 所示。输入 X 经过一个残差单元输出 C 个大小为 $H \times H \times B$ 的特征图, 其中 C 为通道数, 并将特征图输入 SE 模块中进行特征重标定。SE 模块的操作主要包括压缩 (squeeze) 和激励 (excitation)。首先利用全局平均

池化对输入的特征图进行压缩, 将形状为 (H, H, B, C) 的特征图压缩为 $(1, 1, 1, C)$, 获取每个通道上的全局特征。然后进行激励操作获得不同通道之间的相关性, 这一步主要由两个全连接层完成, 第 1 个全连接层将 C 个通道压缩为 C/r 个通道, 减少参数量, 其中 r 为压缩比例, 激活函数 ReLU 增加特征的非线性。第 2 个全连接层恢复到 C 个通道, 激活函数 Sigmoid 用于学习每个通道的相关性, 并为每个特征通道生成不同的权重, 从而使得网络对各个通道的特征更有辨别能力。通过乘法加权的方式实现增益有用特征, 抑制无用特征的目的。最后输入 X 通过跳跃连接与 SE 模块的输出相加, 作为下一层的输入。

3.2 面向注意力机制的深度卷积神经网络 SE-ResNet

高光光谱图像具有丰富的光谱信息, 但波段之间相关性较强, 存在信息冗余。为了提取更具判别力的光谱特征, 需要搭建深层次的网络结构。但由于训练样本数量的限制, 为了防止过拟合和网络退化, 本实验组采用残差结构构建深度卷积神经网络。所提卷积神经网络结构如图 5 所示, 具体的操作过程如下:

1) 标定样本数据。以目标像素为中心, 提取 $S \times S \times B$ 的高光谱立方体作为样本数据, 其中 $S \times S$ 为空间邻域尺寸, B 表示图像的波段数量, 以 $S \times S \times B$ 作为模型的输入数据。

2) 提取特征。特征提取部分包括 1 个卷积层、2 个池化层和 2 个注意力残差模块 (包含 3 个卷积层)。所有的卷积层均使用 $3 \times 3 \times 3$ 大小的卷积核, 较小的卷积核可以避免输入信息的过度损失。卷积层中卷积核的个数按照 8、16、32 这样的比例设置, 即下一层卷积核为上一层的 2 倍, 注意力残差模块中的卷积核个数保持不变。激活函数使用 ReLU, 因为其在计算速度和收敛速度上具有很大的优势, 使用池化层对提取

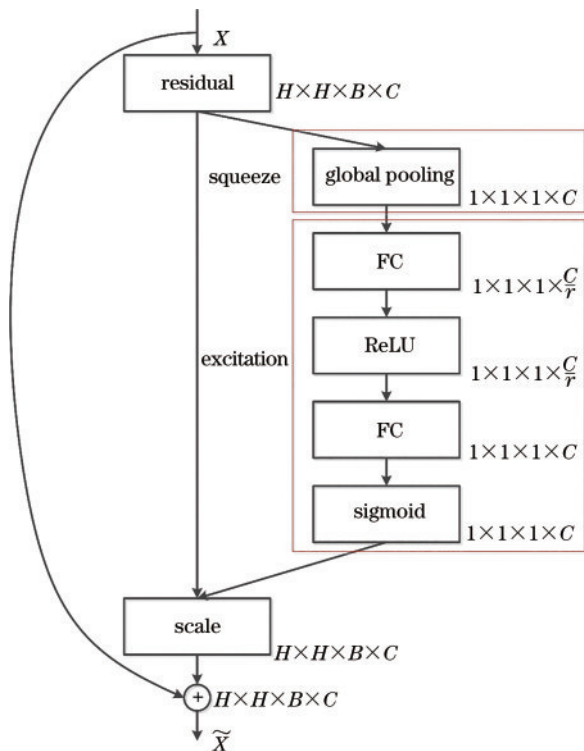


图 4 SE-Res 模块
Fig. 4 SE-Res block

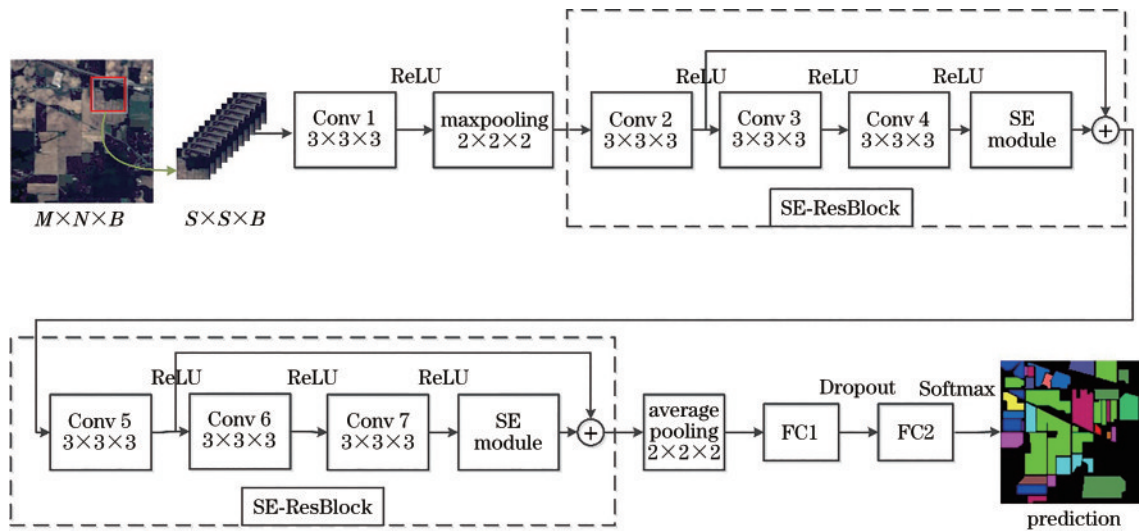


图 5 SE-ResNet 结构

Fig. 5 SE-ResNet structure

的特征进行整合,并提高训练速度。

3) 建立全连接层。平展平均池化层输出的特征,并通过全连接层(FC1)将三维特征立方体转换为 1×128 维的特征向量,使用 Dropout 正则化方法防止过拟合。

4) 构建分类层。使用 Softmax 激活函数作为分类函数,对输入的特征向量进行监督训练,实现高光谱图像分类。

4 实 验

4.1 数据集

为了评估所提方法的效果,在 Indian Pines 和 Pavia University 这两个公开高光谱数据集进行分类实验。Indian Pines 高光谱数据是 1992 年用 AVIRIS 成

像光谱仪在美国印第安纳州西北部的松树森林获取的影像中截取的一部分。未校正过的原始数据包含从 $0.4 \sim 2.5 \mu\text{m}$ 的 224 个连续光谱波段,校正后的数据保留下 200 个波段以供研究。该数据集的像素尺寸为 145×145 ,空间分辨率为 20 m,包含 16 类地物。Indian Pines 高光谱数据的假彩色图像如[图 6(a)]所示。Pavia University 高光谱数据是 2001 年由德国的 ROSIS-03 传感器在意大利的城市帕维亚所拍摄的,其中截取帕维亚大学区域作为高光谱图像分类研究。该数据集的像素大小为 610×340 ,空间分辨率为 1.3 m,成像波长范围为 $0.43 \sim 0.86 \mu\text{m}$,剔除受噪声影响的 12 个波段还保留有 103 个波段。Pavia University 数据集共包含 9 类地物。Pavia University 高光谱数据的假彩色图像如[图 6(b)]所示。




图 6 假彩色图像。(a) Indian Pines;(b) Pavia University

Fig. 6 False color images. (a) Indian Pines; (b) Pavia University

4.2 实验设计

实验所用硬件为 Intel i9-10900k 处理器、64 GB 内存和 NVIDIA GeForce RTX 3090 的 GPU,软件为基

于 python 的 TensorFlow 深度学习框架。在实验过程中,对 Indian Pines 数据集,采用 3:1:6 的比例划分为训练集、验证集和测试集。对 Pavia University 数据集,

采用 1:1:8 的比例划分为训练集、验证集和测试集。输入网络的样本空间邻域大小设置为 19×19 , 优化函数选择 Adam 优化器, 学习率设置为 0.001, 网络训练的最大迭代次数设置为 200。为减小计算量并加快网络训练速度, 两个高光谱的数据集均被归一化到 $[-1, +1]$ 之间。分类性能评价指标采用总体分类精度(OA)、平均分类精度(AA)和 Kappa 系数。

4.3 实验参数设置

4.3.1 压缩比例对分类结果的影响

SE 模块中的压缩比例 r 是一个很重要的超参数, 根据网络结构, 将压缩比例 r 的值设置为 4、8、16, 图 7 为在两个数据集上不同压缩比例 r 对应的总体分类精度。从图中可以看出, 当 $r=16$ 时, 网络在两个数据集上的总体分类精度最高, 故最终压缩比例 r 设置为 16。

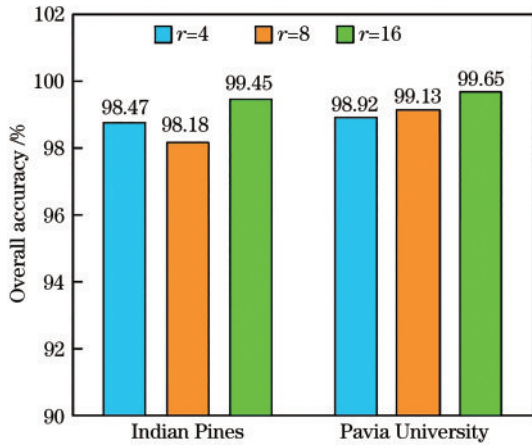


图 7 不同压缩比例对应的总体分类精度

Fig. 7 Overall accuracy of different reduction ratio

4.3.2 空间邻域大小对分类结果的影响

空间邻域大小会影响网络分类精度。空间邻域过小时, 无法提取充分的空间信息, 造成精度下降; 空间邻域过大会对小目标的空间特征提取造成影响。为了寻找合适的空间邻域大小, 根据网络结构, 将空间邻域设置为 13×13 、 15×15 、 17×17 、 19×19 和 21×21 。图 8 为 Indian Pines 和 Pavia University 数据集在不同

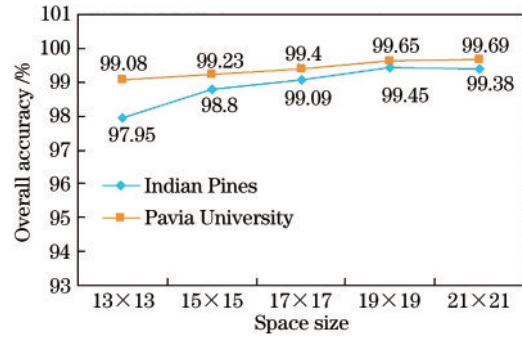


图 8 不同空间邻域大小对应的总体分类精度

Fig. 8 Overall accuracy of different space sizes

空间邻域上的总体分类精度。从图 8 可以看出, 随着空间尺寸的增大, 分类精度在逐渐提高, 但当 Indian Pines 的空间尺寸超过 19×19 时, 分类精度反而下降; 当 Pavia University 的空间尺寸为 21×21 时, 精度最高, 但对比其空间尺寸为 19×19 时的精度提升并不是很大。因此, 综合考虑训练时间和精度等因素, 最终的空间邻域大小设置为 19×19 。

4.3.3 样本规模大小对分类结果的影响

样本数量是另一个影响分类精度的因素。样本数量过少, 无法训练出一个性能优良的网络模型; 样本数量过多, 会造成模型训练时间过长。为了寻找最佳的样本比例, 保持验证集不变, 调整训练集和测试集的比例为 1:8、2:7、3:6、4:5。表 1 为 Indian Pines 和 Pavia University 数据集在不同样本比例下测试集的分类精度和训练时间, 图 9 为 Indian Pines 数据集在不同样本比例下的训练集和验证集的损失和准确率变化图。从表 1 可以看出, 随着训练样本的增多, 测试集的分类精度在不断提高, 但训练的时间也在增加。从图 9 可以看出, 对于 Indian Pines 数据集, 当训练集和测试集比例为 1:8 时, 训练集和验证集的损失和准确率曲线不稳定, 随着训练样本的增多, 训练集和验证集的损失和准确率曲线随着训练次数的增加逐渐平滑。综合各项指标因素, Indian Pines 数据集选择 3:1:6 的样本比例, Pavia University 数据集选择 1:1:8 的样本比例。

表 1 Indian Pines 和 Pavia University 数据集在不同样本比例下的分类精度和训练时间

Table 1 Classification accuracy and training time of Indian Pines and Pavia University datasets with different sample ratios

Sample ratio		1:1:8	2:1:7	3:1:6	4:1:5
Indian Pines	OA / %	95.20	98.43	99.45	99.61
	AA / %	93.20	97.14	99.18	99.23
	Kappa / %	94.52	98.20	99.37	99.55
	Train time / s	307.27	524.31	735.64	963.75
Pavia University	OA / %	99.65	99.89	99.93	99.85
	AA / %	99.44	99.80	99.88	99.64
	Kappa / %	99.53	99.85	99.91	99.80
	Train time / s	673.62	1147.15	1627.13	3922.04

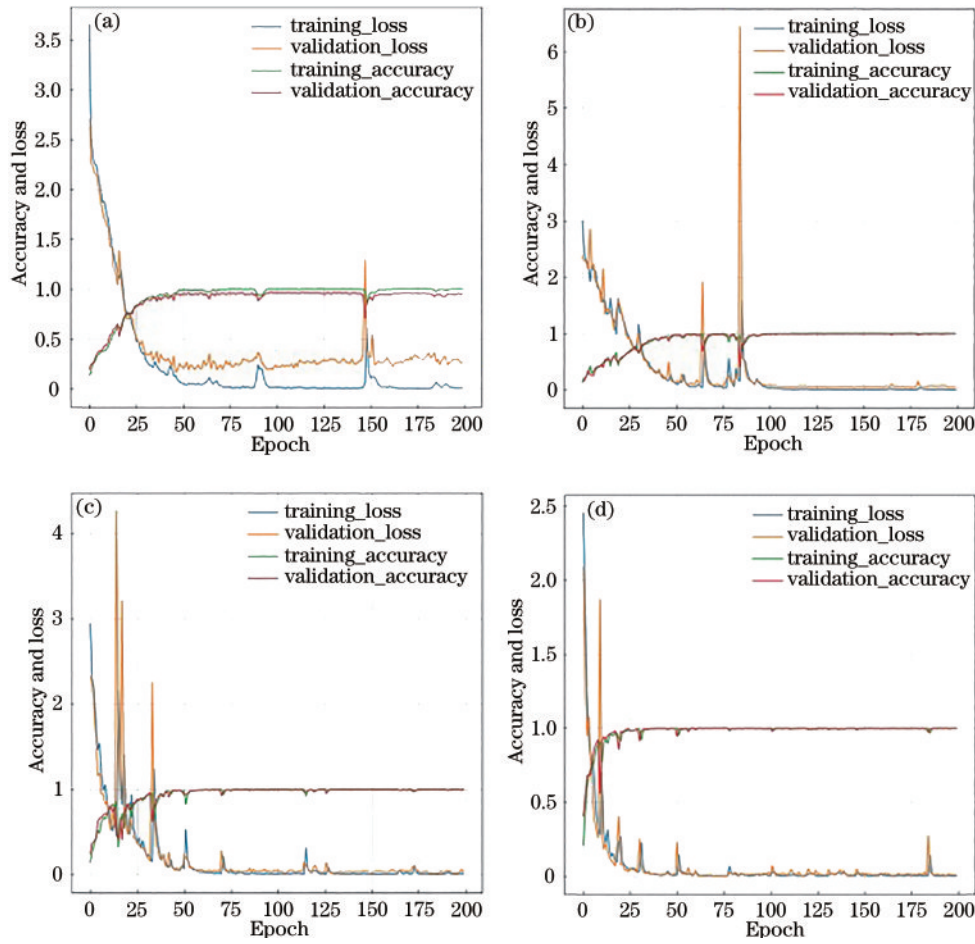


图9 Indian Pines 在不同样本比例下的训练和验证集的损失和准确率变化图。(a) 1:1:8;(b) 2:1:7;(c) 3:1:6;(d) 4:1:5
 Fig. 9 Loss and accuracy of training and validation sets of Indian Pines with different sample ratios. (a) 1:1:8; (b) 2:1:7; (c) 3:1:6; (d) 4:1:5

4.4 实验结果及分析

为验证所提 SE-ResNet 的分类精度, 分别与 SVM、2D-CNN^[22]、3D-CNN 和未加入 SE 模块的网络结构相同的 ResNet 进行了对比分析, 其中 SVM 选择 python 的 sklearn 库中的 RBF 方法, 实验参数通过多次实验选择分类结果最好的一种。3D-CNN 包含三个卷积层和两个池化层, 其他参数设置与本实验保持一致。

表 2 为不同方法在 Indian Pines 和 Pavia University 数据集上的分类精度。SVM 仅使用光谱特征进行分类, 2D-CNN 加入了空间特征, 所以 2D-CNN 的总体分类精度明显好于 SVM。3D-CNN、ResNet 使用三维卷

积直接对高光谱数据进行空谱特征提取, 无需降维处理, 与 2D-CNN 相比, 总体分类精度有所提高。加入注意力机制后, 对于 Indian Pines 数据集和 Pavia University 数据集, 平均分类精度都较无注意力机制的 ResNet 提高了大约 1 个百分点。因此, 注意力机制的加入可以改善高光谱图像的分类结果。

图 10 和图 11 分别为不同方法在 Indian Pines 和 Pavia University 数据集上的分类结果图。从图中可以看出: 仅使用光谱特征进行分类的 SVM 方法的结果图上明显存在“椒盐”现象, 噪声较多; 加入空间信息的 2D-CNN 则优化了这个现象, 但还有明显的错分现象;

表 2 Indian Pines 和 Pavia University 数据集上的分类精度
 Table 2 Classification accuracy of Indian Pines and Pavia University datasets

unit: %

Method	SVM	2D-CNN	3D-CNN	ResNet	SE-ResNet	
Indian Pine	OA / %	91.49	95.76	98.33	98.23	99.45
	AA / %	90.13	96.23	96.37	98.01	99.18
	Kappa / %	90.29	95.16	98.09	97.98	99.37
Pavia University	OA / %	94.45	97.38	98.15	98.90	99.65
	AA / %	92.74	96.70	97.10	98.31	99.44
	Kappa / %	92.62	96.53	97.55	98.54	99.53




图 10 Indian Pines 数据集上的分类结果图。(a) Ground truth; (b) SVM; (c) 2D-CNN; (d) 3D-CNN; (e) ResNet; (f) SE-ResNet

Fig. 10 Classification maps for Indian Pines. (a) Ground truth; (b) SVM; (c) 2D-CNN; (d) 3D-CNN; (e) ResNet; (f) SE-ResNet




图 11 Pavia University 数据集上的分类结果图。(a) Ground truth; (b) SVM; (c) 2D-CNN; (d) 3D-CNN; (e) ResNet; (f) SE-ResNet

Fig. 11 Classification maps for Pavia University. (a) Ground truth; (b) SVM; (c) 2D-CNN; (d) 3D-CNN; (e) ResNet; (f) SE-ResNet

使用三维卷积的 3D-CNN、ResNet 和 SE-ResNet 能够进一步降低这种错分现象,其中对于特征相近的地物,SE-ResNet 更能区分出这类地物。

5 结 论

高光谱图像蕴含丰富的空间信息和光谱信息,普通的基于光谱信息的高光谱分类方法未利用高光谱图像的空间信息,造成分类精度不高,易出现“椒盐”现象。基于深度学习方法的 2D-CNN 虽利用了高光谱图像的空间信息,但在数据预处理部分需要经过光谱降维,这在一定程度上损失了一些光谱信息,虽然精度有所提升,但没有充分利用高光谱图像的光谱优势。3D-CNN 由于网络层数的限制,没有提取丰富的、深层的空谱特征。为了提取丰富的、深层的空谱特征,本实验组参考已有的神经网络,设计了一种基于注意力机制的残差卷积神经网络(SE-ResNet)进行高光谱图像分类,与其他分类网络相比,SE-ResNet 在 Indian Pines 数据集上总体分类精度达到了 99.45%,在 Pavia University 数据集上总体分类精度达到了 99.65%。与未加入注意力机制的 ResNet 相比,SE-ResNet 在区别特征相近的地物上更有优势。SE-ResNet 与其他网络相比虽然在分类结果上取得了一些不错的进步,但也存在一些不足,在后续的研究中,将进一步改进网络结构,提取更具有判别力的空谱特征并使用更少的样本使模型达到不错的分类精度。

参 考 文 献

[1] Wang A L, Wang Y, Chen Y S. Hyperspectral image

classification based on convolutional neural network and random forest[J]. *Remote Sensing Letters*, 2019, 10(11): 1086-1094.

[2] Bo C J, Lu H C, Wang D. Spectral-spatial K-Nearest neighbor approach for hyperspectral image classification [J]. *Multimedia Tools and Applications*, 2018, 77(9): 10419-10436.

[3] 赵春晖, 齐滨, 张焱. 基于改进型相关向量机的高光谱图像分类[J]. *光学学报*, 2012, 32(8): 0828004.

Zhao C H, Qi B, Zhang Y. Hyperspectral image classification based on variational relevance vector machine[J]. *Acta Optica Sinica*, 2012, 32(8): 0828004.

[4] Guo Y H, Yin X J, Zhao X C, et al. Hyperspectral image classification with SVM and guided filter[J]. *EURASIP Journal on Wireless Communications and Networking*, 2019, 2019: 56.

[5] 叶珍, 白璘. 基于主成分分析与局部二值模式的高光谱图像分类[J]. *激光与光电子学进展*, 2017, 54(11): 111006.

Ye Z, Bai L. Hyperspectral image classification based on principal component analysis and local binary patterns[J]. *Laser & Optoelectronics Progress*, 2017, 54(11): 111006.

[6] Zaatour R, Bouzidi S, Zagrouba E. Independent component analysis-based band selection techniques for hyperspectral images analysis[J]. *Journal of Applied Remote Sensing*, 2017, 11: 026006.

[7] 马世欣, 刘春桐, 李洪才, 等. 基于线性嵌入和张量流形的高光谱特征提取[J]. *光学学报*, 2019, 39(4): 0412001.

Ma S X, Liu C T, Li H C, et al. Feature extraction based on linear embedding and tensor manifold for hyperspectral image[J]. *Acta Optica Sinica*, 2019, 39(4): 0412001.

[8] 魏立飞, 余铭, 钟燕飞, 等. 空-谱融合的条件随机场高

- 光谱影像分类方法[J]. 测绘学报, 2020, 49(3): 343-354.
- Wei L F, Yu M, Zhong Y F, et al. Hyperspectral image classification method based on space-spectral fusion conditional random field[J]. *Acta Geodaetica et Cartographica Sinica*, 2020, 49(3): 343-354.
- [9] 胡轩, 卢其楷. 基于显著性剖面的高光谱图像分类算法[J]. 光学学报, 2020, 40(16): 1611001.
- Hu X, Lu Q K. Hyperspectral image classification algorithm based on saliency profile[J]. *Acta Optica Sinica*, 2020, 40(16): 1611001.
- [10] Fauvel M, Benediktsson J A, Chanussot J, et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(11): 3804-3814.
- [11] Benediktsson J A, Palmason J A, Sveinsson J R. Classification of hyperspectral data from urban areas based on extended morphological profiles[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(3): 480-491.
- [12] Hu W, Huang Y Y, Wei L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. *Journal of Sensors*, 2015, 2015: 258619.
- [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, July 26-31, 2015, Milan, Italy. New York: IEEE Press, 2015: 4959-4962.
- [14] 胡丽, 单锐, 王芳, 等. 基于双通道空洞卷积神经网络的高光谱图像分类[J]. 激光与光电子学进展, 2020, 57(12): 122803.
- Hu L, Shan R, Wang F, et al. Hyperspectral image classification based on dual-channel dilated convolution neural network[J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 122803.
- [15] Li Y, Zhang H K, Shen Q. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network[J]. *Remote Sensing*, 2017, 9(1): 67.
- [16] 张明华, 邹亚晴, 宋巍, 等. GGCN: 基于 GPU 的高光谱图像分类算法[J]. 激光与光电子学进展, 2020, 57(20): 201101.
- Zhang M H, Zou Y Q, Song W, et al. GGCN: GPU-based hyperspectral image classification algorithm[J]. *Laser & Optoelectronics Progress*, 2020, 57(20): 201101.
- [17] 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.
- [18] 张祥东, 王腾军, 杨耘. 基于多尺度残差网络的小样本高光谱图像分类[J]. 激光与光电子学进展, 2020, 57(16): 162801.
- Zhang X D, Wang T J, Yang Y. Classification of small-sized sample hyperspectral images based on multi-scale residual network[J]. *Laser & Optoelectronics Progress*, 2020, 57(16): 162801.
- [19] Zhang C J, Li G D, Du S H, et al. Three-dimensional densely connected convolutional network for hyperspectral remote sensing image classification[J]. *Journal of Applied Remote Sensing*, 2019, 13(1): 016519.
- [20] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(8): 2011-2023.
- [21] 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.
- [22] 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.