

DOI:10.13232/j.cnki.jnju.2023.01.014

## 基于模糊空谱特征的高光谱图像分类

陈 瑞<sup>1</sup>, 徐金东<sup>1</sup>, 刘兆伟<sup>1</sup>, 阎维青<sup>1</sup>, 王 璇<sup>1</sup>, 宋永超<sup>1</sup>, 倪梦莹<sup>1,2\*</sup>

(1. 烟台大学计算机与控制工程学院, 烟台, 264000; 2. 烟台大学物理与电子信息学院, 烟台, 264000)

**摘 要:**难以兼得高空间分辨率和光谱分辨率的高光谱遥感数据常存在“同物异谱”和“同谱异物”现象,这种光谱异质问题给分类过程带来了一定的不确定性,且现有深度分类网络存在空间信息利用不足和拟合退化问题.提出一种联合空间和模糊光谱特征的双分支高光谱遥感图像分类方法,通过在光谱分支中设计非对称卷积模糊模块增强卷积层的光谱表征能力,解决分类数据中的光谱异质问题,进而对地物特征进行精确的分类描述.采用门控循环单元模型分组获取相邻光谱序列信息,缓解因网络深度增加带来的拟合退化问题,在空间分支中利用波段间的相关性引入卷积长短时记忆模块,充分捕捉空间上下文信息.在三个公开的高光谱数据集上的实验结果表明,双分支结构的模糊分类网络能充分利用光谱和空间包含的细粒度信息,更具判别力的空谱特征有效地克服了光谱异质问题,比流行的深度学习方法取得了更好的分类结果.

**关键词:**高光谱遥感,图像分类,非对称卷积模糊模块,模糊学习,空谱特征

中图分类号:TP391

文献标志码:A

## Hyperspectral image classification based on fuzzy spectral-spatial features

Chen Rui<sup>1</sup>, Xu Jindong<sup>1</sup>, Liu Zhaowei<sup>1</sup>, Yan Weiqing<sup>1</sup>, Wang Xuan<sup>1</sup>, Song Yongchao<sup>1</sup>, Ni Mengying<sup>1,2\*</sup>

(1. School of Computer and Control Engineering, Yantai University, Yantai, 264000, China;

2. School of Physics and Electronic Information, Yantai University, Yantai, 264000, China)

**Abstract:** Hyperspectral remote sensing data, which is difficult to have both high spatial resolution and spectral resolution, often have the phenomenon of “the same object with a different spectrum” and “a foreign object in the same spectrum”. This kind of spectral heterogeneity brings some uncertainty to image classification, and there are problems of insufficient utilization of spatial information and degradation of depth network fitting. In this paper, a dual branch hyperspectral remote sensing image classification method combining spatial and fuzzy spectral features is proposed. By designing asymmetric convolution fuzzy modules in the spectral branches, the spectral representation ability of the convolution layer is enhanced, the spectral heterogeneity in the classification data is solved, and then the ground features are accurately classified and described. The gated recurrent unit model is used to obtain the adjacent spectral sequence information in groups to alleviate the fitting degradation problem caused by the increase of network depth. In the spatial branch, the correlation between bands is used to introduce the convolutional long short-term memory module to effectively capture the spatial context information. Experimental results on three public hyperspectral datasets show that the fuzzy classification network with double branch structure can make full use of the fine-grained information contained in spectral-spatial, and the more discriminative spectral-spatial features can effectively overcome the problem of spectral heterogeneity, and achieve better classification results than state-of-the-art deep learning methods.

**Key words:**hyperspectral remote sensing, image classification, asymmetric convolution fuzzy module, fuzzy learning, spectral-spatial feature

基金项目:国家自然科学基金(62072391,62066013)

收稿日期:2022-10-06

\* 通讯联系人, E-mail: nimengying@ytu.edu.cn

高光谱图像(Hyperspectral Image, HSI)包含丰富的光谱信息和地物空间分布信息<sup>[1]</sup>,在农业、生态、海洋、军事等方面有广泛的应用<sup>[2]</sup>.但由于其固有的硬件缺陷,成像过程中存在光谱变异和噪声干扰,导致地物类别内不一致性和类别间不确定性的问题,而且HSI信息冗余、标记样本有限,难以提取有效的判别性空谱特征信息,给HSI分类任务带来了一定的困扰.使用单一光谱空间特征的传统机器学习图像分类方法不能充分利用HSI“图谱合一”的性质<sup>[3]</sup>,分类性能难以满足实际需求.

深度学习模型可以在少量先验知识的情况下学习具有代表性的深层特征<sup>[4]</sup>,与浅层特征相比,深层特征能学习更抽象、更复杂的结构信息,对图像局部变化具有更强的鲁棒性和不变性,在HSI分类领域被广泛研究<sup>[5]</sup>.Chen et al<sup>[6]</sup>首次将深度学习的概念引入HSI分类,使用多层堆叠自编码器提取深度特征.但由于HSI本身是三维立方体数据,仅依靠增加网络深度难以获得良好的分类结果,所以联合空谱特征成为HSI分类任务的趋势.Chen et al<sup>[7]</sup>提出三维卷积神经网络(3D Convolutional Neural Network, 3DCNN)的HSI分类,在空间和光谱维度上同时进行卷积.考虑小类别和类边界的错误分类,Zhao and Du<sup>[8]</sup>提出一种基于光谱-空间特征的分类(Spectral-Spatial Feature Based Classification, SSFC)方法,利用平衡局部判别嵌入和卷积神经网络(Convolutional Neural Network, CNN)分别提取光谱和空间特征,但由于特征提取过程和分类器的训练是分离的,分类精度稳定性欠佳.Zhong et al<sup>[9]</sup>提出一种光谱-空间残差网络(Spectral-Spatial Residual Network, SSRN),利用光谱残差块和空间残差块依次从HSI学习深度判别特征.然后,又提出一种新的空谱联合网络(Spectral-Spatial Transformer Network, SSTN)<sup>[10]</sup>,使用空间注意力模块和光谱关联模块,通过克服卷积核的约束来有效提升模型分类性能.Wang et al<sup>[11]</sup>提出一种端到端自适应分类网络(Adaptive Spectral-Spatial Multi-scale Network, ASSMN),提取HSI分类的多尺度上下文信息,获取具有判别性的空谱联合特征.

HSI的波段可视为是连续的,具有很强的内

部相关性和一定的序列性,序列模型自身具有的良好性能在分类任务中表现出显著优势,已有不少相关工作进行了探索.其中,门控循环单元(Gated Recurrent Units, GRU)能捕捉自然语言中长句的时间序列变异<sup>[12]</sup>,一些工作将GRU模型应用于HSI分类.Zhou et al<sup>[13]</sup>提出一种融合CNN和GRU优势的深度学习框架,使用CNN提取每个波段的空间特征,且利用GRU构建融合网络,对不同波段的空间特征进行融合.Pan et al<sup>[14]</sup>提出一种基于光谱-空间信息的GRU模型用于HSI分类,可以在一个连续的光谱输入中学习波段间的相关性.此外,为了在保持输入数据形状的同时更好地提取空间序列信息,Shi et al<sup>[15]</sup>在长短时记忆网络(Long Short-Time Memory, LSTM)的基础上提出卷积长短时记忆网络(Convolutional LSTM, ConvLSTM),将门中的全连接层替换为卷积层,能够有效提取时空特征.Hu et al<sup>[16]</sup>提出ConvLSTM与2D或3D卷积相结合的方法来捕获特征图中不同通道之间的关系.

综上,考虑现有深度学习对遥感空谱信息利用不足的问题以及模糊学习在处理数据不确定性时的优势,本文提出一种基于模糊空谱特征网络(Fuzzy Spectral-Spatial Feature Network, FSSFN)的HSI分类方法.利用端到端的学习策略,将特征提取分为光谱和空间两个分支,通过共享统一的损失函数将这两个分支特征进行融合分类.

本文的主要贡献:

(1)在光谱分支中设计了非对称卷积模糊模块(Asymmetric Convolution Fuzzy Module, ACFM)来增强深度学习卷积层的表征能力,突出目标像素信息,捕获更具区分性和判别性的特征,克服邻域像素的干扰,有针对性地处理HSI像素间的不确定性.

(2)光谱特征提取过程采用GRU捕获长序列中的相关信息来过滤无关信息,约减网络参数,提高模型训练效率,且保留重要特征,减少模型过拟合风险,防止因网络加深导致的模型退化问题.

(3)在空间分支中使用ConvLSTM在空间子网中提取特征信息,有效捕捉时空特征,更好地刻画空间信息,实现多尺度上下文信息的特征感知.

(4)在三个公开的高光谱数据集上进行测试,从分类结果和定量分析结果可以得出,本文提出的FSSFN框架与其他现有流行的深度学习方法相比,具有更好的分类性能.

### 1 提出的方法

基于模糊空谱特征网络(FSSFN)框架如图1所示,分为光谱分支和空间分支两部分.光谱分支提取深层光谱特征,获取区分不同地物类别的重要信息;空间分支捕获像素的空间信息,提高分类精度.该网络通过双分支结构分别对光谱特征和局部空间特征同时进行深入挖掘,经过特征融合,最后输入Softmax层得到分类结果.

**1.1 非对称卷积模糊模块(ACFM)** 由于现有的卷积操作难以有效提取HSI包含的刻画目标属性的光谱信息,为了增强网络的特征提取能力,充分获取分类任务需要的具有价值的光谱特征信息,本文利用模糊学习映射特征来克服邻域像素干扰,突出目标像素的主要信息,有助于分类模型

捕获重要特征、抑制不相关特征.受ACNet<sup>[17]</sup>的启发,设计一种ACFM来处理图像光谱特征,解决数据分类任务中的不确定性问题.其中每个ACFM遵循特定尺度的特征映射,从邻域像素中提取与目标像素更相关的特征信息,得到更具判别力和区分性的特征,减弱混合像元和噪声污染等不利影响,从而建立特征与分类结果之间的关联,提高网络的表达能力,获得鲁棒的分类结果.

如图2所示,以一个通道的模糊学习过程为例.设 $F$ 为输入大小为 $U \times V$ 的特征图,其中 $U, V$ 表示特征图的高度和宽度.首先,通过非对称卷积增加感受域,获取三个不同卷积核融合的细节特征,然后通过模糊学习层<sup>[18]</sup>获取邻域特征信息,即通过对通道中的每个像素邻域的加权均值来重构该像素的特征值以解决HSI分类任务中的类内光谱异质性问题.该层可视为由高斯函数中的多个参数描述的模糊层,该通道中的所有像素点执行相同的卷积操作,则具有相似的特征,对像素的不确定性进行模糊表示.

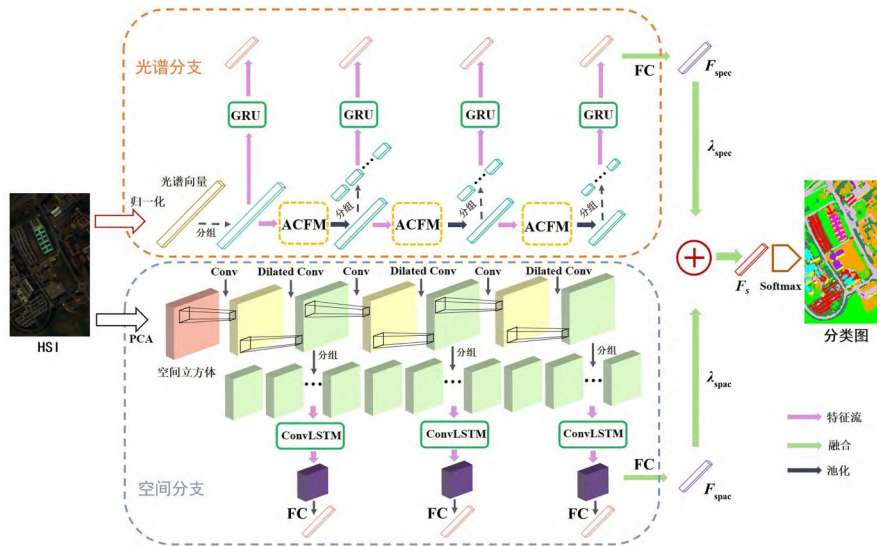


图1 FSSFN的网络结构

Fig. 1 FSSFN network structure




图2 ACFM的结构

Fig. 2 ACFM structure

模糊层如式(1)所示:

$$Z_{u,v} = e^{-\frac{(F_{u,v} - \mu)^2}{\sigma^2}}, u = 1, \dots, U, v = 1, \dots, V \quad (1)$$

其中, $(u, v)$ 为特征点 $F_{u,v}$ 在该通道中的坐标, $\mu$ 和 $\sigma$ 分别是均值和标准差, $Z_{u,v}$ 表示在该通道中特征点 $(u, v)$ 输出的模糊语义标签.



通过非对称卷积操作将  $3 \times 3$  卷积运算分解为  $1 \times 3$  层和  $3 \times 1$  层, 如图 3 所示. 其中,  $3 \times 3$  卷积通过一个相对较大的感受域捕捉特征,  $1 \times 3$  和  $3 \times 1$  卷积可以看作额外的先验信息, 能更好地关注水平和垂直特征, 在保持感受野并减少运算时间前提下细化了每层的特征提取. 中央交叉位置即卷积核的骨架, 使用非对称卷积核替代普通的方形卷积核, 将水平和竖直的特征信息叠加到骨架上, 增强卷积核骨架位置特征的重要性, 减弱冗余信息的影响.




图 3 非对称卷积的结构

Fig. 3 Asymmetric convolution structure

非对称卷积层如式(2)所示:

$$F = \phi \left[ \gamma_i \frac{x_i - E(x_i)}{\sqrt{\text{var}(x_i) + \epsilon_i}} \right] + \beta_i \quad (2)$$

其中,  $F$  为非对称卷积层的最终输出,  $\text{var}(\cdot)$  和  $E(\cdot)$  表示输入的方差函数和期望,  $\epsilon$  是用来保持数值稳定的常数,  $\gamma$  和  $\beta$  是批处理层的两个可训练参数,  $\phi(\cdot)$  为 ReLU 激活函数,  $x_i$  为三个分支融合特征, 即  $x_i = f_{3 \times 3}(x_{i-1}) + f_{1 \times 3}(x_{i-1}) + f_{3 \times 1}(x_{i-1})$ ,  $x_{i-1}$  为非对称卷积层的输入.

**1.2 光谱特征提取子网** 光谱中包含用于区分不同地物类别的重要信息, 本文引入光谱分支为 HSI 分类任务获取准确的光谱特征. 如图 1 中的光谱分支所示, 首先对原始的光谱特征向量进行归一化处理输入 ACFM 中提取特征信息. 由于不同尺度的上下文信息能提高分类精度, 将输入数据的尺度多样化, 一次使用多个波段获取多尺度光谱特征信息, 即通过将各层 ACFM 学习到的特征向量逐次减半输出 GRU, 分组获取不同波长范围光谱特征向量. 最后, 融合所有 GRU 的输出, 经过一个全连接 (Fully Connected, FC) 层得到最终的光谱特征.

为了获取相邻波段间完整的光谱信息, 在该分支中使用 GRU 分组获取相邻光谱序列间的上下文信息. GRU 包含更新门和重置门, 可以有效减少参数数量, 节省训练时间, 缓解模型过拟合问题. 其中, 需要调整不同 GRU 时间步长的超参数来获得位于不同波长范围的多个光谱段, 需要将不同的特征向量分成不同层次的组, 从而得到多尺度的特征描述信息.

**1.3 空间特征提取子网** 如图 1 所示, 空间分支在进行特征提取时, 由于原始 HSI 波段数据量大, 信息冗余度高, 首先对其进行主成分分析 (Principal Component Analysis, PCA), 分解降维, 经过归一化处理得到大小为  $h \times w \times d$  的子立方体,  $h, w, d$  分别为高度、权重和降维后的通道数. 然后, 经过  $3 \times 3$  的卷积层提取特征, 使用空洞卷积层增加感受域并保持特征图的分辨率. 连续进行三组这样的操作, 得到相应的空间特征序列.

考虑 HSI 空间分辨率的限制, 在大范围不邻空间区域呈现较弱的相关性, 但光谱波段间具有很强的相关性, 可能造成空间上下文信息的丢失. 因此, 该子网采用 ConvLSTM 模型对获取的空间序列信息进行分组操作, 在获取时序关系的同时, 与卷积操作一样刻画局部空间特征, 即时空特征, 弥补易丢失的空间上下文信息. 结合 Wang et al<sup>[11]</sup> 提出的用于处理光谱向量的交替分组策略, 在行和列方向上连续执行立方体分组并输入 ConvLSTM, 提取行和列方向上的像素相关性.

**1.4 融合分类** 由于光谱和空间特征的重要性可能会因不同的地物类别和场景而不同, 受 Xu et al<sup>[19]</sup> 的启发, 将这两部分的权重融入二者特征串联的过程, 得到最终的融合特征  $F_s$ , 如式(3)所示:

$$F_s = \lambda_{\text{spec}} F_{\text{spec}} + \lambda_{\text{spac}} F_{\text{spac}} \quad (3)$$

其中,  $F_{\text{spec}}$  和  $F_{\text{spac}}$  分别为光谱分支和空间分支获取的特征,  $\lambda_{\text{spec}}$  和  $\lambda_{\text{spac}}$  为相应的权重因子.

最后, 利用多任务交叉熵损失函数进行约束分类, 如式(4)所示:

$$L = L_s + L_{\text{spec}} + L_{\text{spac}} = -\frac{1}{m} \sum_{i=1}^m \left\{ y_i \left[ \lg(\tilde{y}_i^s) + \lg(\tilde{y}_i^{\text{spec}}) + \lg(\tilde{y}_i^{\text{spac}}) \right] + (1 - y_i) \left[ \lg(1 - \tilde{y}_i^s) + \lg(1 - \tilde{y}_i^{\text{spec}}) + \lg(1 - \tilde{y}_i^{\text{spac}}) \right] \right\} \quad (4)$$

其中,  $L_s$  是主损失函数,  $L_{\text{spec}}$  和  $L_{\text{spac}}$  是光谱和空间特征损失函数,  $\tilde{y}_i^s$ ,  $\tilde{y}_i^{\text{spec}}$  和  $\tilde{y}_i^{\text{spac}}$  是第  $i$  个训练样本相应的预测标签,  $y_i$  是真值标签,  $m$  是训练样本数.

## 2 实验结果与分析

选取三个公开高光谱遥感数据集 Indian Pines (IN), University of Pavia (UP) 和 Kennedy Space Center (KSC)<sup>[20]</sup> 进行实验, 分析评估算法性能. 将 FSSFN 与流行的深度学习方法进行比较, 包括 3DCNN<sup>[7]</sup>, SSUN<sup>[19]</sup>, SSRN<sup>[9]</sup>, ASSMN<sup>[11]</sup> 和 SSTN<sup>[10]</sup>, 对比方法的实验参数均按其原文设置. 使用总体精度 (Overall Accuracy, OA)、平均准确度 (Average Accuracy, AA) 与  $Kappa$  系数作为定量评价标准. 设置训练过程批处理大小 batch-size 为 16, 学习率为  $1e-2$ , epoch 为 200. 实验平台为 Intel 6140 处理器, 512 G 内存, RTX2080Ti 显卡, 基于 Pytorch 深度学习框架实现.

### 2.1 实验数据集

(1) IN: 由机载可见/红外成像光谱仪 (Airborne Visible/Infrared Imaging Spectrometer, AVIRIS) 传感器于 1992 年在印第安纳州西北部收集, 包含 220 个波段, 像素大小为  $145 \times 145$ , 去除 20 条水吸收及噪声波段, 剩下 200 条光谱波段用于实验测试. 其空间分辨率为 20 m, 波长范围为  $0.4 \sim 2.5 \mu\text{m}$ . 该数据集包含 16 个地物类别, 主要有农业区和森林, 还有一些建筑物以及道路. IN 数据集的训练集和测试集描述如表 1 所示.

(2) UP: 由意大利北部的反射光学系统成像光谱仪于 2001 年获得, 包含 115 个波段, 像素大小为  $610 \times 340$ , 去除噪声波段后只有 103 个波段用于实验测试. 空间分辨率为 1.3 m, 波长范围为  $0.43 \sim 0.86 \mu\text{m}$ , 包含九个地物覆盖类别, 包括树、沥青、道路、砖块、牧场等. UP 数据集的训练集和测试集描述如表 2 所示.

(3) KSC: 由美国佛罗里达州 AVIRIS 于 1996 年收集. 包含 224 个光谱波段, 去除噪声和水波段后在  $0.4 \sim 2.5 \mu\text{m}$  保留 176 个波段用于实验. 像素大小为  $512 \times 614$ , 空间分辨率为 18 m, 包括 13 个地物覆盖类别, 主要是沼泽类型. KSC 数据集的训练集和测试集描述如表 3 所示.

表 1 IN 数据集使用的训练和测试样本数量

Table 1 Number of training and testing samples used in IN dataset

Class number	Class name	Training	Test
1	Alfalfa	33	13
2	Corn-notill	100	1328
3	Corn-mintill	100	730
4	Corn	100	137
5	Grass-pasture	100	383
6	Grass-trees	100	630
7	Grass-pasture-mowed	20	8
8	Hay-windowed	100	378
9	Oats	14	6
10	Soybean-notill	100	872
11	Soybean-mintill	100	2355
12	Soybean-clean	100	493
13	Wheat	100	105
14	Woods	100	1165
15	Buildings-Grass-Trees-Drives	100	286
16	Stone-Steel-Towers	75	18
Total		1342	8907

表 2 UP 数据集使用的训练和测试样本数量

Table 2 Number of training and testing samples used in UP dataset

Class number	Class name	Training	Test
1	Asphalt	100	6531
2	Meadows	100	18549
3	Gravel	100	1999
4	Trees	100	2964
5	Painted metal sheets	100	1245
6	Bare Soil	100	4929
7	Bitumen	100	1230
8	Self-Blocking Bricks	100	3582
9	Shadows	100	847
Total		900	41876

2.2 IN 数据集上的实验结果及评价分析 IN 数据集上的实验结果如图 4 所示. 由图可见, 其他分类方法, 如 3DCNN 和 SSRN, 有许多像素点被错分, 而 FSSFN 的误分区更少, 产生的同质区域更多, 地物边界更加清晰平滑, 能更真实地反映地物分布情况. ASSMN 虽然也采用了自适应空谱联合的方法用于 HSI 分类, 但使用简单的卷积层进

表 3 KSC 数据集使用的训练和测试样本数量

Table 3 Number of training and testing samples used in KSC dataset

Class number	Class name	Training	Test
1	Scrub	33	728
2	Willow swamp	23	220
3	CP hammock	24	232
4	CP/Oak	24	228
5	Slash pine	15	146
6	Oak/Broadleaf	22	207
7	Hardwood swamp	9	96
8	Graminoid marsh	38	393
9	Spartina marsh	51	469
10	Catiai marsh	39	365
11	Salt marsh	41	378
12	Mud flats	49	454
13	Water	91	836
Total		459	4572

行特征提取获得的分类精度比较有限,存在许多噪声污染,边界区分较模糊.表4是分类客观评价指标的计算结果,FSSFN的OA,AA和Kappa三个指标均优于对比方法.和2022年提出的SSTN

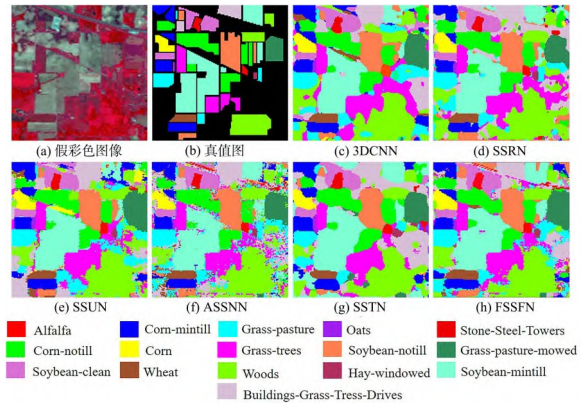


图 4 各算法在 IN 数据集上的分类结果

Fig. 4 Classification maps of different algorithms on IN dataset

相比,本文方法的OA,AA,Kappa指标分别提高了2.73%,4.9%和3.08%,这得益于FSSFN采用了ACFM,增加了特征提取能力,有效处理了像素间的不确定性.在不同地物分类指标中,FSSFN也取得了较好的分类效果,尤其在Grass-trees和Woods类别中,分类精度分别达到100.00%和99.49%,只有极小的噪声影响,在所有方法中分类效果最佳.此外,虽然该数据集中

表 4 各算法在 IN 数据集上的分类准确率

Table 4 Classification accuracies of different algorithms on IN dataset

Class	3DCNN <sup>[7]</sup>	SSRN <sup>[9]</sup>	SSUN <sup>[19]</sup>	ASSMN <sup>[11]</sup>	SSTN <sup>[10]</sup>	FSSFN
OA	96.42%	97.12%	96.49%	97.35%	94.78%	97.51%
AA	98.61%	96.45%	97.83%	98.62%	93.82%	98.72%
Kappa	95.86%	96.57%	96.41%	96.93%	94.03%	97.11%
Alfalfa	100%	99.23%	100.00%	100.00%	70.00%	100.00%
Corn-notill	93.30%	96.35%	94.80%	94.35%	95.30%	93.97%
Corn-mintill	99.59%	96.53%	99.04%	98.22%	92.37%	98.22%
Corn	100.00%	96.92%	100.00%	97.08%	89.95%	100.00%
Grass-pasture	100.00%	99.01%	98.96%	99.48%	87.70%	97.13%
Grass-trees	99.37%	98.96%	99.84%	99.68%	97.48%	100.00%
Grass-pasture-mowed	100.00%	98.33%	100.00%	100.00%	100.00%	100.00%
Hay-windowed	100.00%	99.94%	100.00%	100.00%	100.00%	100.00%
Oats	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
Soybean-notill	95.41%	90.92%	98.17%	94.61%	86.79%	95.64%
Soybean-mintill	93.25%	98.94%	93.29%	96.86%	95.96%	97.62%
Soybean-clean	98.17%	95.35%	99.59%	98.78%	96.12%	97.97%
Wheat	100.00%	99.78%	99.05%	100.00%	94.18%	100.00%
Woods	98.71%	99.47%	98.45%	98.88%	98.90%	99.49%
Buildings-Grass-Tress-Drives	100.00%	94.80%	100.00%	100.00%	96.35%	100.00%
Stone-Steel-Towers	100.00%	78.66%	100.00%	100.00%	100.00%	100.00%



Oats 和 Soybean-mintill 类别样本数量差异较大, 存在不同类别之间的数据不平衡性, 但从表 4 可以看出, 本文方法在这两类均取得了较高的分类精度, 样本数量差异性没有影响模型的分类性能, 该方法在小样本中仍具有良好的适应性, 分类性能稳定. 从分类结果中也可以看出, FSSFN 的噪声点更少, 边界更平滑, 很好地保留了细节信息.

**2.3 UP数据集上的实验结果及评价分析** UP数据集包含九类地物, 包括树、沥青、道路等, 不存在明显的小样本地物类别, 可利用的训练样本较多. 在分类性能最优的情况下, 随机抽取每类样本的训练数为 100, 其余样本组成测试集, 实验结果如图 5 所示. 由图可见, 本文方法的效果最佳, 能准确区分并获取完整的类别形状, 边界更清晰, 而 3DCNN 和 SSUN 方法存在较多的噪声, 分类结果不理想. 分类结果的客观评价指标如表 5 所示. FSSFN 的 OA 达到 97.03%, 而 3DCNN 和 SSUN 由于特征提取具有局限性, OA 仅为 93.54% 和 92.36%, 结果差异较大. 对于 Asphalt 类别, 不同方法的分类精度也有很大差距, 但 FSSFN 仍取得了最佳的实验结果, 分类效果突出, 分类精度和 3DCNN, SSUN, SSRN, ASSMN, SSTN 相比, 提升幅度较大, 达到 97.41%. 这是由于使用 ACFM 增强了卷积层的表征能力以及 GRU 模型有效提取了光谱序列中的相关信息, 有效缓解了精度下降问题. 在 Bare Soil 类别中, 本文方法的 OA, AA 和 Kappa 指数比 ASSMN 分别




图 5 各算法在 UP 数据集上的分类结果

Fig. 5 Classification maps of different algorithms on UP dataset

提高 0.65%, 1.99% 和 0.93%, 其分类结果的物边缘更清晰, 噪声点更少, 且整体分类效果也优于 3DCNN, SSUN, SSRN, SSTN. SSRN 虽然也取得不错的分类结果, 但边界区分不够平滑, 例如在 Meadows 类别中表现较突出.

**2.4 KSC数据集上的实验结果及评价分析** 最后在 KSC 数据集上进行分类实验来评估每种算法的性能, 样本数量参考 SSUN 的设置, 分类结果如图 6 所示. 由图可见, FSSFN 和 3DCNN, SSRN 相比, 产生的同质区域更多, 误分率更低,

表 5 各算法在 UP 数据集上的分类准确率

Table 5 Classification accuracies of different algorithms on UP dataset

Class	3DCNN <sup>[7]</sup>	SSRN <sup>[9]</sup>	SSUN <sup>[19]</sup>	ASSMN <sup>[11]</sup>	SSTN <sup>[10]</sup>	FSSFN
OA	93.54%	96.71%	92.36%	96.38%	96.37%	97.03%
AA	95.92%	97.80%	95.21%	96.24%	95.06%	98.23%
Kappa	91.50%	95.61%	89.97%	95.13%	95.19%	96.06%
Asphalt	92.40%	85.69%	86.86%	96.65%	96.25%	97.41%
Meadows	91.97%	99.82%	90.90%	99.18%	98.57%	95.65%
Gravel	94.77%	100.00%	94.85%	93.70%	84.22%	98.20%
Trees	97.80%	99.96%	99.63%	98.62%	90.62%	98.55%
Painted metal sheets	99.91%	100.00%	99.60%	100.00%	100.00%	100.00%
Bare Soil	92.45%	95.47%	93.06%	81.27%	98.40%	97.79%
Bitumen	98.85%	100.00%	96.59%	97.32%	99.46%	98.86%
Self-Blocking Bricks	95.53%	99.28%	95.90%	99.41%	92.00%	98.13%
Shadows	99.62%	100.00%	99.53%	100.00%	96.02%	100.00%

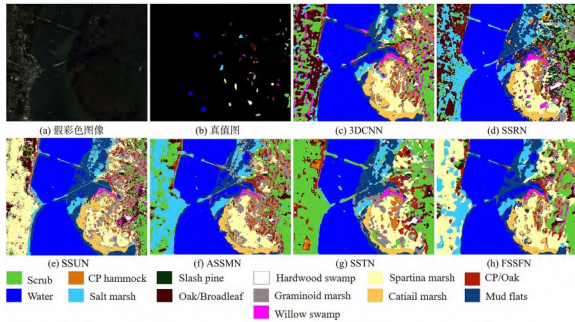


图 6 各算法在 KSC 数据集上的分类结果

Fig. 6 Classification maps of different algorithms on KSC dataset

杂碎斑点更少,分类效果更好. 客观评价结果如表 6 所示. 由表可见, FSSFN 的实验结果最佳, 其  $OA$ ,  $AA$  和  $Kappa$  指标比 ASSMN 分别提高 0.81%, 1.73% 和 0.91%. 另外, FSSFN 在 CP hammock 类别中误分率较大, 这是后期值得思考

表 6 各算法在 KSC 数据集上的分类准确率

Table 6 Classification accuracies of different algorithms on KSC dataset

Class	3DCNN <sup>[7]</sup>	SSRN <sup>[9]</sup>	SSUN <sup>[19]</sup>	ASSMN <sup>[11]</sup>	SSTN <sup>[10]</sup>	FSSFN
$OA$	97.52%	96.76%	96.57%	97.70%	97.66%	98.51%
$AA$	96.87%	96.28%	94.82%	96.70%	94.69%	98.43%
$Kappa$	97.24%	96.39%	96.18%	97.42%	97.40%	98.33%
Scrub	94.75%	100.00%	95.05%	94.37%	99.69%	96.29%
Willow swamp	94.77%	93.06%	95.91%	98.64%	96.10%	98.18%
CP hammock	96.64%	100.00%	95.26%	97.84%	99.54%	87.07%
CP/Oak	86.27%	69.18%	96.93%	100.00%	99.07%	100.00%
Slash pine	96.37%	100.00%	80.14%	93.84%	69.34%	99.32%
Oak/Broadleaf	97.05%	95.60%	73.43%	87.92%	97.41%	100.00%
Hardwood swamp	97.08%	100.00%	100.00%	86.46%	75.28%	100.00%
Graminoid marsh	97.84%	98.35%	98.98%	99.75%	99.18%	99.75%
Spartina marsh	99.30%	99.76%	99.15%	98.96%	100.00%	98.96%
Cattail marsh	99.89%	97.65%	98.63%	100.00%	100.00%	100.00%
Salt marsh	99.84%	98.01%	99.21%	100.00%	97.46%	100.00%
Mud flats	99.56%	100.00%	100.00%	99.34%	97.88%	100.00%
Water	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%

由表可见, 在光谱分支中使用 LSTM 和 GRU 取得的分类精度差异较大, 使用 GRU 和 LSTM 相比, 其  $OA$ ,  $AA$ ,  $Kappa$  分别提高 2.87%, 4.86%, 3.16%. 这是因为 HSI 本身具有训练样本高度稀疏性的特点, 在标记样本有限情况下 GRU 比 LSTM 更适用于 HSI 分类任务. 而引入 ACFM 后, 整体的分类精度有改善, 比单独使用 GRU 时

和改进的地方.

值得注意的是, 虽然该数据集样本数量普遍较少, 但在小样本前提下本文方法仍能获取较高的分类精度和稳定性, 这是因为使用 ACFM 突出了目标像素信息, 并且 GRU 模型更适用于具有少量标记样本的 HSI 分类任务, 模型训练参数更少, 训练时间更短, 能有效抑制过拟合问题.

**2.5 消融实验结果及评价分析** ACFM 和 GRU 的使用对本文方法至关重要, 为了验证这两个模块的有效性, 用相同的实验条件在 KSC 数据集上进行消融实验. 即模型在单独采用光谱子网进行分类任务时, 同时使用 ACFM 和 GRU (Spectral-ACFM-GRU), GRU (Spectral-GRU), LSTM (Spectral-LSTM) 进行对比, 然后单独采用空间分支 (Spatial) 进行分类任务以及联合光谱-空间 (Joint) 分支进行对比实验, 实验结果如表 7 所示.

的  $OA$ ,  $AA$ ,  $Kappa$  都有一定程度的提升, 分别为 87.94%, 82.24%, 86.52%, 证明 ACFM 对于特征提取的有效性. 在单独使用空间分支时, 该子网采用 ConvLSTM, 有效利用了波段间的相关性, 弥补了易丢失的空间上下文信息, 也取得了较好的分类性能. 联合光谱-空间分支整体精度均高于单独使用二者时的性能, 分类精度最佳.



表7 KSC数据集上消融实验的分类准确率

Table 7 Classification accuracies of ablation experiments on KSC dataset

Class	Spectral+ACFM-GRU	Spectral-GRU	Spectral-LSTM	Spatial	Joint
OA	87.94%	86.25%	83.38%	95.20%	98.51%
AA	82.24%	81.23%	76.37%	96.75%	98.43%
Kappa	86.52%	84.64%	81.48%	96.64%	98.33%
Scrub	97.50%	85.03%	82.28%	77.61%	96.29%
Willow swamp	88.64%	82.73%	86.82%	92.73%	98.18%
CP hammock	84.05%	64.22%	50.00%	98.28%	87.07%
CP/Oak	96.43%	96.43%	92.86%	100.00%	100.00%
Slash pine	46.58%	36.30%	23.29%	97.95%	99.32%
Oak/Broadleaf	32.37%	44.44%	26.57%	97.10%	100.00%
Hardwood swamp	67.71%	89.58%	79.17%	100.00%	100.00%
Graminoid marsh	88.80%	79.64%	82.44%	97.73%	99.75%
Spartina marsh	91.65%	92.69%	91.02%	95.62%	98.96%
Catitail marsh	98.90%	99.19%	93.15%	100.00%	100.00%
Salt marsh	96.56%	92.86%	91.80%	100.00%	100.00%
Mud flats	90.09%	92.95%	93.39%	99.78%	100.00%
Water	99.88%	99.88%	100.00%	100.00%	100.00%

为了验证提出方法的效率,在三个数据集上测试方法的客观执行时间,利用CPU-time计时,实验结果如表8所示.由表可见,训练阶段在IN数据集上使用GRU模型时网络训练时间仅为1398.3 s,而使用LSTM模型训练时间增加了2493 s,差异明显.测试阶段,GRU模型的优势在UP数据集上更显著,和LSTM模型相比,其测试时间节约了109.34 s.

表8 GRU模型在三个数据集上的有效性测试

Table 8 Effective test of GRU model on three datasets

		IN	UP	KSC
Train time(s)	Joint-GRU	1398.3	8878.0	6875.4
	Joint-LSTM	3891.3	9445.7	9791.1
Test time (s)	Joint-GRU	12.74	99.60	22.36
	Joint-LSTM	37.27	208.94	130.47

综上,FSSFN中的GRU模型可以有效约减网络参数,比LSTM模型缩减了实验训练和测试时间,加快了收敛速度,提高了运行效率.

### 3 结论

本文通过双分支结构的模糊分类网络解决HSI分类任务中光谱异质性和模型退化问题.在

提取光谱特征时,使用GRU模型获得局部像素之间的相互关系,提高了特征提取效率,有效抑制了过拟合.为了削弱邻域像素的干扰,设计ACFM突出目标像素信息,增强了网络的表征能力,提取深层光谱信息.在空间特征提取时,使用Conv-LSTM模型执行分组策略,充分利用波段间的相关性,刻画了空间结构信息,获得鲁棒的分类性能.在三个公开的HSI数据集上的实验表明,本文算法与其他先进的深度学习空谱分类网络相比,能更有效地提取空谱判别特征,具有较高的分类精度和良好的性能.

#### 参考文献

- [1] 叶珍,白璘,何明一.高光谱图像空谱特征提取综述.中国图象图形学报,2021,26(8):1737-1763.(Ye Z, Bai L, He M Y. Review of spatial-spectral feature extraction for hyperspectral image. Journal of Image and Graphics, 2021, 26(8): 1737-1763.)
- [2] Li W, Dou Z G, Cui L J, et al. Suitability of hyperspectral data for monitoring nitrogen and phosphorus content in constructed wetlands. Remote Sensing Letters, 2020, 11(5): 495-504.
- [3] Ren J S, Wang R X, Liu G, et al. An SVM-based nested sliding window approach for spectral - spatial

- classification of hyperspectral images. *Remote Sensing*, 2020, 13(1):114.
- [4] 赵伍迪, 李山山, 李安, 等. 结合深度学习的高光谱与多源遥感数据融合分类. *遥感学报*, 2021, 25(7): 1489—1502. (Zhao W D, Li S S, Li A, et al. Deep fusion of hyperspectral images and multi-source remote sensing data for classification with convolutional neural network. *National Remote Sensing Bulletin*, 2021, 25(7):1489—1502.)
- [5] 吴鸿昊, 王立国, 石瑶. 高光谱图像小样本分类的卷积神经网络方法. *中国图象图形学报*, 2021, 26(8): 2009—2020. (Wu H H, Wang L G, Shi Y. Convolution neural network method for small-sample classification of hyperspectral images. *Journal of Image and Graphics*, 2021, 26(8):2009—2020.)
- [6] Chen Y S, Lin Z H, Zhao X, et al. Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2094—2107.
- [7] Chen Y S, Jiang H L, Li C Y, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(10):6232—6251.
- [8] Zhao W Z, Du S H. Spectral - spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8):4544—4554.
- [9] Zhong Z L, Li J, Luo Z M, et al. Spectral - spatial residual network for hyperspectral image classification: A 3-D deep learning framework. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(2):847—858.
- [10] Zhong Z L, Li Y, Ma L F, et al. Spectral - spatial transformer network for hyperspectral image classification: A factorized architecture search framework. *IEEE Transactions on Geoscience and Remote Sensing*, 2022(60):5514715.
- [11] Wang D, Du B, Zhang L P, et al. Adaptive spectral-spatial multiscale contextual feature extraction for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(3):2461—2477.
- [12] Lynn H M, Pan S B, Kim P. A deep bidirectional GRU network model for biometric electrocardiogram classification based on recurrent neural networks. *IEEE Access*, 2019(7):145395—145405.
- [13] Zhou F, Hang R L, Liu Q S, et al. Integrating convolutional neural network and gated recurrent unit for hyperspectral image spectral - spatial classification//Chinese Conference on Pattern Recognition and Computer Vision. Springer Berlin Heidelberg, 2018(11259):409—420.
- [14] Pan E T, Ma Y, Dai X B, et al. GRU with spatial prior for hyperspectral image classification//2019 IEEE International Geoscience and Remote Sensing Symposium. Yokohama, Japan: IEEE, 2019: 967—970.
- [15] Shi X J, Chen Z R, Wang H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting//Proceedings of the 28<sup>th</sup> International Conference on Neural Information Processing Systems. Montreal, Canada: MIT Press, 2015(28):802—810.
- [16] Hu W S, Li H C, Pan L, et al. Spatial - spectral feature extraction via deep ConvLSTM neural networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(6):4237—4250.
- [17] Ding X H, Guo Y C, Ding G G, et al. ACNet: Strengthening the kernel skeletons for powerful CNN via asymmetric convolution blocks//2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea (South): IEEE, 2019:1911—1920.
- [18] Zhao T Y, Xu J D, Chen R, et al. Remote sensing image segmentation based on the fuzzy deep convolutional neural network. *International Journal of Remote Sensing*, 2021, 42(16):6264—6283.
- [19] Xu Y H, Zhang L P, Du B, et al. Spectral - spatial unified networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(10):5893—5909.
- [20] Li K, Xu J, Zhao T, et al. A fuzzy spectral clustering algorithm for hyperspectral remote sensing image classification. *IET Image Processing*, 2021, 15(12): 2810—2817.

(责任编辑 杨可盛)