

DOI:10.16136/j.joel.2022.08.0802

基于多维度特征遥感图像分类方法的研究

王佳鑫¹, 任彦^{1*}, 王盛越², 高晓文¹, 叶玉伟¹

(1. 内蒙古科技大学 信息工程学院, 内蒙古 包头 014010; 2. 包头市农牧科学技术所, 内蒙古 包头 014010)

摘要:为了解决传统高光谱图像分类方法精度低、计算成本高及未能充分利用空-谱信息的问题, 本文提出一种基于多维度并行卷积神经网络(multidimensional parallel convolutional neural network, 3D-2D-1D PCNN)的高光谱图像分类方法。首先, 该算法利用不同维度卷积神经网络(convolutional neural network, CNN)提取高光谱图像信息中的空-谱特征、空间特征及光谱特征; 之后, 采用相同并行卷积层将组合后的空-谱特征、空间特征及光谱特征进行特征融合; 最后, 通过线性分类器对高光谱图像信息进行精准分类。本文所提方法不仅可以提取高光谱图像中更深层次的空间特征和光谱特征信息, 同时能够将光谱图像不同维度的特征进行融合, 减小计算成本。在 Indian Pines、Pavia Center 和 Pavia University 数据集上对本文算法和 4 种传统算法进行对比实验, 结果表明, 本文算法均得到最优结果, 分类精度分别达到了 99.210%、99.755% 和 99.770%。

关键词:图像处理; 高光谱图像分类; 卷积神经网络; 深度学习; 遥感图像

中图分类号: TP751 **文献标识码:** A **文章编号:** 1005-0086(2022)08-0807-08

Research on remote sensing image classification method based on multi-dimensional features

WANG Jiabin¹, REN Yan^{1*}, WANG Sengyue², GAO Xiaowen¹, YE Yuwei¹

(1. School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou, Inner Mongolia 014010, China; 2. Baotou Institute of Agriculture and Animal Husbandry Science and Technology, Baotou, Inner Mongolia 014010, China)

Abstract: In order to solve the problems of low accuracy, high computational cost and failure to make full use of space spectrum information of traditional hyperspectral image classification methods, a hyperspectral image classification method based on multi-dimensional parallel convolution neural network (3D-2D-1D PCNN) is proposed in this paper. Firstly, the algorithm uses different dimensions of convolutional neural network (CNN) to extract the spatial spectral features, spatial features and spectral features of hyperspectral image information. Then, the same parallel convolution layer is used to fuse the combined spatial spectral features, spatial features and spectral features. Finally, hyperspectral image information is accurately classified by linear classifier. The proposed method can not only extract the deeper spatial and spectral feature information in hyperspectral images, but also fuse the features of different dimensions of spectral images to reduce the computational cost. Comparative experiments are carried out on Indian Pines, Pavia Center and Pavia University data sets. The results show that the proposed algorithm obtains the optimal results, and the classification accuracy reaches 99.210%, 99.755% and 99.770% respectively.

Key words: image processing; hyperspectral image classification; convolutional neural network (CNN); deep learning; remote sensing image

* E-mail: ren0831@imust.edu.cn

收稿日期: 2021-11-30 修订日期: 2021-12-28

基金项目: 国家自然科学基金(620630271)、内蒙古科技计划项目(2020GG0048)、内蒙古自然科学基金(2019MS06002)和内蒙古自治区高等学校青年科技英才支持计划(NJYT22057)资助项目

1 引 言

随着遥感图像分辨率的不断提高,高光谱遥感已经成为遥感领域的研究热点。高光谱遥感技术是利用高光谱传感器,以连续的波段对目标区域同时成像,得到联合空-谱信息的高光谱图像^[1]。高光谱图像包含丰富的地物光谱信息和空间信息,广泛应用于农业遥感^[2]、环境保护^[3]和防震救灾^[4,5]等领域。

目前针对高光谱遥感图像的处理方法主要包括数据降维^[6]、图像分类^[7]、目标检测^[8]和辐射校正^[9]等。其中,遥感图像分类是高光谱图像处理和应用的重要研究方向,其目的是将图像中的每一个像素分配给唯一的标签。同时,高光谱图像结构复杂,由数百个连续的波段组成,使得特征提取更加困难。鉴于复杂的数据结构和有限的标记样本,高光谱遥感图像分类仍然面临巨大的挑战。

在高光谱图像分类的早期阶段,主要运用的方法有近邻函数、决策树和线性函数等,但是这些经典分类器的主要问题是容易产生 Hughes 现象^[10]。为了解决这一现象,CAMPS 等提出了支持向量机(support vector machine, SVM)的方法,这一算法能够有效地抑制 Hughes 现象的产生,因此成为之后很长一段时间分类的主流方法。但 SVM 算法分类精度低,无法应用到实际中,这一问题在深度学习中得到了有效的解决,其中效果最优的是卷积神经网络(convolutional neural network, CNN)。

CNN 因其逐层结构,可以分层提取更多隐含的和更深层次的特征而引起极大关注。常见的基于 CNN 模型的高光谱分类方法:1D CNN 提取图像光谱信息,2D CNN 提取图像空间信息,3D CNN 能够兼顾光谱信息和空间信息的提取。HU 等^[11]首先将 1D CNN 用于提取高光谱图像的光谱特征,相对 SVM 模型而言具有更高的分类精度。在此之前,CHEN 等^[12]使用 AutoEncoder 模型提取高光谱特征。HU 和 CHEN 使用的方法仅考虑了光谱图像的光谱信息,忽略了图像的空间信息。MAKANTASIS 等^[13]提出了一种新的基于深度学习的方法,该方法将 2D CNN 与多层感知机相结合,利用 2D CNN 提取图像空间信息,利用多层感知机进行分类。LI 等^[14]提出一种不依赖于任何预处理和后处理的遥感图像分类三维卷积神经网络(3D CNN)框架,该方法通过三维卷积核将高光谱遥感图像的光谱信息和空间信息有效融合;虽然有效地提高了分类精度,但也增加了计算成本。

针对以上分类精度低和计算成本高的问题,学者们提出了不同方法。HE 等^[15]提出一种多尺度三维深度卷积神经网络(multiscale 3D depth convolution neural network, M3D DCNN)模型,该模型能够以端到端的方式从遥感图像中提取光谱特征和空间特征,通过将两者有效结合来提高分类精度。陈亨等^[16]通过将 3D CNN 拆分成一次二维卷积和两次一维卷积来降低运算成本。张祥东等^[10]提出基于注意力机制的 3D-2D CNN 算法,先利用注意力机制对光谱图像进行降维处理,之后利用 3D CNN 提取空-谱联合信息和利用 2D CNN 学习图像中更多抽象的空间信息;该方法同 3D CNN 相比,在保持分类精度的基础上降低了计算成本。以上方法虽然对分类精度低和运算成本高的问题进行了有效的改善,但依然存在着问题:多尺度 3D CNN 以牺牲运算效率来提高分类精度;拆分式 3D CNN 没能将空-谱信息有效融合;基于注意力机制的 3D-2D CNN 没有充分考虑光谱特征优势。

为了解决这些问题,本文提出并行 3D-2D-1D CNN 算法。首先,该算法利用并行卷积层中的一维卷积、二维卷积和三维卷积分别提取高光谱图像的光谱特征、空间特征和空-谱特征;之后,再次利用并行卷积层将提取的多维度特征进行融合;最后,通过线性分类器对高光谱图像进行分类。该方法在提高计算效率的同时,充分利用高光谱遥感图像的空间信息和光谱信息,提高分类精度。

2 本文方法

2.1 并行 3D-2D-1D CNN 结构

本文提出的并行 3D-2D-1D CNN 模型如图 1 所示,其主要思想是通过 3D-CNN 同步提取空间和光谱特征,2D-CNN 提取高级抽象空间特征,1D-CNN 进一步提取光谱特征,充分利用了高光谱图像中丰富的空间和光谱信息。

3D CNN 是在高光谱立方体中,运用三维卷积核进行卷积计算,因此能够同时提取空-谱联合信息^[17]。本文提出的算法在保留 3D CNN 对空-谱联合信息提取的基础上,将同层其他并行的三维卷积计算过程替换为二维卷积和一维卷积计算,根据卷积运算的规则,本算法相对多尺度 3D CNN^[15]计算次数少,提升运算效率。

假设输入的高光谱数据块形状为 $H \times W \times C$, 一个多尺度 3D CNN 层卷积核的个数为 N , 单个卷积核的大小为 $S \times S \times S$ (此处假设多尺度 3D CNN 每个卷积核的大小相等), 卷积运算的步长大小为 1, 采用填充策略使得并行结构中一个卷积核的输入输出

数据大小相等,则对于一个多尺度 3D CNN 结构进行一次卷积操作的计算量 Q_1 如式(1):

$$Q_1 = H \times W \times C \times S \times S \times S \times N. \quad (1)$$

若当存在 L 层并行结构时,此模型效果达到最优,则最优模型计算量 Q_2 如式(2):

$$Q_2 = L \times H \times W \times C \times S \times S \times S \times N. \quad (2)$$

假设本文提出的并行 3D-2D-1D CNN 模型每层结构包含 n_1 个三维卷积核、 n_2 个二维卷积核和 n_3 个一维卷积核(其中 $N=n_1+n_2+n_3$),则此模型的计算量 Q_3 如式(3):

$$Q_3 = n_1 Q_4 + n_2 Q_5 + n_3 Q_6, \quad (3)$$

式中,每层并行结构中三维卷积运算的计算量 $Q_4 = L \times H \times W \times C \times S \times S \times S$,二维卷积运算的计算量 $Q_5 = L \times H \times W \times C \times S \times S$,一维卷积运算的计算量 $Q_6 = L \times H \times W \times C \times S$ 。则并行 3D-2D-1D CNN 模型与多尺度 3D CNN 模型计算量之比 P 如式(4):

$$P = \frac{Q_3}{Q_2} = \frac{n_1 Q_4 + n_2 Q_5 + n_3 Q_6}{L \times H \times W \times C \times S \times S \times S \times N} = \frac{n_1 \times S \times S + n_2 \times S + n_3}{S \times S \times N}, \quad (4)$$

式中,不妨取 $n_1=n_2=n_3=1, S=3$,则 $P=0.48$ 。由此可见,本文提出的算法模型相较于多尺度 3D CNN 模型计算量大大减小。




图1 并行 3D-2D-1D CNN 结构图

Fig. 1 Diagram of parallel 3D-2D-1D CNN structure

2.2 总体网络结构

本文网络总体结构如图2所示,该网络主要由 3D CNN、并行 3D-2D-1D CNN、Dropout 层和 Linear 分类器组成。网络输入为从原始高光谱图像数据选取图像邻域块 $F_n \in \mathbf{R}^{h \times w \times c}$,对 F_n 使用三维卷积层得到 F'_n ,提取空-谱信息,同时将单通道图像转变成 16 通道。分别用 3D CNN、2D CNN 和 1D CNN 提取图像特征,得到空谱特征 F_n^{ss} 、空间特征 F_n^{spa} 和光谱特

征 F_n^{spe} 。将获得的多维度空间与光谱特征使用特征融合模块进行融合,得到空-谱特征 $F_n^{sum} \in \mathbf{R}^{h \times w \times 16C}$ 。之后,采用池化层对特征图进行降维和去除冗余信息处理,实现简化网络复杂度和减小计算量的目的。为了缓解过拟合问题的出现,在全连接层前添加 Dropout 层,最后通过 Linear 分类器得到分类结果。权值更新通过将误差矩阵与原卷积核的权值相加实现。




图2 网络总体结构

Fig. 2 Overall network structure

3 实验数据及训练过程

3.1 实验数据

本文选用 Indian Pines、Pavia Center 和 Pavia University 3 个开源的高光谱数据集对本文算法进行测试和验证。

Indian Pines 数据集是最早用于高光谱图像分

类的测试数据集,于 1992 年采用机载可见红外成像光谱仪对美国印第安纳州的一块印度松树进行成像。图像大小为 145×145 pixel,拍摄范围为 3.2×3.2 km,波长范围为 $0.4 \sim 2.5 \mu\text{m}$,空间分辨率为 20 m,具有 200 个光谱带数,主要包括房屋、森林、植被和农田等 16 种不同的地物。图 3 为 Indian Pines 数据集的假彩图与真实地物信息图。




图 3 Indian Pines 高光谱影像:(a) 假彩图;(b) 真实信息图

Fig. 3 Indian Pines hyperspectral image:(a) False color map;(b) Real feature information map

Pavia Center 和 Pavia University 数据集由 ROSIS 传感器获取,拍摄于帕维亚中心和帕维亚大学,常被用于高光谱图像分类。其中,Pavia Center 高光谱数据集的图像大小为 1096×715 pixel,空间分辨率为 1.3 m,具有 102 个光谱带数,主要包括砖瓦、水

和树等 9 种不同的地物;Pavia University 高光谱数据集的图像大小为 610×340 pixel,空间分辨率为 1.3 m,具有 103 个光谱带数,主要包括草坪、裸土和公路等 9 种不同的地物。图 4 为 Pavia Center 和 Pavia University 数据集的假彩图与真实地物信息




图 4 Pavia Center 和 Pavia University 高光谱影像:(a) (b)Pavia Center 假彩图;(c) (d) Pavia University 真实信息图

Fig. 4 Pavia Center and Pavia University hyperspectral image:(a) (b) False color map of Pavia Center;
(c) (d) Real feature information map of Pavia University

息图。

3.2 训练过程

本实验使用总体精度(overall accuracy, OA)、平均精度(average accuracy, AA)和 Kappa 系数作为分类精度评价指标。其中 OA 指被正确分类的类别像元数与总的类别像元个数的比值;AA 指每一类中被正确分类的像元数与此类像元总数的比值的平均

值;Kappa 系数是一种比例,表示模型的分类结果与完全随机的分类结果产生错误减少的比例,其值($-1 < \text{Kappa} < 1$)越大表示分类精度越高。本实验在卷积计算过程中输入窗口尺寸(batch_size)为 7×7 ,训练样本与测试样本的比例为 3 : 7,最大训练轮数(epoch)为 150,根据实验结果,选取的最佳学习率为 0.01。本文所有实验均在 Windows10 操作系统下完

成,使用 visdom 进行监测,使用开源深度学习框架 Pytorch。

提出的模型包括 1 个 3 维卷积层、2 个并行 3D-2D-1D 卷积层,综合利用 3 种维度的卷积神经网络充分提取图像的空谱信息。其中,每个并行 3D-2D-1D 卷积包括 1 个 3 维卷积核、1 个 2 维卷积核和 2 个 1 维卷积核。3 维卷积核的尺寸为 $3 \times 3 \times 3$,表示空间尺寸为 3×3 ,光谱尺寸为 3;2 维卷积核的尺寸为 5×5 ;2 个 1 维卷积核的尺寸分别为 7 和 11,采用 2 个 1 维卷积核主要是为了提取不同感受野的光谱特征,使分类更准确。

4 实验结果对比与分析

为了验证本文所提出方法的有效性,将与各类

经典算法进行对比,其中包括 SVM、2D CNN、3D CNN 和多尺度 3D CNN。在实验过程中,各种方法采用的参数都调整为最优^[10,12,15,18]。

Indian Pines、Pavia Center 和 Pavia University 数据集的分类精度如表 1 所示。从表中可以看出本文提出的并行 3D-2D-1D CNN 在所列出的算法中为最优算法,分类精度分别达到了 99.210%、99.755%、99.770%。在 Indian Pines 数据集中,2D CNN 模型相较 SVM 模型提升较大,这段提升充分证明了 CNN 算法在高光谱遥感图像分类中的优势。3D CNN 相较 2D CNN 提升较为明显,提升了 5.784%,由此可证明光谱信息在遥感图像分类中具有重要作用。本文提出的并行 3D-2D-1D CNN 相较 3D CNN 也有 3.001%的提升,表明本文提出的模型

表 1 Indian Pines、Pavia Center 和 Pavia University 数据集的分类精度(%)

Tab. 1 Classification accuracy of Indian Pines, Pavia Center and Pavia University datasets(%)

Method	Index	Indian Pines	Pavia Center	Pavia University
SVM	OA	67.693	98.105	83.646
	AA	51.331	93.455	71.233
	KAPPA	62.187	97.334	77.479
2D CNN	OA	90.425	98.956	95.702
	AA	91.194	98.711	97.311
	KAPPA	89.132	98.497	94.378
3D CNN	OA	96.209	99.073	96.200
	AA	97.562	98.867	98.289
	KAPPA	95.689	98.713	95.010
Multiscale 3D CNN	OA	98.244	99.498	99.652
	AA	97.954	98.989	99.388
	KAPPA	96.431	98.993	99.021
Parallel 3D-2D-1D CNN	OA	99.210	99.755	99.770
	AA	98.850	99.547	99.703
	KAPPA	98.931	99.687	99.611

具有更高的分类精度和更好的信息提取能力。

Pavia Center 和 Pavia University 数据集在每个 CNN 模型中的分类精度都较高,经过分析得出结论,主要是因为这两个数据集的样本较为均衡,地物之间的光谱信息具有明显的差异,因此能够更加精确地辨认出每一种地物。为了进一步分析算法对不同地物的分类精度,将以 Indian Pines 数据集每种地物分类精度为例,对比不同算法之间的差异。Indian Pines 数据集每一种地物在不同算法上的分类精度如表 2 所示。

本文提出的并行 3D-2D-1D CNN 模型在 Indian Pines 数据集上的分类精度优于其他模型,除了 Al-

falfa 以外,其他地物的分类精度均达到 97% 以上。Grass pasture moved 和 Oats 在 3D CNN、多尺度 3D CNN 和并行 3D-2D-1D CNN 中分类精度均达到了 100%,而在 SVM 和 2D CNN 中分类精度较低,证明这两种地物空间信息不明显,但具有明显的光谱信息,最终导致只利用空间信息的算法分类精度较低。在 Stone steel towers 中,3D CNN 和并行 3D CNN 分类精度优于本文提出的并行 3D-2D-1D CNN,分析原因是该地物的光谱信息相对空间信息较弱,本文提出的算法更多地是利用一维光谱信息的优势,和只注重空间信息的 2D CNN 和偏重空间信息的 3D CNN 相比处于劣势,最终使得分类精度相对较弱。

在特定波段,部分地物之间光谱特征差异明显,部分地物之间空间特征差异明显。对于空间特征明显的地物,3D CNN 具有优势;对于光谱特征明显的地物,

本文提出的算法具有更大的优势。

图5展示了不同算法在IndianPines数据集上的分类结果。从图中可以看出,本文提出的算法噪

表 2 Indian Pines 数据集不同地物分类精度(%)
Tab. 2 Classification accuracy of different features in Indian pines dataset(%)

	SVM	2D CNN	3D CNN	Multiscale 3D CNN	Parallel 3D-2D- 1D CNN
Alfalfa	0	96.9	96.8	100	95.7
Corn notill	56.5	91.7	97.7	99.0	99.0
Corn mintill	54.3	85.8	91.3	95.0	99.8
Corn	23.6	94.1	93.6	98.7	97.9
Grass pasture	53.8	94.3	97.4	99.4	98.3
Grass trees	84.8	97.6	99.7	100	100
Grass pasture moved	0	80.0	100	100	100
Hay windrowed	91.2	100	99.7	100	100
Oats	0	86.7	100	100	100
Soybean notill	63.6	86.9	95.9	98.2	98.4
Soybean mintill	69.7	89.0	96.6	96.8	99.6
Soybean clean	33.4	87.4	96.7	97.8	98.0
Wheat	87	98.6	100	100	100
Woods	85.8	96.4	99.8	99.4	100
Buildings grass trees drives	26.7	75.3	94.3	98.7	97.2
Stone steel towers	90.9	98.4	98.4	100	97.8

点最少,最为平整,接近于真实地物图。对于 3D CNN 和并行 3D CNN 模型,相对 SVM 和 2D CNN 模型,噪点减少,分类精度更高,但也都存在分类精度较低的部分(图中框出的部分),而本文提出的并行 3D-2D-1D CNN 模型有效地降低了这部分的分类精度,使整体分类精度有所提高。

模型前 150 次迭代中的总体分类精度和损失折线图如图 6 所示。从图中可以清晰地看出本文算法收敛很快,在迭代 15 次左右时准确率可达到 90%以

上。训练过程中,只有在第 50 次左右和第 130 次左右因学习率过高而导致波动过大,整体来看波动较为平缓。

为了进一步证明本文所提出算法的优势,表 3 列出了各算法在不同数据集上的训练时间和测试时间。从表中可以看出:本文算法相对 3D CNN 在提高分类精度的同时,运行时间基本不变;相对多尺度 3D CNN 在分类精度提高的同时大大降低了运算成本,计算效率更高。



(a)



(b)



(c)



图 5 Indian Pines 数据集不同算法分类结果:(a) 真实信息图; (b) SVM; (c) 2D CNN;
(d) 3D CNN; (e) M3D DCNN; (f) 3D-2D-1D PCNN

Fig. 5 Classification results of different algorithms in Indian pines dataset:(a) Real ground map; (b) SVM; (c) 2D CNN;
(d) 3D CNN; (e) M3D DCNN; (f) 3D-2D-1D PCNN




图 6 Indian Pines 数据集前 150 次迭代中的分类精度和损失图:(a) 准确率; (b) 损失
Fig. 6 Classification accuracy and loss graph in the first 150 iterations
of the Indian Pines dataset:(a) Accuracy; (b) Loss

表 3 各数据集在不同算法的训练时间和测试时间(s)

Tab. 3 Training time and test time of each data set with different algorithms(s)

		SVM	2D CNN	3D CNN	Multiscale 3D CNN	Parallel 3D-2D-1D CNN
Indian Pines	Train/s	5.32	108.17	253.20	462.44	231.21
	Test/s	1.36	3.60	10.72	11.17	6.20
Pavia Center	Train/s	36.55	809.11	1 872.85	3 420.97	1 735.04
	Test/s	48.74	70.63	119.32	20.00	111.44
Pavia University	Train/s	13.75	230.94	541.17	987.44	483.42
	Test/s	20.86	25.78	42.95	47.44	44.02

5 结 论

针对传统高光谱遥感图像算法分类精度低、计算成本高和未能充分利用图像空-谱信息的问题,本文提出了并行 3D-2D-1D CNN 模型。该模型通过多维度 CNN 充分利用图像空-谱信息,在提高分类精度的同时有效降低了计算成本。本文通过 Indian Pines、Pavia Center 和 Pavia University 数据集将本

文算法与传统算法进行对比,分析结果得出结论:本文方法在 OA、AA 和 Kappa 3 个评价指标下均取得了最好的分类结果,3 个数据集的分类精度分别达到了 99.210%、99.755%和 99.770%。
本文虽然缓解了分类精度低和计算成本高的问题,但是没有解决高光谱遥感图像数据冗余的问题。接下来的研究将着重于用数据降维的方法去除高光谱图像中冗余部分,使分类结果更好,运算成本

更低。

参考文献:

- [1] MANIFOLD B, MEN S Q, HU R Q, et al. A versatile deep learning architecture for classification and label-free prediction of hyperspectral images[J]. *Nature Machine Intelligence*, 2021, 3(4): 306-315.
- [2] KHANAL S, KUSHAL K C, FULTON J P, et al. Remote sensing in agriculture-accomplishments, limitations, and opportunities[J]. *Remote Sensing*, 2020, 12(22): 3783.
- [3] WANG Q. Progress of environmental remote sensing monitoring technology and some frontier problems in China [J]. *Journal of Remote Sensing*, 2021, 25(1): 25-36.
王桥. 中国环境遥感监测技术进展及若干前沿问题[J]. *遥感学报*, 2021, 25(1): 25-36.
- [4] LISHA D, LEI M, LONGGUO L, et al. A survey of remote sensing and geographic information system applications for flash floods[J]. *Remote Sensing*, 2021, 13(9): 1818.
- [5] ZHU J, SONG C, KE L, et al. Remote sensing investigation of the offset effect between reservoir impoundment and glacier meltwater supply in Tibetan Highland catchment [J]. *Water*, 2021, 13(9): 1307.
- [6] QIN J, CHEN J, XIANG X, et al. A privacy-preserving image retrieval method based on deep learning and adaptive weighted fusion[J]. *Journal of Real-Time Image Processing*, 2020, 17(1): 161-173.
- [7] LIU Y, GAO L, XIAO C, et al. Hyperspectral image classification based on a shuffled group convolutional neural network with transfer learning[J]. *Remote Sensing*, 2020, 12(11): 1780.
- [8] DANQING X, YIQUAN W. MRFF-YOLO: A multi-receptive fields fusion network for remote sensing target detection [J]. *Remote Sensing*, 2020, 12(19): 3118.
- [9] HONGTAO C, XINGFA G, XIANGQIN W, et al. Lookup table approach for radiometric calibration of miniaturized multispectral camera mounted on an unmanned aerial vehicle[J]. *Remote Sensing*, 2020, 12(24): 4012.
- [10] 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.
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.
- [11] HU W, HUANG Y, WEI L, et al. Deep Convolutional neural networks for hyperspectral image classification[J]. *Journal of Sensors*, 2015, 1: 258619.
- [12] CHEN Y, LIN Z, 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.
- [13] MAKANTASIS K, KARANTZALOS K, DOULAMIS A, et al. Deep supervised learning for hyperspectral data classification through convolutional neural networks[C]//IEEE International Geoscience and Remote Sensing Symposium (IGARSS), July 26-31, 2015, Milan, Italy. New York: IEEE, 2015: 4959-4962.
- [14] LI Y, ZHANG H, SHEN Q. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network[J]. *Remote Sensing*, 2017, 9(1): 67.
- [15] HE M, LI B, CHEN H, et al. Multi-scale 3D deep convolutional neural network for hyperspectral image classification[C]//2017 24th IEEE International Conference on Image Processing, September 17-20, 2017, Beijing, China. New York: IEEE, 2017: 3904-3908.
- [16] CHEN H, DENG F. Hyperspectral remote sensing image classification based on decomposed three-dimensional convolution neural network[J]. *Science of Surveying and Mapping*, 2020, 45(8): 96-102+129.
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.
- [17] KONG F Q, ZHOU Y B, SHEN Q, et al. End-to-end multi-spectral image compression method based on convolutional neural network [J]. *Chinese Journal of Lasers*, 2019, 46(10): 1009001.
孔繁铨, 周永波, 沈秋, 等. 基于卷积神经网络的端到端多光谱图像压缩方法[J]. *中国激光*, 2019, 46(10): 1009001.
- [18] LIU B, YU X, ZHANG P, et al. A semi-supervised convolutional neural network for hyperspectral image classification[J]. *Remote Sensing Letters*, 2017, 8(9): 839-848.

作者简介:

任彦 (1977—), 女, 教授, 硕士生导师, 主要研究方向为遥感图像处理。