

基于混合卷积网络的高分辨率高光谱图像分类研究

沈柄志, 聂若梅, 蒋海鹏, 杨智帅, 宋铭睿, 陈思琪, 李鑫伟*

北京林业大学理学院, 北京 100083

摘要 传统卷积神经网络模型未能充分利用高分辨率高光谱图像中丰富的空间-光谱信息, 存在计算成本大、小样本数据分类精度低的问题。提出一种轻量化多尺度金字塔混合池化混合卷积模型。以混合卷积网络为基础, 所提模型采用改进的金字塔池化模块增强对空间-光谱特征的提取能力, 使用较少的卷积层和深度可分离卷积, 并用全局平均池化层代替部分全连接层以实现卷积层到全连接层的过渡, 显著降低了参数量。采用三个高分辨率高光谱数据集对所提方法进行测试, 同时与经典高光谱图像分类方法进行对比实验, 结果表明所提方法在分辨率高、地物种类多、边界复杂的情况下仍然能取得最佳的分类结果。在 WHU-Hi-LongKou、WHU-Hi-HanChuan、WHU-Hi-HongHu 数据集上仅使用 1%、2%、2% 训练样本的情况下, 所提方法的总体精度分别达 99.12%、98.43%、98.84%, 优于传统卷积网络, 证明了所提模型计算成本小, 在小样本问题上准确率高, 能很好地适用于高分辨率高光谱数据集。

关键词 遥感; 高光谱图像分类; 混合卷积网络; 混合池化; 特征融合; 高分辨率

中图分类号 TP751

文献标志码 A

DOI: 10.3788/LOP202259.2428006

High-Resolution Hyperspectral Image Classification Based on Hybrid Convolutional Network

Shen Bingzhi, Nie Ruomei, Jiang Haipeng, Yang Zhishuai, Song Mingrui, Chen Siqi,

Li Xinwei*

College of Science, Beijing Forestry University, Beijing 100083, China

Abstract Traditional convolutional neural network models fail to fully utilize the rich spatial-spectral information in high-resolution hyperspectral images, and have the problems of high computational cost and low classification accuracy for small sample data. This study proposes a lightweight multiscale pyramid hybrid pooling hybrid convolution model. Based on the hybrid convolution network, the proposed model uses an improved pyramid pooling module to enhance the ability to extract spatial-spectral features, uses fewer convolution layers and depth separable convolution, and uses the global average pooling layer to replace a part of the full connection layer to achieve the transition from the convolution layer to the full connection layer, significantly reducing number of parameters. In this study, the proposed method is tested on three high-resolution hyperspectral datasets and compared with classical hyperspectral image classification methods. The results show that the proposed method can achieve the best classification results under high-resolution conditions, multiple ground object types, and complex boundaries. The overall accuracy of the proposed method on WHU-Hi-LongKou, WHU-Hi-HanChuan, and WHU-Hi-HongHu datasets are 99.12%, 98.43%, and 98.84%, respectively, when only 1%, 2%, and 2% training samples are used, which is superior to that of the traditional convolutional networks. It is proved that the model proposed in this study has a low computational cost, high accuracy for small sample problems, and can be well applied to high-resolution hyperspectral datasets.

Key words remote sensing; hyperspectral image classification; hybrid convolutional network; hybrid pooling; feature fusion; high resolution

1 引言

高光谱成像技术可以收集数十到数百个波段丰富

的光谱信息。高光谱遥感利用许多电磁波获取被测物体相关数据^[1], 是当前遥感技术的前沿领域^[2]。高光谱图像由地表图像信息和光谱信息结合而成, 具有光谱

收稿日期: 2022-01-20; 修回日期: 2022-01-25; 录用日期: 2022-01-28

基金项目: 中央高等学校基本科研业务费项目(BLX201610)、北京林业大学“北京市大学生科学研究与创业行动计划”(S202110022147)

通信作者: *xwli_1989@163.com

信息量大、纳米级光谱分辨率、图谱合一等优点。利用深度学习技术对成像光谱仪与飞行器、卫星结合所获取的高光谱图像进行分类已成为新兴的研究领域。高光谱图像分类技术已经广泛应用于农林业^[3]、自然保护^[4]、矿业^[5]、环境科学^[6]、生物威胁检测^[7]等领域。

近年来,随着深度学习技术的迅速发展,高光谱图像分类在方法和性能上得到了突破性进展,与传统的机器学习方法如支持向量机(SVM)和随机森林(RF)等相比,分类精度有了较大提升,在特征提取方面展现了显著优势。基于深度学习的高光谱图像分类方法常使用卷积神经网络(CNN)进行特征提取。1D-CNN^[8]注重图像的光谱特征,缺乏对空间信息的关注。2D-CNN^[9]在特征提取时缺乏对光谱信息的关注,因此在复杂场景下的分类性能不佳。Lee等^[10]提出了带有残差连接的2D-CNN(Res-2D-CNN),增大了网络深度,提升了分类精度。3D-CNN^[11]相比之下精度较高,但在数据量增大的情况下计算成本较大,同时模型特征提取能力不足,在复杂区域错误分类现象较多。Chen等^[12]使用基于3D-CNN的模型提取光谱信息和空间信息,采用L2正则化和Drop out来处理训练样本有限导致的过拟合问题。充分的特征提取有利于提升对高光谱图像的分类精度^[13],但传统的2D-CNN、3D-CNN不能充分融合空间特征和光谱特征。

目前CNN存在多种改进方法。注意力机制能让网络关注更重要的空间-光谱特征^[14],进而抑制噪声和冗余信息,提升特征提取能力。颜铭靖等^[15]为解决高光谱图像数据量较大的问题,引入了空洞卷积结构,在不增加网络参数量的情况下提升了光谱特征提取能力。Zhong等^[16]提出的CNNCRF框架利用条件随机场(CRF)在提取深度光谱特征和局部空间特征的基础上进一步融合空间上下文信息,改善了分类图中空洞和非连片区域的问题,同时采用虚拟样本增强技术解决了标记样本有限的问题。Zhong等^[17]设计了一个端到端的空谱残差网络(SSRN)来提取空间特征和光谱特征,进一步利用了空间-光谱联合信息,提升了模型的特征提取能力。魏祥坡等^[18]将残差密集单元提取的密集特征与浅层特征相加,实现了对分层特征的融合。Gao等^[19]使用深度可分离卷积降低了网络参数量。章文^[20]深入研究了深度可分离卷积在轻量化高光谱图像分类方法中的作用。Roy等^[21]提出的混合卷积网络(HybridSN)首先利用3D-CNN在三维空间提取空间-光谱联合信息,其次利用2D-CNN进一步提取高光谱图像中更加抽象的空间信息,在保持分类精度的同时大幅度提高了计算效率并降低了模型的复杂性。该方法在Indian Pines等数据集上获得了优秀的分类效果,但对多尺度特征和纹理信息的利用还不够充分,特征融合能力有待提升,在复杂区域和小样本问题上还有进一步改进的空间。

基于深度学习的分类方法通常需要大量样本来学

习参数,然而对高光谱数据集进行标记需花费大量的成本,这导致高光谱图像数据集的标记比例通常较低,因此优化小样本问题变得尤为重要。研究者往往通过优化网络结构,提升模型的特征提取能力,进而提升模型在小样本数据上的表现。如Gong等^[22]提出多尺度激励挤压金字塔池化模型(MSPN),提升了在小样本问题上的分类精度和泛化能力,并使用全局平均池化层代替全连接层,降低了模型参数量。冯凡等^[23]提出M-HybridSN模型,利用特征图连接和逐像素相加两种方式进行多特征融合,使得网络能对高光谱数据中的复杂特征进行更高效的学习,提高了对小样本情况的分类效果。刘金香等^[24]提出的融合3D-2D-1D-CNN模型对不同维度的CNN进行有机融合,充分利用了高光谱的空间-光谱联合特征,提高了模型的适用性。另一方面,现有的高光谱数据集,如Indian Pines等,存在空间分辨率低、像素标记比例低、类别精细度低等问题。这些缺点限制了对地面目标进行精细分类的进一步研究。最近的无人机高光谱数据集相比以往常用数据集在空间分辨率和光谱分辨率上都有了较大提升,如武汉大学无人机高光谱数据集(WHU-Hi Dataset)^[16,25]具有小于0.5 m的空间分辨率和更多的波段数量。WHU-Hi Dataset是一个较新的高光谱数据集,其中包含三个独立的数据集,分别在湖北省的洪湖市龙口镇、汉川市和洪湖市采集。该数据集具有极高的空间分辨率和像素标记比例以及丰富的地物类型。传统2D-3D-CNN模型往往使用单一大小的卷积核和池化层,提取特征尺度单一、缺乏对不同尺度特征的融合提取、空间上下文信息利用不足、泛化能力较差、参数量大,因此在对WHU-Hi Dataset进行分类时存在训练时间长、过拟合、小样本条件下分类精度低的问题。

为了解决以上问题,本文在混合卷积网络^[21]和多尺度金字塔池化网络^[22,26]的基础上进行改进,提出了一种多尺度金字塔混合池化混合卷积模型。该模型结合最大值池化与均值池化的优点,提出多尺度混合池化模块,在提取多尺度特征的同时有效降低了计算复杂度。模块中的跳过连接缓解了细节丢失问题,通过浅层与深层的特征融合得到高维多尺度特征,有助于提升模型在小样本条件下的分类精度。另外,本研究通过使用更少的卷积层和深度可分离卷积,降低了模型参数量,提高了模型训练速度。

2 基本原理

2.1 轻量化多尺度金字塔池化混合卷积网络

图1为所提轻量化多尺度金字塔混合池化混合卷积网络(LHHN)。首先,利用主成分分析法对数据的光谱维度进行降维,在保留主要光谱信息的同时降低计算量。网络包含两个3D卷积层,用于提取空间-光谱联合特征。2D深度可分离卷积可进一步提取空间

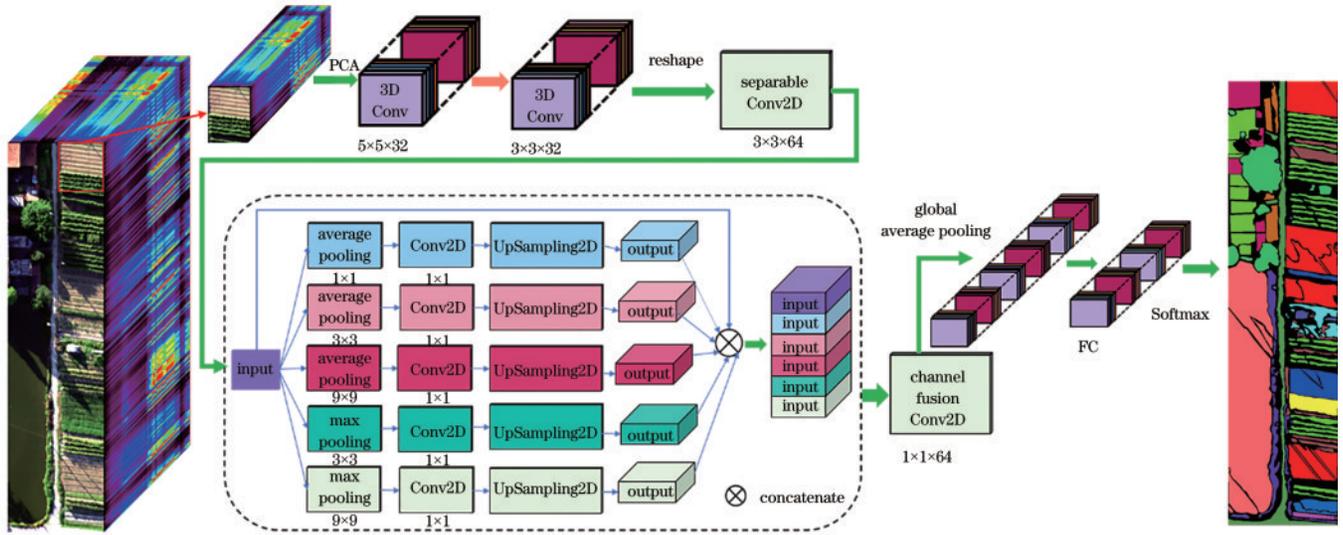


图1 轻量化多尺度金字塔混合池化混合卷积网络示意图

Fig. 1 Schematic of lightweight multi-scale pyramid hybrid pooling hybrid convolution network

特征并降低参数量。混合池化模块可以提取空间信息并融合多尺度特征。使用 1×1 大小的2D卷积核整合通道信息,并降低通道数量,再次降低了计算成本。用全局平均池化代替部分全连接层,显著降低了计算量,最后通过Softmax函数输出分类结果。

2.2 深度可分离卷积

Howard等^[27]在Mobile Net中引入了深度可分离卷积,把常规卷积分解成逐深度卷积(depthwise convolution)和逐点卷积(pointwise convolution)。得益于能够大幅降低参数量和计算量的优点,深度可分离卷积广泛应用于轻量化网络中。为了应对高分辨率图像带来的计算量大的问题,在3D-CNN后引入了2D深度可分离卷积。

2.3 金字塔混合池化模块

金字塔池化模块^[26]在语义分割领域展现了优异的性能,Gong等^[22]证明了金字塔池化模块在高光谱图像分类上的有效性。该模块克服了传统特征融合与池化方式在多尺度特征提取上的局限性。该模块首先对输入图像进行不同尺度的池化,进而得到多尺度的特征图;之后使用 1×1 卷积将通道维度降为原来的 $1/N$,再对降维后的特征图进行基于双线性插值的上采样操作,可将图像恢复为原来的大小;其次再对多尺度特征图与输入进行拼接,最终得到具有多尺度信息的特征图。多尺度池化层可以增大模型感受野,融合不同尺度区域的特征,进而充分地提取和融合高分辨率高光谱图像中丰富的局部细节信息和全局信息。模块中的跳过连接缓解了细节丢失,最终与原始特征图融合得到高维多尺度特征^[26]。

均值池化能够在降维时保留图像的空间上下文信息^[22,26],而最大值池化可以减少无关信息干扰,更多关注图像的纹理信息。为了弥补单独使用最大值池化和均值池化的缺点,本文对金字塔池化模块进行改进,提

出了由3个均值池化层和2个最大值池化层组成的金字塔混合池化模块,使用两种不同的池化层来更加充分地提取高光谱图像的丰富信息,进而提升模型在小样本条件和复杂区域上的表现。

2.4 全局平均池化

传统卷积网络通常在末端使用全连接层级联Softmax函数得到分类结果,但是全连接层的参数量庞大,且容易出现过拟合现象,从而影响网络的泛化能力。Lin等^[28]使用全局平均池化层代替全连接层,将池化后得到的特征向量直接输入Softmax层。此方法可以缓解全连接层造成的过拟合,同时增加模型对图像空间变化的鲁棒性。Gong等^[22]验证了该方法在高光谱图像分类上的有效性。本文采取与GoogLeNet^[29]相同的操作,在网络最后保留了一个全连接层。

3 实验结果与分析

3.1 实验数据及训练样本设置

为了验证所提模型的有效性,采用武汉大学新开源的高分辨率高光谱数据集WHU-Hi Dataset^[16,25]对模型进行测试和对比实验。WHU-Hi Dataset可作为作物精确分类和高光谱图像分类研究的基准数据集(http://rsidea.whu.edu.cn/resource_WHUHi_sharing.htm)。WHU-Hi Dataset包含WHU-Hi-LongKou、WHU-Hi-HanChuan、WHU-Hi-HongHu三个数据集。

WHU-Hi-LongKou数据集于2018年7月在中国湖北省洪湖市龙口镇采集,主要有农作物、水、道路、房屋等9种地物;空间分辨率约为0.463 m,图像尺寸为 550×400 像素,有270个波段。WHU-Hi-HanChuan数据集于2016年6月在中国湖北省汉川市采集,图像中有很多阴影覆盖的区域,有草莓、豇豆、大豆、高粱、菠菜等共16种地物;空间分辨率约为0.109 m,图像大小为 1217×303 像素,共274个波段。WHU-Hi-

HongHu 数据集于 2017 年在中国湖北省洪湖市采集, 在数据采集过程中天气多云; 研究区是典型的受土地破碎化影响的区域, 种植棉花、油菜、卷心菜等 17 种作物, 共有 22 种地物; 该地区有同一作物类型的不同品种, 如大白菜和小芸苔; 空间分辨率约为 0.043 m, 图

像尺寸为 940×475 像素, 有 270 个波段。

对于 WHU-Hi-LongKou、WHU-Hi-HanChuan、WHU-Hi-HongHu 数据集, 训练样本分别占标记总样本数的 1%、2%、2%, 所占比例均未超过 2%, 可以代表小样本的分类问题, 详细信息如表 1~3 所示。

表 1 WHU-Hi-LongKou 数据集的分类信息

Table 1 Class information of the WHU-Hi-LongKou dataset

| No. | Class name | Number of training samples | Number of test samples | No. | Class name | Number of training samples | Number of test samples |
|-----|---------------------|----------------------------|------------------------|-----|------------------|----------------------------|------------------------|
| C1 | Corn | 345 | 34166 | C6 | Rice | 119 | 11735 |
| C2 | Cotton | 84 | 8290 | C7 | Water | 670 | 66386 |
| C3 | Sesame | 30 | 3001 | C8 | Roads and houses | 71 | 7053 |
| C4 | Broad-leaf soybean | 632 | 62580 | C9 | Mixed weed | 52 | 5177 |
| C5 | Narrow-leaf soybean | 42 | 4109 | | | | |

表 2 WHU-Hi-HanChuan 数据集的分类信息

Table 2 Class information of the WHU-Hi-HanChuan dataset

| No. | Class name | Number of training samples | Number of test samples | No. | Class name | Number of training samples | Number of test samples |
|-----|---------------|----------------------------|------------------------|-----|---------------|----------------------------|------------------------|
| C1 | Strawberry | 895 | 43840 | C9 | Grass | 189 | 9280 |
| C2 | Cowpea | 455 | 22298 | C10 | Red roof | 210 | 10306 |
| C3 | Soybean | 206 | 10081 | C11 | Gray roof | 338 | 16593 |
| C4 | Sorghum | 107 | 5246 | C12 | Plastic | 74 | 3605 |
| C5 | Water spinach | 24 | 1176 | C13 | Bare soil | 182 | 8934 |
| C6 | Watermelon | 91 | 4442 | C14 | Road | 371 | 18189 |
| C7 | Greens | 118 | 5785 | C15 | Bright object | 23 | 1113 |
| C8 | Trees | 359 | 17619 | C16 | Water | 1508 | 73893 |

表 3 WHU-Hi-HongHu 数据集的分类信息

Table 3 Class information of the WHU-Hi-HongHu dataset

| No. | Class name | Number of training samples | Number of test samples | No. | Class name | Number of training samples | Number of test samples |
|-----|------------------------|----------------------------|------------------------|-----|--------------------------|----------------------------|------------------------|
| C1 | Red roof | 281 | 13760 | C12 | Brassica chinensis | 179 | 8775 |
| C2 | Road | 70 | 3442 | C13 | Small Brassica chinensis | 450 | 22057 |
| C3 | Bare soil | 437 | 21384 | C14 | Lactuca sativa | 147 | 7209 |
| C4 | Cotton | 3265 | 160020 | C15 | Celtuce | 20 | 982 |
| C5 | Cotton firewood | 124 | 6094 | C16 | Film covered lettuce | 145 | 7117 |
| C6 | Rape | 891 | 43666 | C17 | Romaine lettuce | 60 | 2950 |
| C7 | Chinese cabbage | 482 | 23621 | C18 | Carrot | 64 | 3153 |
| C8 | Pakchoi | 81 | 3973 | C19 | White radish | 174 | 8538 |
| C9 | Cabbage | 217 | 10602 | C20 | Garlic sprout | 70 | 3416 |
| C10 | Tuber mustard | 248 | 12146 | C21 | Broad bean | 27 | 1301 |
| C11 | Brassica parachinensis | 220 | 10795 | C22 | Tree | 81 | 3959 |

3.2 实验环境及参数

所提方法在 Ubuntu 系统上通过采用 Keras 框架实现, 对比方法 Res-2D-CNN^[10]和 3D-CNN^[12]在 PyTorch 框架下采用开源项目 <https://github.com/eecn/>

Hyperspectral-Classification 进行, HybridSN^[21]采用 <https://github.com/gokriznastic/HybridSN> 进行。硬件环境为 CPU Intel(R) Xeon(R) CPU E5-2678 v3 @ 2.50 GHz, GPU NVIDIA GeForce RTX 2080 Ti, 运行

内存为 62 GB。所提方法和 HybridSN 在预处理中使用主成分分析进行降维,主成分个数为 30,使用 Adam 优化器,学习率为 0.001。对比实验方法采用对应文献中的默认参数。所有方法的训练轮数均为 50,输入数据的图片大小均为 17×17 。

表 4 给出了不同模型在输入数据空间大小为 17×17 时的参数量,可以看出所提模型在参数量上具有显著优势。

表 4 不同模型的参数量

Table 4 Number of parameters of different models

| Parameter | Res-2D-CNN | 3D-CNN | HybridSN | LHH |
|----------------------|------------|---------|----------|-------|
| Number of parameters | 479114 | 1299306 | 1715078 | 11443 |
| | | | | 8 |

3.3 实验结果

选取总体精度(OA)、平均精度(AA)、Kappa 系数作为模型分类性能的评价指标。表 5~7 分别为不同方法在 WHU-Hi-LongKou、WHU-Hi-HanChuan、WHU-

Hi-HongHu 数据集上的分类精度比较。图 2~4 分别为在 WHU-Hi-LongKou、WHU-Hi-HanChuan、WHU-Hi-HongHu 数据集上真实图像和不同模型分类结果。从表 5~7 可以看出:所提方法在 WHU-Hi-LongKou、WHU-Hi-HanChuan、WHU-Hi-HongHu 三个数据集上(使用 1%、2%、2% 训练样本)的 OA 分别为 99.12%、98.43%、98.84%,与 Res-2D-CNN 方法相比分别提高了 14.16 个百分点、16.27 个百分点、11.10 个百分点,表明所提模型能更好地利用高分辨率光谱数据集的信息,在小样本问题上具有优良性能。LHHN 模型在 WHU-Hi-LongKou 数据集上的精度和 HybridSN 模型接近,但是由于用全局平均池化层代替了部分全连接层以及使用更少的 3D 卷积层,LHHN 具有更短的训练时间,从表 5 可以看出所提模型在 WHU-Hi-LongKou 数据集上的整体训练时间较 Res-2D-CNN、3D-CNN、HybridSN 分别减少 142.12 s、808.62 s、25.8 s。所提模型在 WHU-Hi-LongKou 和 WHU-Hi-HongHu 数据集上都具有最短的训练时间,结果表明所提模型可有效缓解高分辨率高光谱数据集带来的计算量大的问题。

表 5 不同方法对 WHU-Hi-LongKou 数据集(1% 训练样本)的分类精度

Table 5 Classification accuracy of different methods on WHU-Hi-LongKou dataset(1% samples)

| No. | Class | Accuracy / % | | | |
|---------------------|----------------------|--------------|--------|----------|-------|
| | | Res-2D-CNN | 3D-CNN | HybridSN | LHHN |
| C1 | Corn | 64.88 | 71.92 | 99.79 | 99.72 |
| C2 | Cotton | 47.50 | 50.14 | 95.55 | 98.41 |
| C3 | Sesame | 54.98 | 0 | 96.07 | 99.49 |
| C4 | Broad-leaf soybean | 86.03 | 88.94 | 99.42 | 99.59 |
| C5 | Narrow-leaf soybeans | 25.21 | 33.33 | 91.58 | 98.38 |
| C6 | Rice | 72.07 | 43.91 | 99.57 | 99.84 |
| C7 | Water | 99.93 | 99.59 | 99.91 | 99.90 |
| C8 | Roads and houses | 86.35 | 72.42 | 95.04 | 92.53 |
| C9 | Mixed weed | 50.74 | 85.53 | 96.01 | 96.55 |
| Training time / s | | 171.49 | 837.99 | 55.17 | 29.37 |
| Predicting time / s | | 247.11 | 736.40 | 22.27 | 25.10 |
| OA / % | | 84.96 | 79.13 | 99.03 | 99.12 |
| Kappa / % | | 80.00 | 73.00 | 98.72 | 99.33 |
| AA / % | | 55.76 | 45.26 | 96.03 | 97.76 |

图 2~4 表明分类错误往往集中在地物样本较少、地物分布不均和边界复杂的区域,Res-2D-CNN、3D-CNN 等方法由于缺乏对纹理特征和多尺度信息的关注,因此在这些区域的分类效果并不理想。WHU-Hi-HanChuan 和 WHU-Hi-HongHu 数据集分别具有 16、22 种地物类型,与 WHU-Hi-LongKou 数据集的 9 种相比地物种类有较大增加;同时由图 3 和图 4 可知 WHU-Hi-HanChuan 和 WHU-Hi-HongHu 数据集具有更加复

杂的地物种类、边界和区域分布。在 WHU-Hi-HanChuan 和 WHU-Hi-HongHu 数据集上,LHHN 模型的 OA 较 HybridSN 分别提升了 0.74 个百分点和 1.14 个百分点,说明了多尺度混合池化混合卷积模型对复杂区域地物边界有更好的区分能力,所提混合池化模块能更好地提取地物纹理特征,在地物种类多、区域复杂、样本数量小的情况下依然能取得较高的分类精度。

表 6 不同方法对 WHU-Hi-HanChuan 数据集(2% 训练样本)的分类精度

Table 6 Classification accuracy of different methods on WHU-Hi-HanChuan dataset(2% samples)

| No. | Class | Accuracy /% | | | |
|--------------------|---------------|-------------|---------|----------|-------|
| | | Res-2D-CNN | 3D-CNN | HybridSN | LHHN |
| C1 | Strawberry | 89.21 | 94.59 | 96.84 | 98.02 |
| C2 | Cowpea | 66.01 | 90.05 | 98.41 | 98.72 |
| C3 | Soybean | 58.19 | 60.95 | 97.69 | 97.27 |
| C4 | Sorghum | 56.86 | 72.56 | 99.64 | 98.94 |
| C5 | Water spinach | 24.49 | 83.75 | 88.98 | 97.78 |
| C6 | Watermelon | 22.29 | 61.15 | 94.19 | 94.01 |
| C7 | Greens | 71.51 | 95.07 | 92.66 | 94.03 |
| C8 | Trees | 74.79 | 75.56 | 96.24 | 98.44 |
| C9 | Grass | 58.76 | 71.59 | 95.75 | 98.04 |
| C10 | Red roof | 94.16 | 97.58 | 98.51 | 98.89 |
| C11 | Gray roof | 89.48 | 92.62 | 96.49 | 98.26 |
| C12 | Plastic | 30.88 | 64.54 | 96.22 | 95.48 |
| C13 | Bare soil | 63.09 | 69.92 | 94.70 | 95.51 |
| C14 | Road | 82.41 | 82.69 | 97.00 | 98.27 |
| C15 | Bright object | 69.33 | 61.53 | 97.33 | 95.83 |
| C16 | Water | 99.31 | 97.61 | 99.95 | 99.92 |
| Training time /s | | 441.68 | 2124.83 | 58.83 | 64.77 |
| Predicting time /s | | 405.13 | 1298.87 | 33.86 | 35.45 |
| OA /% | | 82.16 | 80.06 | 97.69 | 98.43 |
| Kappa /% | | 79.07 | 76.87 | 97.30 | 98.16 |
| AA /% | | 60.20 | 65.95 | 94.35 | 96.40 |

表 7 不同方法对 WHU-Hi-HongHu 数据集(2% 训练样本)的分类精度

Table 7 Classification accuracy of different methods on WHU-Hi-HongHu dataset(2% samples)

| No. | Class | Accuracy /% | | | |
|--------------------|--------------------------|-------------|---------|----------|--------|
| | | Res-2D-CNN | 3D-CNN | HybridSN | LHHN |
| C1 | Red roof | 95.55 | 95.38 | 97.99 | 98.64 |
| C2 | Road | 73.52 | 79.98 | 90.39 | 92.61 |
| C3 | Bare soil | 86.68 | 88.43 | 96.73 | 99.1 |
| C4 | Cotton | 97.86 | 99.00 | 99.57 | 99.74 |
| C5 | Cotton firewood | 79.00 | 82.61 | 95.38 | 97.94 |
| C6 | Rape | 92.32 | 88.71 | 99.02 | 99.57 |
| C7 | Chinese cabbage | 75.41 | 84.47 | 95.38 | 97.11 |
| C8 | Pakchoi | 41.85 | 65.76 | 94.47 | 95.94 |
| C9 | Cabbage | 98.07 | 97.51 | 96.58 | 99.61 |
| C10 | Tuber mustard | 66.36 | 80.92 | 96.97 | 97.89 |
| C11 | Brassica parachinensis | 74.98 | 76.52 | 96.49 | 97.19 |
| C12 | Brassica chinensis | 62.03 | 71.27 | 93.41 | 97.17 |
| C13 | Small Brassica chinensis | 65.39 | 75.41 | 96.77 | 97.30 |
| C14 | Lactuca sativa | 81.88 | 88.40 | 97.56 | 99.44 |
| C15 | Celtuce | 61.57 | 98.54 | 97.57 | 65.91 |
| C16 | Film covered lettuce | 88.48 | 87.45 | 88.86 | 98.59 |
| C17 | Romaine lettuce | 63.77 | 88.36 | 80.95 | 98.53 |
| C18 | Carrot | 60.85 | 64.01 | 93.27 | 96.09 |
| C19 | White radish | 82.31 | 73.04 | 96.49 | 98.61 |
| C20 | Garlic sprout | 80.37 | 61.30 | 96.81 | 96.62 |
| C21 | Broad bean | 2.78 | 19.54 | 93.12 | 97.06 |
| C22 | Tree | 69.74 | 66.90 | 96.12 | 96.12 |
| Training time /s | | 674.38 | 3243.99 | 122.16 | 101.07 |
| Predicting time /s | | 473.05 | 1519.56 | 55.54 | 61.31 |
| OA /% | | 87.74 | 84.80 | 97.70 | 98.84 |
| Kappa /% | | 84.47 | 80.93 | 97.09 | 98.53 |
| AA /% | | 66.53 | 66.19 | 93.25 | 97.35 |

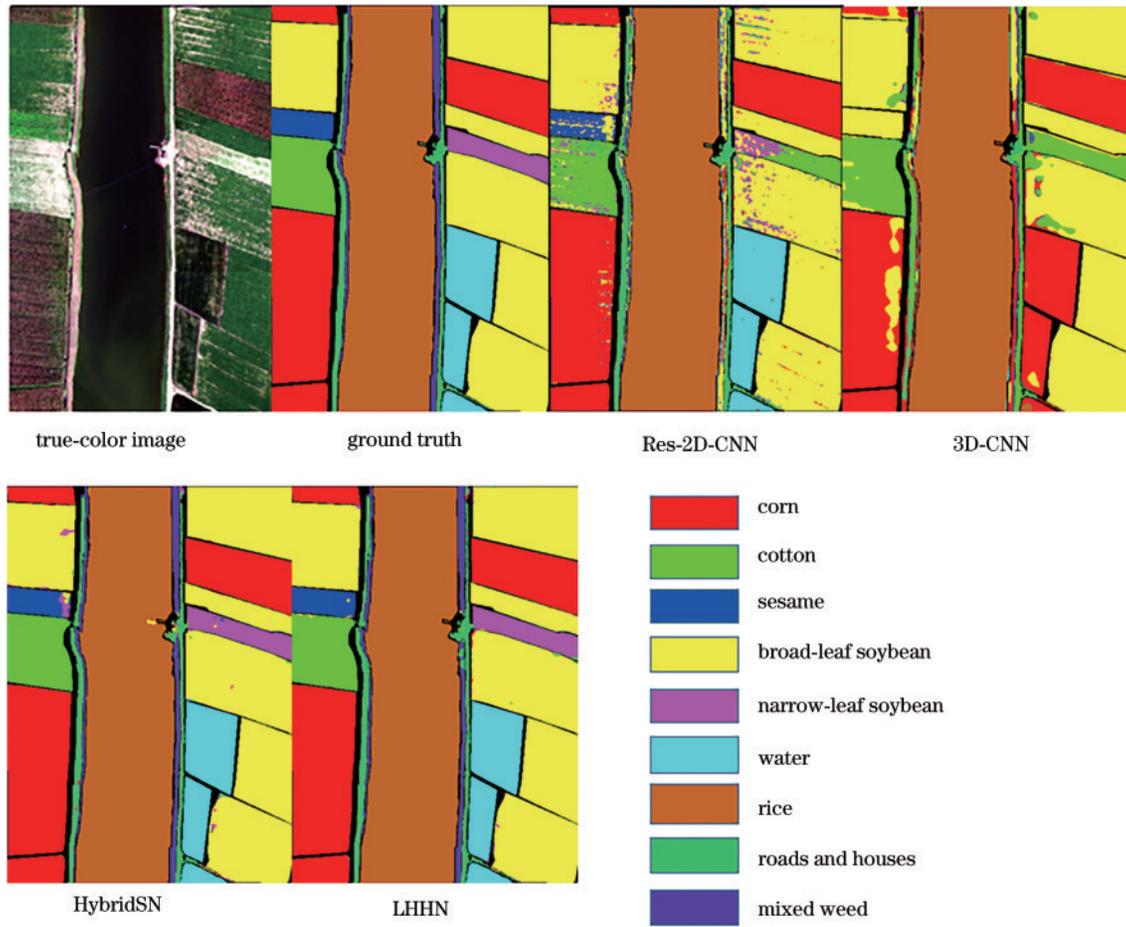


图 2 不同分类方法在 WHU-Hi-LongKou 数据集上的分类结果
 Fig. 2 Classification results of different classification methods on WHU-Hi-LongKou dataset

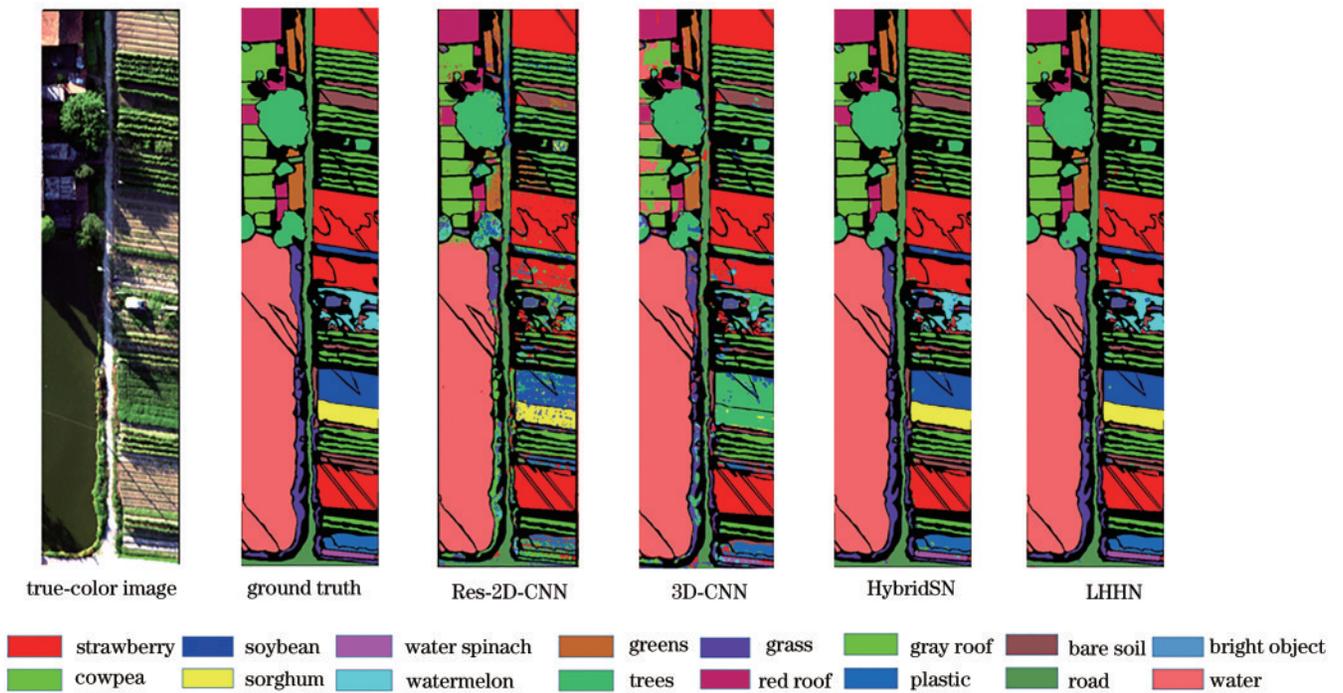


图 3 不同分类方法在 WHU-Hi-HanChuan 数据集上的分类结果
 Fig. 3 Classification results of different classification methods on WHU-Hi-HanChuan dataset

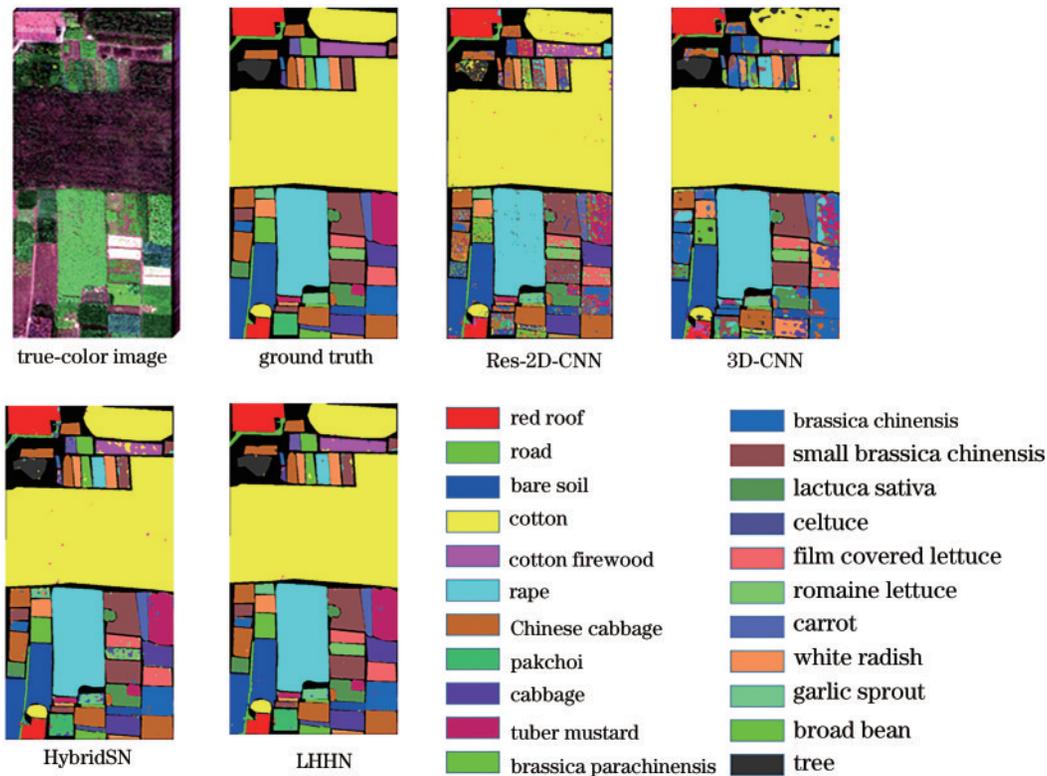


图 4 不同分类方法在 WHU-Hi-HongHu 数据集上的分类结果
 Fig. 4 Classification results of different classification methods on WHU-Hi-HongHu dataset

4 结 论

针对高分辨率高光谱数据集计算量大的问题和小训练样本条件下分类精度不佳的问题,以 WHU-Hi Dataset 高分辨率高光谱数据集作为基准数据集,在混合卷积网络和金字塔池化网络的基础上进行改进,提出了轻量化多尺度金字塔混合池化混合卷积模型。所提模型提升了对小样本的分类精度,通过使用更少的 3D 卷积层和引入深度可分离卷积降低模型的参数量,具有较快的训练速度和推理速度。与 Res-2D-CNN、3D-CNN 等方法相比,所设计的多尺度混合池化模块增加了模型的感受野,提升了模型对地物边界和多尺度特征的提取能力,在复杂区域仍然有较高精度,总体精度得到较大提升。未来将进行进一步探索,如何提升模型对复杂或非连片区域的分类能力。

参 考 文 献

[1] 张兵. 时空信息辅助下的高光谱数据挖掘[D]. 北京: 中国科学院研究生院(遥感应用研究所), 2002.
 Zhang B. Hyperspectral data mining supported by temporal and spatial information[D]. Beijing: University of Chinese Academy of Sciences (Institute of Remote Sensing and Digital Earth, Chinese Academy of Sciences), 2002.

[2] 袁迎辉, 林子瑜. 高光谱遥感技术综述[J]. 中国水运, 2007(8): 155-157.
 Yuan Y H, Lin Z Y. Overview of hyperspectral remote

sensing technology[J]. China Water Transport, 2007(8): 155-157.

[3] Lacar F M, Lewis M M, Grierson I T. Use of hyperspectral imagery for mapping grape varieties in the Barossa Valley, South Australia[C]//IGARSS 2001 Scanning the Present and Resolving the Future, July 9-13, 2001, Sydney, NSW, Australia. New York: IEEE Press, 2001: 2875-2877.

[4] 陈鹏飞. 无人机在农业中的应用现状与展望[J]. 浙江大学学报(农业与生命科学版), 2018, 44(4): 399-406.
 Chen P F. Applications and trends of unmanned aerial vehicle in agriculture[J]. Journal of Zhejiang University (Agriculture and Life Sciences), 2018, 44(4): 399-406.

[5] van der Meer F. Analysis of spectral absorption features in hyperspectral imagery[J]. International Journal of Applied Earth Observation and Geoinformation, 2004, 5 (1): 55-68.

[6] Stuffer T, Förster K, Hofer S, et al. Hyperspectral imaging: an advanced instrument concept for the EnMAP mission (Environmental Mapping and Analysis Programme) [J]. Acta Astronautica, 2009, 65(7/8): 1107-1112.

[7] Plaza A, Du Q, Chang Y L, et al. High performance computing for hyperspectral remote sensing[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2011, 4(3): 528-544.

[8] Hu W, Huang Y Y, Wei L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015, 2015: 258619.

[9] 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 (IGARSS), July 26-31, 2015, Milan, Italy. New York: IEEE Press, 2015: 4959-4962.
- [10] Lee H, Kwon H. Going deeper with contextual CNN for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2017, 26(10): 4843-4855.
- [11] 陈亨, 邓非. 分解式三维卷积神经网络的高光谱遥感影像分类[J]. 测绘科学, 2020, 45(8): 96-102, 129.
Chen H, Deng F. Hyperspectral remote sensing image classification based on decomposed three-dimensional convolutional neural network[J]. Science of Surveying and Mapping, 2020, 45(8): 96-102, 129.
- [12] 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.
- [13] 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.
- [14] 张祥东, 王腾军, 朱劭俊, 等. 基于扩张卷积注意力神经网络的高光谱图像分类[J]. 光学学报, 2021, 41(3): 0310001.
Zhang X D, Wang T J, Zhu S J, et al. Hyperspectral image classification based on dilated convolutional attention neural network[J]. Acta Optica Sinica, 2021, 41(3): 0310001.
- [15] 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.
- [16] Zhong Y F, Hu X, Luo C, et al. WHU-Hi: UAV-borne hyperspectral with high spatial resolution (H^2) benchmark datasets and classifier for precise crop identification based on deep convolutional neural network with CRF[J]. Remote Sensing of Environment, 2020, 250: 112012.
- [17] Zhong Z L, Li J, Luo Z M, et al. Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(2): 847-858.
- [18] 魏祥坡, 余旭初, 谭熊, 等. 利用残差密集网络的高光谱图像分类[J]. 激光与光电子学进展, 2019, 56(15): 151006.
Wei X P, Yu X C, Tan X, et al. Hyperspectral image classification based on residual dense network[J]. Laser & Optoelectronics Progress, 2019, 56(15): 151006.
- [19] Gao H M, Yang Y, Li C M, et al. Multiscale residual network with mixed depthwise convolution for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(4): 3396-3408.
- [20] 章文. 基于轻量级神经网络的高光谱图像分类研究[D]. 合肥: 合肥工业大学, 2021.
Zhang W. Research on hyperspectral image classification based on lightweight neural network[D]. Hefei: Hefei University of Technology, 2021.
- [21] Roy S K, Krishna G, Dubey S R, et al. HybridSN: exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(2): 277-281.
- [22] Gong H, Li Q X, Li C L, et al. Multiscale information fusion for hyperspectral image classification based on hybrid 2D-3D CNN[J]. Remote Sensing, 2021, 13(12): 2268.
- [23] 冯凡, 王双亭, 张津, 等. 基于多特征融合和混合卷积神经网络的高光谱图像分类[J]. 激光与光电子学进展, 2021, 58(8): 0810010.
Feng F, Wang S T, Zhang J, et al. Hyperspectral images classification based on multi-feature fusion and hybrid convolutional neural networks[J]. Laser & Optoelectronics Progress, 2021, 58(8): 0810010.
- [24] 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.
- [25] Zhong Y F, Wang X Y, Xu Y, et al. Mini-UAV-borne hyperspectral remote sensing: from observation and processing to applications[J]. IEEE Geoscience and Remote Sensing Magazine, 2018, 6(4): 46-62.
- [26] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[EB/OL]. (2016-12-04) [2022-01-05]. <https://arxiv.org/abs/1612.01105>.
- [27] Howard A G, Zhu M L, Chen B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[EB/OL]. (2017-04-17) [2022-01-16]. <https://arxiv.org/abs/1704.04861>.
- [28] Lin M, Chen Q, Yan S C. Network In network[EB/OL]. (2013-12-16) [2022-01-07]. <https://arxiv.org/abs/1312.4400>.
- [29] 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.