

基于多任务学习的高光谱图像目标分类和分割方法

韩宇霖^{1,2}, 刘凯新^{1,2}, 陈平^{1,2}

(1. 中北大学 电子测试技术国家重点实验室, 太原 030051;

2. 中北大学 信息与通信工程学院, 太原 030051)

摘要: 高光谱图像具有丰富的光谱特征和空间特征, 针对传统的基于卷积神经网络的高光谱图像分类方法只能完成单一的任务, 缺乏对其他任务的泛化能力的问题, 提出基于多任务学习的高光谱图像分类和分割方法, 通过共享统一的网络来组合完成不同的任务; 该框架采用共享编码器来有效提取多尺度特征, 同时在主干网络中引入光谱通道注意力以实现空间和光谱特征的联合提取, 并使用两个特定于任务的解码器来获取不同任务的结果; 所提出的方法在高光谱图像数据集上进行两项任务的对比实验, 结果表明, 与其他方法相比, 该方法实现了最好的性能。

关键词: 高光谱图像; 多任务学习; 语义分割; 特征融合; 注意力机制

Hyperspectral Image Target Classification and Segmentation Method Based on Multi-task Learning

HAN Yulin^{1,2}, LIU Kaixin^{1,2}, CHEN Ping^{1,2}

(1. The State Key Lab for Electronic Testing Technology, North University of China, Taiyuan 030051, China;
2. Department of Information and Communication Engineering, North University of China, Taiyuan 030051, China)

Abstract: Hyperspectral images have rich spectral and spatial features. Traditional hyperspectral image classification methods based on convolutional neural networks can only complete a single task and lack generalization ability for other tasks. In this paper, a multi-task learning hyperspectral image classification and segmentation method is proposed to achieve different tasks by sharing a unified network. The framework uses a shared encoder to efficiently extract multi-scale features, while introducing spectral attention in the backbone network to achieve joint extraction of spatial and spectral features, and uses two task-specific decoders to obtain results for different tasks. The proposed method performs comparative experiments of two tasks on hyperspectral image datasets. The results show that compared with other methods, the proposed multi-task learning method achieves the best performance.

Keywords: hyperspectral image; multitask learning; semantic segmentation; feature fusion; attention mechanism

0 引言

高光谱遥感技术, 作为一种先进的多维信息获取手段, 融合了成像与光谱分析技术, 具备显著的高空间分辨率与高光谱分辨率特性^[1]。该技术生成的三维数据立方体蕴含着丰富的空间、辐射和光谱维度信息^[2], 这一特性显著提升了地物识别能力, 使得许多在传统可见光

遥感和多光谱遥感技术中难以辨识的目标得以在高光谱遥感中被有效探测。因此, 高光谱图像技术已成为遥感领域中的一个研究热点, 其在精准农业、环境科学、海洋污染控制以及军事侦察等多个军民融合领域展现出广泛的应用潜力和深远的实际价值。

传统的高光谱图像分类方法主要依赖于手工设计的浅层特征提取, 这些特征往往无法充分捕捉数据的深层

收稿日期:2024-12-04; 修回日期:2025-01-06。

基金项目:国家优秀青年科学基金(62122070);国家自然科学基金一青年基金(62301507)。

作者简介:韩宇霖(2000-),男,硕士研究生。

通讯作者:陈平(1983-),男,博士后,教授。

引用格式:韩宇霖,刘凯新,陈平. 基于多任务学习的高光谱图像目标分类和分割方法[J]. 计算机测量与控制, 2025, 33(4): 241-246, 254.

次、本质性规律,导致在处理复杂数据集时算法的鲁棒性受限。近年来,随着深度学习技术的在计算机视觉领域的不断发展,卷积神经网络(CNN, convolutional neural networks)已广泛应用于各种高光谱图像的分类任务,根据不同算法对高光谱图像的特征提取方式主要分为基于光谱谱特征、空间特征和空谱联合特征的3类方法。基于光谱特征的分类方法将高光谱图像示为一维光谱序列,通过滤波器来捕获局部光谱模式并使用元素运算生成特征图。文献[3]将一维光谱向量转换为具有级联的二维特征矩阵,这种设计允许在不同的光谱波段上重复使用特征;文献[4]采用全局平均池化层来减少可训练参数并提高维特征;文献[5]提出一种结合卷积层和循环层的混合模型,用于提取位置不变的中间级特征和光谱上下文细节,基于光谱特征的分类方法能够有效地提取局部光谱特征,捕捉细微的光谱差异,有助于区分不同的地物类别。基于空间特征的分类方法则侧重于高光谱图像中的空间信息,它将高光谱图像中的宽度和高度作为空间维度,用第三个维度表示每个像素的光谱数据。文献[6]提出一种使用 Gabor 滤波增强的 2D-CNN 来解决过拟合问题,有效地保留空间细节;文献[7]引入了一种基于空间特征的自适应可变形采样位置的可变形网络,增强了复杂结构的提取。基于空间特征的分类方法能够捕获重要的空间上下文信息,对于处理高光谱图像中的结构、纹理和局部对象等空间特征至关重要,然而基于光谱或空间的分类方法主要关注其中一类特征,在训练样本有限的情况下往往会导致无法有效利用高光谱图像中的信息,这可能会出现丢失准确分类所需的特征从而发生过拟合的情况,高光谱数据的高维度和复杂性加剧了这个问题。因此,能够同时处理光谱和空间特征的方法被提出,文献[8]提出一种光谱-空间残差网络,利用光谱和空间残差块中的 3D 卷积来提取联合特征;文献[9]引入全卷积网络(FCN, fully convolutional networks)从图像中提取多样化特征,使用加权融合策略将空间特征与光谱信息进行融合;文献[10]实现了双通道的 CNN 框架,采用 1D-CNN 进行光谱特征提取,2D-CNN 用于空间特征提取。与仅关注单一特征的方法不同,基于空谱联合的分类方法通过利用光谱和空间特征进行互补,使得模型能够捕捉到更丰富的特征,来提高分类准确性。

虽然现有的高光谱图像分类方法针对特定的任务和有限的数据集不断地进行优化,但是这些方法缺乏泛化能力,多个专门化的模型参数面对不同的数据集不能共享,因此,本文引入多任务学习来实现高光谱图像基本任务的统一模型。多任务学习的目标是能够同时处理多个模型的任务^[11],与特定任务相比,多任务学习模型可以通过统一的架构和共享参数解决更多的任务,从而

防止模型像传统方法过度拟合指定数据。

综上所述,本文提出了用于高光谱图像分类和分割的多任务学习网络,研究的主要目标包括以下3个方面:1)提出一种基于CNN的新型高光谱图像多任务学习框架,采用共享编码器实现高效的多尺度特征提取,并针对不同任务采取特定的解码器得到结果;2)采用Res2Net作为主干网络的同时引入光谱通道注意力提取高光谱图像的光谱特征,在下采样阶段实现光谱特征与空间特征的联合提取;3)与传统的特定于任务的方法不同,多任务学习的方法能够提供更全面的高光谱图像表示,并降低了多个任务的总成本。

1 本文方法

1.1 网络总框架

首先为了消除频谱冗余,在输入网络之前,采用主成分分析(PCA, principal component analysis)对原始的高光谱数据进行降维,设高光谱数据立方体表示为 $X \in R^{C \times H \times W}$,其中 X 为原始输入, C 为光谱波段数, H 为高度, W 为宽度。PCA将光谱通道的数据通过线性变换将多波段影像转换为新的特征空间,同时保持相同的空间维度,保留了原始的空间信息,对于不同物体的识别都至关重要。将降维后的数据表示为 $\bar{X} \in R^{B \times H \times W}$,其中 $\bar{X}$ 是经过PCA后的高光谱数据, B 为PCA后的光谱波段数, H 为高度, W 为宽度。

本文所提出的网络总框架如图1所示,采用编码-解码器的结构,主要包括一个共享的编码器部分和两个特定于任务的解码器,高光谱图像经过PCA降维后输入共享编码器中提取多尺度特征,然后不同任务的解码器分别对特征进行解码,获得相应任务的结果。




图1 网络总体结构

1.2 共享编码器

多尺度特征图在网络框架中起着至关重要的作用,在分类过程中,分类模型倾向于将全局特征作为图像的概要,而分割模型则需要高分辨率特征来解析每个像素,因此需要一个高效的编码器来提取多尺度特征。

Res2Net^[12]作为 ResNet^[13]残差网络的多尺度改进, 通过改进残差模块的内部结构, 在提升网络的多尺度特征提取能力的同时不增加计算量, Res2Net 的残差块结构如图 2 所示。




图 2 Res2Net 残差模块


在 Res2Net 的残差模块中, 在 1×1 卷积后将输入特征分为 i 个特征子集, 分别记为 $x_n, n = (1, 2, \dots, i)$, 每个特征子集的通道数均为输入特征通道数的 $1/i$ 且空间大小相同。其中除了 x_1 外, 每个特征子集都会经过一个 3×3 卷积; 当 $2 < n \leq i$ 时, x_n 与前一个经过 3×3 卷积后的输出相加再进行 3×3 卷积。上述操作表示如下:

$$y_n = \begin{cases} x_n & n = 1; \\ K_n(x_n) & n = 1; \\ K_n(x_n + y_{n-1}) & 2 < n \leq i. \end{cases} \quad (1)$$

其中: $K_n()$ 为 3×3 卷积, y_n 为 $K_n()$ 的输出结果。为了在下采样阶段充分提取高光谱图像中的光谱特征并与空间特征进行融合, 本文在 Res2Net 的残差结构中引入通道注意力自适应地提取特征波段信息。受 SENet^[14] 的启发, 本文设计了一种光谱通道注意力, 采用 1×1 卷积层替代了全连接层以更好地拟合图像特征, 具体结构如图 3 (a) 所示。

其中, $\tilde{X} \in R^{C \times H \times W}$ 为光谱通道注意力模块的输入特征, 使用全局平均池化对高光谱图像的空间维度进行压缩, 得到通道注意力映射 $F_c \in R^{C \times 1 \times 1}$, 这种方法能够更好地捕捉不同波段之间的相关性。然后经过 1×1 卷积层将通道维度降低, 通过一个 ReLU 激活函数和一个 1×1 卷积层恢复原始通道数, 利用 Sigmoid 激活函数得到不同通道的权重分布, 最后将权重分布与原始输入逐元素相乘, 为输入特征的每个通道自适应分配相应的权重, 得到包含通道关注度的特征。在 Res2Net 中的残差连接末尾引入光谱通道注意力, 具体结构如图 3 (b)

所示。



(a) 光谱通道注意力结构 (b) 引入光谱通道注意力的Res2Net残差结构

图 3 结构示意图

1.3 分类解码器

分类解码器采用常规的 CNN 分类方法, 具体结构如图 4 所示。在编码器阶段提取图像的特征, 这些特征捕捉了输入数据的重要信息包括边缘、纹理、形状等特征, 将共享编码器输出的特征通过自适应平均池化来减少空间维度, 使每个通道的特征图转换为一个单一的数值, 从而得到一个固定长度的特征向量; 池化后的特征图通过展平操作转换为一维特征向量, 展平的特征向量传递给全连接层, 将特征向量映射到类别空间, 输出层的每个节点对应一个类别; 最后使用 SoftMax 激活函数将全连接层的输出转换为不同目标类型的概率分布, 实现最终的分类决策。




图 4 分类解码器结构

1.4 分割解码器

在分割解码器阶段, 设计了多尺度上下文提取模块, 该模块将多尺度特征提取和通过使用不同膨胀率的空洞卷积捕获多尺度特征, 提高不同尺度目标的分割性能; 然后引入特征融合模块利用深层特征对浅层特征进行指引并实现自适应地融合, 提升目标的细节边缘分割能力, 最后进行上采样, 实现高光谱图像的像素级分类。

1.4.1 多尺度上下文提取模块

高光谱图像在具有很高的图像分辨率的同时, 存在

不平衡的地物类别和不同目标尺度的变化等问题,而单一尺度的特征提取在编码阶段容易导致语义信息的丢失,难以实现良好的目标特征提取。ASPP^[15]通过引入不同膨胀率的空洞卷积来捕获不同尺度和特征的上下文信息,减少不同尺度语义信息的丢失,得到更全面、更准确的特征信息,从而提高了目标的分类精度。本文提出了一种多尺度上下文提取模块,该模块的内部结构如图 5 所示。




图 5 多尺度上下文提取模块

该模块主要由两个部分组成：第一部分是并行膨胀卷积多尺度特征提取模块,采用 5 个并行的膨胀卷积分支来获取不同尺度的特征信息,其中除了第一个大小为 1×1 的卷积以外,其余 4 个都是步幅为 1 并且没有填充的 3×3 卷积。上述过程表示如下:

$$[C_{1 \times 1}^1(X) \cdot C_{3 \times 3}^d(X)], d = 3, 6, 9, 12 \quad (2)$$

其中:“ $\cdot$ ”表示特征连接操作,指沿着通道尺寸对特征进行拼接; $C_{1 \times 1}^1()$ 表示膨胀率为 1 的 1×1 卷积; $C_{3 \times 3}^d()$ 表示膨胀率为 d 的 3×3 卷积,膨胀率 d 分别为 3, 6, 9, 12; X 表示输入特征。

第二部分是全局特征和上下文信息提取模块,负责获取全局特征和上下文信息。首先对输入特征进行执行全局平均池化,然后引入协调注意力模块 (Coordinate Attention Module)^[16]使得模型更关注有意义的特征并获取上下文信息。最后,该模块将两部分的输出特征进行拼接,实现了多尺度上下文的特征提取。

1.4.2 特征融合模块

网络深层的特征往往包含丰富的语义信息,但是在下采样过程中扩大感受野的同时丢失了对象的空间信息,而编码阶段生成的浅层特征包含了高质量的颜色、纹理和边缘信息等空间特征,这些特征对于目标的边缘细节分割具有重要的作用。本文提出的特征融合模块将

浅层特征中的空间细节信息与深层的语义特征进行高效融合,实现了空间细节信息与语义信息的互补,具体结构如图 6 所示。




图 6 特征融合模块

特征融合模块的输入是经过多尺度上下文提取模块后得到的深层特征 $F_h \in R^{C_h \times H \times W}$ 和主干网络中 Res-Block1 生成的浅层特征 $F_l \in R^{C_l \times H_l \times W_l}$ 。首先为了充分利用深层特征中的语义信息,对深层特征 F_h 执行步幅为 1, 填充为 3 的平均池化操作以获得特征矩阵 P_h , 然后通过对 P_h 进行两次连续卷积后使用 Sigmoid 激活函数获得增强的注意力矩阵 AS_h , 具体过程如下式:

$$AS_h = \text{Sig}\{[K_2(K_1 P_h)]\} \quad (3)$$

其中: K_1 卷积用来对深层特征的通道数量进行下降,为了进行后续的运算, K_2 卷积在 K_1 卷积运算后改变中间特征矩阵的通道数,使其与 F_l 的大小相同;“ $()$ ”和“ $[]$ ”表示卷积核数量不同的 1×1 卷积运算,“ $\{\}$ ”表示上采样运算;最后与浅层空间信息融合得到增强的低级特征 AM_l , 具体过程表示如下:

$$AM_l = AS_h \otimes F_l \quad (4)$$

2 实验数据集构建

目前用于高光谱目标分割的数据集极少,针对本文的研究问题,创建了高光谱图像数据集用于实验。高光谱数据采用凌云光 HV-125 系列高光谱成像仪实现高光谱图像的采集拍摄,每幅图像在 450~950 nm 的光谱范围内包含 128 个波段,光谱分辨率为 4 nm,影像大小为 $1387 \text{ px} \times 1829 \text{ px}$ 。为了模拟复杂多变的地貌环境,采用坦克、雷达、哨所和仓库 4 类缩比目标,分别在沙地和草地两种环境下对不同的目标进行高光谱数据采集,缩比目标与真实目标的比例为 1:300,以达到尽可能真实的模拟效果。

本文对高光谱相机采集到的数据进行了一系列预处理,首先为了与彩色图像进行比较,采用提取不同波段进行组合的方法生成对应的彩色图像以进行可视化,然后对大图像的边缘裁剪后进行重采样,每幅图像的最终大小为 $768 \text{ px} \times 512 \text{ px}$ 。分类任务的数据标注方式是通过将每幅图像中对应的目标类别进行标注;分割数据的标注方式是将采集的高光谱图像生成的可视化图像使用 LabelMe^[17]数据标记软件进行语义分割标注。该数据集共包含 2 000 幅高光谱图像,按照 7:2:1 的比例将数

数据集划分为训练集、验证集和测试集, 其中训练集包含 1 400 幅高光谱图像, 验证集包含 400 幅高光谱图像, 测试集包含 200 幅高光谱图像。不同类别目标的可视化图像及真值图像如图 7 所示。




图 7 高光谱数据集: (a) 可视化图像 (b) 标签

3 实验设置与结果分析

3.1 实验评价与相关设置

本文所有实验方法运行的硬件配置为 Intel Xeon Gold 6248R 处理器, 以及 NVIDIA RTX A6000 显卡, CUDA 版本为 12.3, 软件环境为 PyTorch1.13.1 框架, 编程语言为 Python3.9。

为了验证本文所提出的模型的有效性, 遵循不同任务的度量方法, 采用整体准确率 (OA, overall accuracy) 作为图像分类的评价指标; 使用两个评价指标包括平均交并比 ($mIoU$, mean intersection over union) 和 F_1 作为图像分割的评价指标, 与目前流行的方法进行比较。OA, $mIoU$ 和 F_1 三个指标基于混淆矩阵的计算方式如下:

$$OA = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$mIoU = \text{mean}\left(\frac{TP}{TP + FP + FN}\right) \quad (6)$$

$$precision = \frac{TP}{TP + FP} \quad (7)$$

$$recall = \frac{TP}{TP + FN} \quad (8)$$

$$F_1 = 2 \times \frac{precision \times recall}{precision + recall} \quad (9)$$

其中: TP 代表预测为正的像素的数量, FP 代表预测为负的正像素的数量, TN 代表预测为负的背景像素的数量, FN 代表预测为负的正像素的数量。

训练时采用随机旋转、随机翻转和随机空间仿射变换的方式进行数据增强。优化器选择自适应矩估计 (Adam, adaptive moment estimation) 优化器, Adam 优化器具有自适应学习率的特性, 能够在训练中表现出更稳定和快速的收敛; 初始学习率设置为 0.001, 选择较小的初始学习率避免发散; 学习率使用余弦衰减策略来进行调整, 使学习率随着训练轮次的增加而按照余弦

函数降低; 批次训练量大小为 4, 训练轮次为 200 轮。本文设计的训练程序能够在训练过程中为不同任务设置特定的损失函数, 采用交叉熵损失函数作为分类任务的损失函数; 采用 Focal Loss^[18] 函数作为分割任务的损失函数, Focal Loss 是对交叉熵函数的一种改进, 在训练过程中使模型专注于更难分类的像素, 实现本文的实验效果。

3.2 分类任务对比实验结果与分析

为验证本文所提出的高光谱图像分类网络的有效性, 在本文构造的数据集上选取了对比模型进行验证, 为了保证对比实验的客观性和公平性, 所有实验采用相同的数据预处理方式和图像增强方法。选择对比的网络包括 GoogleNet^[19]、ResNet50、MobileNetV2^[20] 和 Res2Net50, 实验结果见表 1。

表 1 本文数据集的分类任务对比实验结果

对比方法	OA/%
GoogleNet	86.34
ResNet50	89.72
MobileNetV2	90.39
Res2Net50	92.95
Res2Net50+SCAt	94.63

从表 1 的实验结果可以看出, 本文提出的分类网络在构造的高光谱数据集上整体准确率达到 94.63%, 与 GoogleNet、ResNet50 和 MobileNetV2 相比, 准确率分别提升了 8.29%、4.91% 和 4.24%。与表现较好的 Res2Net50 相比, 准确率提升了 1.68%。由于高光谱图像中存在空间分辨率高和光谱特征丰富的特点, 因此本文所提出网络在下采样阶段提取多尺度空间特征的同时, 通过引入光谱特征注意力, 提取特征波段并与空间特征融合, 实现在高光谱图像上良好的分类精度, 证明了本文方法对高光谱图像的目标分类具有一定的优越性。

3.3 分割任务对比实验结果与分析

为验证本文所提出的高光谱图像分割网络的有效性, 在本文构造的数据集上选取了对比模型进行验证, 为了保证对比实验的客观性和公平性, 所有实验采用相同的数据预处理方式和图像增强方法。选择对比的网络包括 UNet^[21]、SegNet^[22]、DeepLabV3+^[23]、LANet^[24] 和 MFCANet^[25]。

不同方法在高光谱数据集上的实验结果如表 2 所示, 其中各类别的指标均为 IoU 。从表 2 的结果中可以看出, 本文方法的 $mIoU$ 和 F_1 分数两类评价指标均优于其他对比模型。与表现较好的 MFCANet 相比, $mIoU$ 提升了 2.96%, F_1 提升了 2.17%, 不同类别的 IoU 分别提高了 1.05%、1.43%、1.49% 和 1.71%。

表 2 高光谱伪装目标数据集的对比实验结果 %

实验算法	装甲车	雷达	仓库	哨所	$mIoU$	F_1
UNet	68.74	57.53	65.68	74.69	66.66	86.81
SegNet	76.31	64.32	66.83	69.56	69.25	88.77
DeepLabV3+	79.65	63.73	74.82	79.44	74.41	89.91
LANet	81.32	79.92	80.45	77.12	79.70	93.54
MFCANet	84.68	82.75	88.13	83.59	84.93	93.55
本文方法	85.73	84.18	89.62	85.30	87.89	95.72

本文方法与对比方法在测试集上的可视化结果对比如图 8 和图 9 所示, 测试图像中共包含 5 种不同种类的目标。通过比较发现, 本文方法的整体分割效果优于其他对比网络, 由于高光谱数据中包含丰富的光谱特征, 有效地提取光谱特征对不同目标的分割效果十分重要, 实验结果证明本文方法在编码器的下采样阶段引入光谱注意力机制将光谱特征与多尺度空间特征进行充分融合, 提高了对目标的定位和分类能力。在多个不同目标同时分割的图像上, 本文方法与其他网络相比在不同尺度的目标上实现了更好的分割效果。同时, 利用特征融合模块将浅层空间细节和深层语义信息的高效融合, 丢失了更少的空间细节信息, 在 4 类目标的分割上实现边缘细节更加清晰的效果。




图 8 高光谱数据集实验结果一




图 9 高光谱数据集实验结果二

4 结束语

本文提出了一种基于 CNN 的多任务学习方法, 用

于高光谱图像的分类和分割。该方法通过共享统一的网络架构来组合完成不同的任务, 以提高模型的泛化能力。具体而言, 该框架采用共享编码器来有效提取多尺度特征, 并在主干网络中引入光谱通道注意力机制, 以实现空间和光谱特征的联合提取。此外, 使用两个特定于任务的解码器来分别获取分类和分割的结果。实验结果表明, 本文所提出的多任务学习方法在高光谱图像数据集上表现出优异的性能, 有效地实现了高光谱图像的分类和分割任务, 具有更高的准确率和分割精度。未来的研究可以进一步探索如何在多任务学习框架中整合更多的高光谱图像处理任务, 以实现更高效和准确的图像分析。此外, 还可以考虑将该方法应用于更大规模和更复杂的数据集, 以验证其在实际应用中的有效性和鲁棒性。

参考文献:

[1] 童庆禧, 张兵, 张立福. 中国高光谱遥感的前沿进展 [J]. 遥感学报, 2016, 20 (5): 689-707.

[2] 叶珍, 白璘, 何明一. 高光谱图像空谱特征提取综述 [J]. 中国图象图形学报, 2021, 26 (8): 1737-1763.

[3] GAO H, ZHANG Y, CHEN Z, et al. Hyperspectral target detection via spectral aggregation and separation network with target band random mask [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-16.

[4] LI Y, HONG D, LI C, et al. HD-Net: High-resolution decoupled network for building footprint extraction via deeply supervised body and boundary decomposition [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2024, 209: 51-65.

[5] WU H, PRASAD S. Convolutional recurrent neural networks for hyperspectral data classification [J]. Remote Sensing, 2017, 9 (3): 298.

[6] CHEN Y, ZHU L, GHAMISI P, et al. Hyperspectral images classification with Gabor filtering and convolutional neural network [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14 (12): 2355-2359.

[7] ZHU J, FANG L, GHAMISI P. Deformable convolutional neural networks for hyperspectral image classification [J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15 (8): 1254-1258.

[8] ZHONG Z, LI J, LUO Z, et al. Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework [J]. IEEE Transactions on Geoscience and Remote SENSING, 2017, 56 (2): 847-858.

[9] JIAO L, LIANG M, CHEN H, et al. Deep fully convolutional network-based spatial distribution prediction for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55 (10): 5585-5599.

(下转第 254 页)