

文章编号:1007-2780(XXXX)XX-0001-14

高低频增强与跨层图卷积聚合的高光谱图像分类

马鑫^{1*}, 汪西原², 白雪冰³

(1. 宁夏工商职业技术大学 信息技术学院, 宁夏 银川 750021;

2. 宁夏大学 电子与电气工程学院, 宁夏 银川 750021;

3. 宁夏大学 前沿交叉学院, 宁夏 中卫 755000)

摘要:针对高光谱图像分类中局部纹理与边缘细节易损失、卷积分支感受野受限以及图分支跨层结构信息利用不足等问题,本文提出一种高低频增强与跨层图卷积聚合的卷积-图卷积联合分类模型。该方法通过高低频残差增强提升输入特征质量,在卷积分支中利用多阶段动态卷积编码提取多尺度空间-光谱特征,在图卷积分支中采用跨层图特征加权聚合增强区域结构建模能力,并通过跨分支注意力融合实现两路特征的协同建模。实验在Indian Pines、Pavia University和Salinas 3个公开数据集上进行,总体分类精度分别达到92.94%、95.11%和97.50%,对应Kappa系数分别为91.94%、93.50%和97.22%。结果表明,所提方法能够兼顾局部细节、空间上下文和区域拓扑结构信息,在不同类型高光谱分类场景下具有较好的综合分类性能。

关键词:高光谱图像分类;空间-光谱联合特征;图卷积网络;注意力融合

中图分类号:TP391 文献标识码:A doi:10.37188/CJLCD.2026-0034 CSTR:32172.14.CJLCD.2026-0034

Hyperspectral image classification via high-low frequency enhancement and cross-layer graph convolution aggregation

MA Xin^{1*}, WANG Xiyuan², BAI Xuebing³

(1. School of Information Technology, Ningxia Polytechnic University of Business and Technology, Yinchuan 750021, China;

2. School of Electronic and Electrical Engineering, Ningxia University, Yinchuan 750021, China;

3. School of Advanced Interdisciplinary Studies, Ningxia University, Zhongwei 755000, China)

Abstract: To address the problems of local texture and edge-detail loss, limited receptive fields in the convolution branch, and insufficient use of cross-layer structural information in the graph branch for hyperspectral image classification, this paper proposes a CNN-GCN joint classification model with high-low frequency enhancement and cross-layer graph convolution aggregation. The model improves input representation through high-low frequency residual enhancement, extracts multi-scale spectral-spatial features using a multi-stage dynamic convolution encoder, enhances regional structural modeling by cross-layer weighted aggregation in the graph branch, and performs collaborative modeling through cross-branch

收稿日期:2026-03-11;修订日期:2026-04-02.

基金项目:国家自然科学基金(No.42361056)

Supported by National Natural Science Foundation of China (No.42361056)

*通信联系人, E-mail:2023012@nxgs.edu.cn

attention fusion. Experiments on three public datasets, Indian Pines, Pavia University, and Salinas, achieve overall accuracies of 92.94%, 95.11%, and 97.50%, with corresponding Kappa coefficients of 91.94%, 93.50%, and 97.22%, respectively. The results show that the proposed method can effectively integrate local details, spatial context, and regional topological structure information, achieving competitive classification performance across different types of hyperspectral classification scenes.

Key words: hyperspectral image classification; spectral-spatial joint features; graph convolution network; attention fusion

1 引言

高光谱图像(Hyperspectral Image, HSI)同时包含丰富的光谱信息和空间结构信息,能够为精细地物识别、农业资源调查、生态环境监测和遥感解译等任务提供重要的数据支撑^[1]。与此同时,高光谱成像技术的应用范围也在不断拓展,已延伸至半导体器件无损检测、微型高分辨光谱测量以及地基成像干涉等方向,体现出光谱成像在精细感知和复杂目标观测中的广泛应用潜力^[2-4]。然而,高光谱数据通常具有波段维度高、谱间冗余强、类别间光谱相似性高以及标注样本有限等特点,使其分类任务长期面临“维数灾难”、小样本条件下模型泛化能力不足以及复杂场景中类别边界易混淆等问题。传统机器学习方法,如支持向量机、K近邻和随机场模型等,虽然在早期高光谱图像分类研究中得到了广泛应用,但这类方法对谱-空联合特征的深层非线性建模能力有限,难以充分挖掘高维遥感数据中的判别信息。

近年来,深度学习的快速发展显著推动了高光谱图像分类研究。相关综述和研究表明,深度学习方法已逐渐成为高光谱分类的主流技术路线,并在特征表达和分类精度方面表现出明显优势^[5]。其中,卷积神经网络(Convolutional Neural Network, CNN)依靠局部连接和参数共享机制,能够有效提取像素邻域内的空间纹理特征;图卷积网络(Graph Convolutional Network, GCN)则能够在超像素图或谱-空间图结构上建模非欧几里得关系,从而增强对长程依赖和区域拓扑结构信息的表征能力。随着高光谱分类任务对局部细节保持能力和全局结构建模能力要求的不断提高, CNN与GCN协同建模逐渐成为高光谱图

像分类的重要研究方向。

在卷积分支建模方面,多尺度卷积与感受野扩展是提升高光谱分类性能的重要手段。Asker^[6]提出结合压缩激励机制、深度可分离卷积和多分支特征融合的分类方法,在降低模型复杂度的同时增强了多尺度特征提取能力。景海钊^[7]等提出3D-CNN与Transformer混合结构的高光谱图像空谱联合分类方法,利用3D卷积提取局部谱-空细节信息,并结合全局建模机制增强长距离依赖关系表征,从而提升复杂场景下的分类性能。刘和^[8]等提出基于空间金字塔注意力机制残差网络的高光谱图像分类方法,通过空间金字塔注意力强化多尺度空间-光谱联合特征表示,提高了模型对关键判别信息的提取能力。此外,注意力机制与多尺度结构的结合也被证明能够有效提升空间-光谱联合特征表达能力。陈海松^[9]等进一步将高效注意力机制与神经架构搜索相结合,实现了高光谱分类网络结构的自动优化设计,提升了模型对不同数据集的适应能力。与此同时,李英超^[10]等面向地物混杂背景提出偏振光谱图像融合方法,表明复杂背景下差异信息增强与互补融合对目标表征具有重要作用;刘敬^[11]等提出主动学习联合聚类分组网络,通过样本选择与分组卷积建模相结合,提高了有限标注条件下高光谱图像的特征学习能力和分类性能;邱敬^[12]等利用跨域交互注意力和对比学习引导红外与可见光图像融合,提高了异构信息融合的有效性;吴海滨^[13]等将CNN、Transformer与对比学习相结合,实现了高光谱与LiDAR数据的协同分类,说明多分支特征提取、全局上下文建模与判别性表示学习对复杂场景分类任务具有重要作用;Zhang^[14]等提出可学习空洞谱-空MLP结构,实现了更加灵活的感受野调节。上述研究表明,多

尺度卷积、注意力增强、信息互补融合与全局上下文建模已成为提升高光谱分类性能的重要途径,但现有方法在细节保持、尺度自适应建模以及不同类型信息的协同利用方面仍有进一步提升空间。

除感受野建模外,高光谱图像中高低频信息的差异化利用同样值得关注。低频成分主要表征区域整体结构和类内一致性,高频成分则反映边缘、纹理及局部细节。对于分类任务,前者有助于增强区域一致性和全局判别能力,后者对边界识别和细粒度类别区分具有重要作用。然而,现有多数方法仍以统一特征整体建模为主,缺乏对高低频信息的协同利用,因而难以兼顾全局一致性与局部细节判别。

在图结构建模方面,图神经网络能够较好地处理高光谱图像中的非欧几里得数据关系,因此在谱-空间联合建模中受到广泛关注。Zhao^[15]等综述了图神经网络在高光谱分类中的研究进展,指出图卷积、图注意力和图表示学习在长程依赖建模方面具有明显优势。Hanachi^[16]等提出多视角图表示学习模型,通过融合光谱图与空间图增强分类判别性。Liu^[17]等设计了双图卷积网络,分别在空间图和谱图上建模,实现跨维度结构特征融合。尽管图卷积模型在区域结构传播和全局关系建模方面具有优势,但现有方法对多层图特征的利用仍不充分,难以兼顾浅层局部信息与深层语义信息。

为了同时利用CNN的局部谱-空特征提取能力和GCN的全局结构建模优势,CNN-GCN融合框架近年来受到广泛关注。Zhou^[18]提出AMGCFN,通过多尺度卷积、多跳图卷积和跨分支注意力实现特征协同建模;Gao^[19]等进一步引入分割引导策略,以增强局部与全局特征的联合表征。尽管此类方法在复杂场景和小样本条件下取得了较好效果,但仍存在多尺度特征自适应建模不足、高低频信息利用不充分、跨层图特征聚合不够深入以及双分支互补性挖掘不足等问题。

针对现有方法在细节保持、尺度自适应建模、跨层图特征利用和双分支融合方面的不足,本文提出一种高低频残差增强卷积-图卷积融合网络(High-and

Low-Frequency Residual-enhanced CNN-GCN Fusion Network, HFRCGFN),该网络通过高低频残差增强、多阶段动态卷积编码、跨层图特征加权聚合和跨分支注意力融合,实现卷积特征与图结构特征的协同建模。

2 HFRCGFN网络模型设计

2.1 模型总体结构

本文提出的HFRCGFN网络整体结构如图1所示。该网络构建了卷积与图卷积并行的双分支框架,通过输入增强、双分支特征提取、跨分支融合和分类输出,实现局部细节、空间上下文及区域拓扑结构信息的协同建模。对于每个待分类像素,以其为中心提取谱-空邻域块作为卷积分支输入,经高低频双分支残差增强模块(High-and Low-Frequency Dual-branch Residual Module, HFDR)和多阶段动态卷积编码模块(Multi-stage Dynamic Convolution Encoding Module, MDCE)提取局部空间-光谱特征;同时,对整幅高光谱图像进行主成分分析(Principal Component Analysis, PCA)降维和简单线性迭代聚类(Simple Linear Iterative Clustering, SLIC)超像素分割,构建图节点及邻接关系,并输入残差图卷积加权聚合模块(Residual Graph Convolution with Weighted Aggregation Module, RGCWA)建模区域级邻域关系与全局拓扑结构。随后,将两路特征送入跨分支注意力融合模块(Cross-branch Attention Fusion Module, CAFM)进行融合,最终输出中心像素的类别标签。通过这种“谱-空邻域块+超像素图结构”的联合输入方式,实现了高光谱图像数据与双分支网络结构的有效结合。




图1 HFRCGFN架构

Fig. 1 Architecture of HFRCGFN

2.2 高低频双分支残差增强模块

为提升输入特征质量,本文在HFRCGFN前端引入高低频双分支残差增强模块(HFDR),其结构如图2所示。该模块通过分离并协同建模高

频与低频成分,在尽量保持原始谱-空分布稳定的前提下,增强边缘纹理细节信息和区域背景结构信息,从而为后续卷积分支与图卷积分支提供更加有效的输入表示。

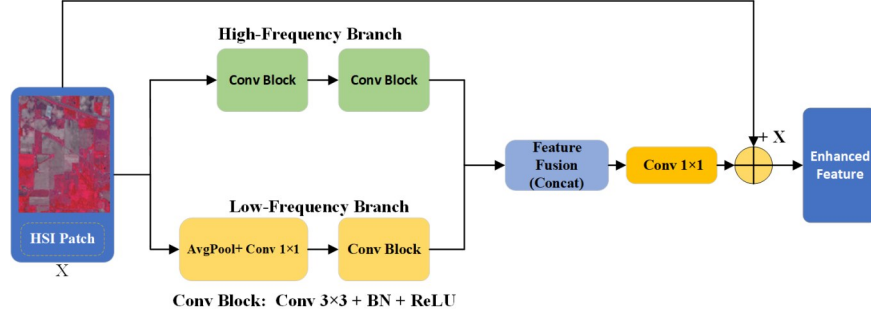


图2 HFDR结构

Fig. 2 Structure of the HFDR module

为便于描述,设输入高光谱图像为:

$$X \in R^{H \times W \times B}, \quad (1)$$

其中 H 、 W 和 B 分别表示图像的高、宽和光谱波段数。经超像素分割后,构建图节点特征矩阵:

$$V \in R^{N \times d}, \quad (2)$$

其中, N 为节点数, d 为节点特征维数。首先采用平均池化提取低频分量:

$$X_l = AvgPool(X). \quad (3)$$

再由输入与低频分量之差得到高频分量:

$$X_h = X - X_l, \quad (4)$$

其中, X_l 主要反映区域的整体轮廓和背景平滑信息, X_h 主要包含边缘、纹理及局部变化信息。为避免直接特征替换导致原始分布被破坏,本文采用残差注入方式对卷积分支输入进行增强,即

$$\tilde{X} = X + \alpha_h X_h, \quad (5)$$

其中, α_h 为可学习参数,用于控制高频增强强度。在图卷积分支中,低频信息还被进一步映射到超

像素节点空间,以增强区域结构表达。设图节点初始特征为 V ,由低频分量 X_l 映射至超像素节点空间后得到的节点特征为 V_l ,则图分支的增强表示为:

$$\tilde{V} = V + \alpha_l V_l, \quad (6)$$

其中, α_l 为可学习系数,用于控制低频结构补充强度。HFDR通过高频增强提升边缘与纹理细节表征,同时利用低频补充增强区域结构信息,为后续双分支特征提取提供更有效的输入表示。

2.3 多阶段动态卷积编码模块

为充分提取不同感受野下的空间-光谱特征,本文在卷积分支中设计了多阶段动态卷积编码MDCE模块,其结构如图3所示,该模块通过多阶段多尺度卷积结构与动态门控融合机制,实现局部细节信息与中大范围上下文信息的逐级编码,从而增强卷积分支对复杂空间模式的表征能力。




图3 MDCE结构

Fig. 3 Structure of the MDCE module

将 HFDR 模块增强后的输出记为 \tilde{X} 。在 MDCE 第 1 阶段中,输入特征同时进入 7×7 、 5×5 和 3×3 三条并行卷积分支,得到:

$$\begin{cases} F_1^7 = \phi_1^7(\tilde{X}) \\ F_1^5 = \phi_1^5(\tilde{X}) \\ F_1^3 = \phi_1^3(\tilde{X}) \end{cases}, \quad (7)$$

其中, $\phi_1^7, \phi_1^5, \phi_1^3$ 分别表示不同尺度卷积映射。三种卷积核对应不同空间感受范围,其中 3×3 分支侧重局部纹理描述, 5×5 分支兼顾局部结构与邻域上下文, 7×7 分支更有利于建模较大范围的空间关系。

为抑制冗余响应并提高多尺度特征融合的自适应性,本文引入门控融合机制对三条分支的输出进行动态加权。设各分支权重分别为 ω_1, ω_2 和 ω_3 , 则第 1 阶段的融合结果为:

$$\begin{cases} F_1 = \omega_1 F_1^7 + \omega_2 F_1^5 + \omega_3 F_1^3 \\ \omega_1 + \omega_2 + \omega_3 = 1 \end{cases}. \quad (8)$$

第 2 阶段以 F_1 为输入,采用与第 1 阶段相同的三分支卷积和门控融合策略,得到阶段输出 F_2 。这种逐阶段的动态编码方式能够根据当前特征分布自动调整不同尺度分支的贡献,有利于增强对复杂空间结构的适应能力。

在第 3 阶段中,三条分支进一步采用空洞卷积,以在控制参数量的同时扩大有效感受野,分别得到 F_3^7, F_3^5, F_3^3 最终将三条分支输出在通道维进行拼接,形成卷积分支的高层多尺度表示:

$$F_c = \text{Concat}(F_3^7, F_3^5, F_3^3). \quad (9)$$

MDCE 通过多尺度卷积、动态门控融合和末级空洞扩张,实现了从局部细节到大范围空间上下文的层次化表征。

2.4 残差图卷积加权聚合模块

在 HFRCGFN 中,图卷积分支的深层语义建模由残差图卷积加权聚合 RGCWA 模块完成,其结构如图 4 所示,该模块通过多层残差图卷积与跨层加权聚合相结合,在增强节点局部邻域传播能力的同时,充分利用不同层级图特征中的结构信息,从而提升图分支的层次表达能力。

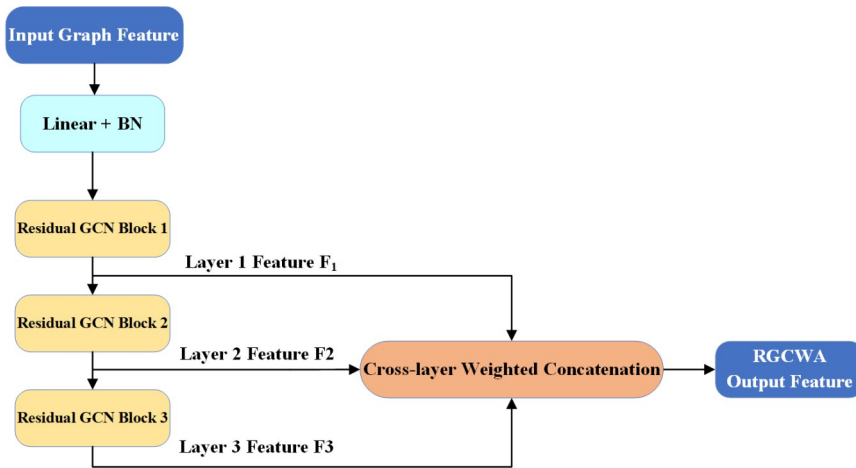


图 4 RGCWA 结构

Fig. 4 Structure of the RGCWA module

设图分支输入特征为 \tilde{V} 。首先,通过线性映射与归一化得到初始节点表示:

$$H_0 = \text{BN}(W_0 \tilde{V}), \quad (10)$$

其中 W_0 为线性映射权重矩阵, $\text{BN}(\cdot)$ 表示批归一化操作。

随后,将初始节点表示依次输入 3 个残差图

卷积块。第 l 层图卷积输出可表示为:

$$H_l = \text{ResGCN}_l(H_{l-1}, A). \quad (11)$$

其中 A 为图邻接矩阵 $\text{ResGCN}_l(\cdot)$ 表示带残差连接的图卷积操作, l 取值为 1, 2, 3。该结构能够在传播节点邻域信息的同时保留浅层特征,从而缓解深层图网络中的过平滑现象。

考虑到不同层图卷积特征具有不同的结构

感受范围,本文对3层输出进行跨层加权拼接,得到图分支高层表示:

$$F_g = \text{Concat}(\beta_1 H_1, \beta_2 H_2, \beta_3 H_3). \quad (12)$$

其中, β_1 、 β_2 和 β_3 为归一化后的自适应权重系数。该设计可同时保留浅层局部邻域关系、中层区域上下文信息和深层全局结构语义,从而增强图分支对长程依赖关系和区域拓扑结构的表征能力。

综上,RGCWA通过“残差图卷积—跨层加权聚合”的方式,有效融合了不同深度的图结构

特征,提升了图卷积分支对局部与全局结构信息的联合建模能力。

2.5 跨分支注意力融合模块

在获得卷积分支输出 F_c 和图卷积分支输出 F_g 后,引入跨分支注意力融合模块 CAFM 完成双分支特征融合,其结构如图5所示。与直接拼接两路特征不同,CAFM首先对卷积分支和图卷积分支进行跨分支交互建模,再通过注意力重标定突出关键响应区域,从而提升卷积特征与图特征之间的互补融合能力。

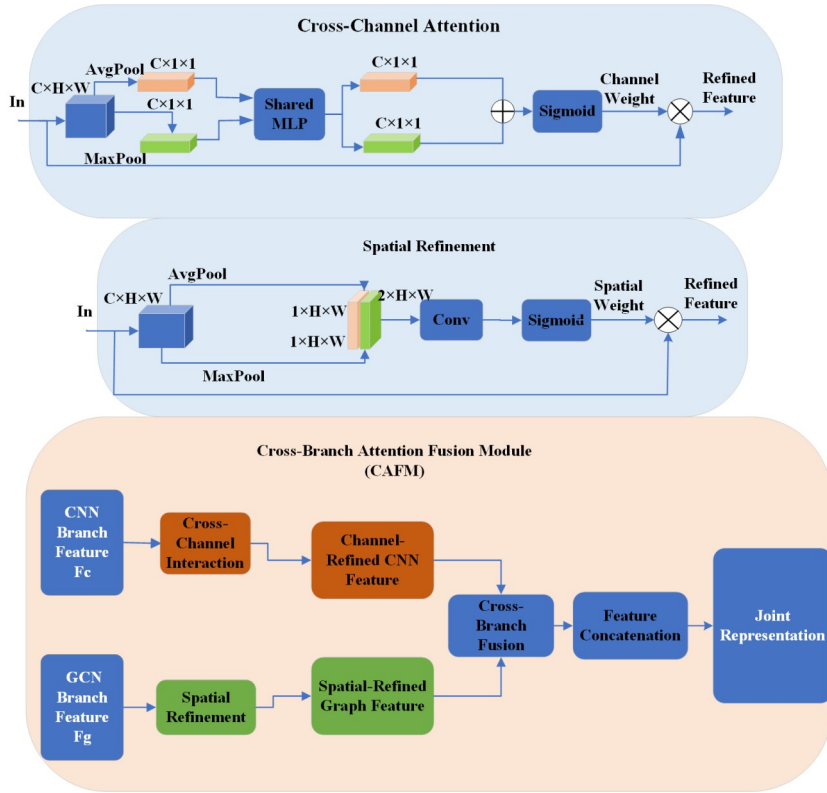


图5 CAFM结构

Fig. 5 Structure of the CAFM module

其中, $f_c(\cdot)$ 和 $f_g(\cdot)$ 分别表示卷积分支和图卷积分支的跨分支映射函数。 \tilde{F}_c 和 \tilde{F}_g 表示跨分支交互后的特征, \bar{F}_c 和 \bar{F}_g 表示经注意力重标定后的增强特征。通过该交互过程,卷积分支能够引入图结构上下文信息,图卷积分支也能够吸收卷积分支中的局部细节表达,从而增强双分支特征之间的相关性建模能力。为进一步突出关键空间位置,CAFM对交互后的两路特征执行空间重标定。

具体地,通过注意力权重图 M_c 和 M_g 分别对两路特征进行加权增强,得到:

$$\begin{cases} \bar{F}_c = \tilde{F}_c + M_c \odot \tilde{F}_c \\ \bar{F}_g = \tilde{F}_g + M_g \odot \tilde{F}_g \end{cases}, \quad (14)$$

其中, \odot 表示逐元素乘法。该过程能够增强对判别性空间区域和关键结构响应的关注,从而提高融合特征的有效性。最后,将增强后的两路特征进行拼接,得到联合表示:

$$F_{\text{joint}} = \text{Concat}\left(\bar{F}_g, \bar{F}_c\right). \quad (15)$$

由此可见,CAF_M通过跨分支交互与注意力重标定相结合,有效促进了卷积特征与图结构特征之间的信息互补,为后续分类输出提供了更具判别性的联合表示。

2.6 分类输出与损失函数

在输出阶段,将联合特征 F_{joint} 输入全连接分类层,并经 *Softmax* 得到各类别的预测概率:

$$P = \text{Softmax}\left(\mathbf{W}F_{\text{joint}} + \mathbf{b}\right), \quad (16)$$

其中, \mathbf{W} 和 \mathbf{b} 分别为分类层权重和偏置。对于 M 类分类任务,设样本真实标签为 one-hot 向量 \mathbf{y} , 预测结果为 P , 则采用交叉熵损失函数作为优化目标:

$$K = -\left(\sum_{m=1}^M y_m \log P_m\right). \quad (17)$$

通过上述分类输出过程,HFRCGF_N 可将卷积分支提取的局部谱-空特征与图卷积分支建模的区域拓扑结构特征进行统一判别,实现高光谱图像分类,其中,最终预测结果对应输入谱-空邻域块中心像素的类别标签。

3 实验结果及分析

3.1 实验设置与数据集

所有实验均在 Windows 11、Python 3.12、PyTorch 2.8.0+CUDA 12.9 环境下完成,硬件平台为 Intel i5-12600KF CPU 和 NVIDIA GeForce RTX 5070 Ti GPU,优化器采用 Adam,学习率设为 0.0005,训练轮数为 500。为验证模型在不同类型高光谱遥感分类任务中的有效性,实验选取 Indian Pines、Pavia University 和 Salinas 3 个公开数据集,分别对应农业种植与乡村混合场景、城市地物精细分类场景和大规模农田种植场景。3 个数据集分别包含 16、9 和 16 个类别,标注样本数分别为 10 366、42 776 和 54 129。考虑到小样本分类场景,Indian Pines 数据集按每类 2%/2%/96% 划分为训练集、验证集和测试集,Pavia University 与 Salinas 数据集按每类 0.2%/0.2%/99.6% 划分。各数据集的基本信息与样本划分统计见表 1~4。

3.2 对比实验

表 1 实验数据集

Tab. 1 Experimental datasets

| 数据集名称 | 图像大小 | 波长/ μm | 波段数 | 空间分辨率/ m |
|--------------|---------|-----------|-----|-------------|
| Indian Pines | 145×145 | 0.40~2.50 | 200 | 20.0 |
| PU | 610×340 | 0.43~0.86 | 103 | 1.3 |
| Salinas | 512×217 | 0.40~2.50 | 204 | 3.7 |

表 2 Indian Pines 数据集划分

Tab. 2 Sample partition of the Indian Pines dataset

















| 类别 | 颜色 | 类别名 | 训练 | 验证 | 测试 |
|----|---|-----------------------------|-----|-----|-------|
| 1 |  | Alfalfa | 1 | 1 | 44 |
| 2 |  | Corn-notill | 29 | 29 | 1 370 |
| 3 |  | Corn-mintill | 17 | 17 | 796 |
| 4 |  | Corn | 5 | 5 | 227 |
| 5 |  | Grass-pasture | 10 | 10 | 463 |
| 6 |  | Grass-trees | 15 | 15 | 700 |
| 7 |  | Grass-pasture-mowed | 1 | 1 | 26 |
| 8 |  | Hay-windrowed | 10 | 10 | 458 |
| 9 |  | Oats | 1 | 1 | 18 |
| 10 |  | Soybean-notill | 20 | 20 | 952 |
| 11 |  | Soybean-mintill | 50 | 50 | 2 355 |
| 12 |  | Soybean-clean | 12 | 12 | 569 |
| 13 |  | Wheat | 5 | 5 | 195 |
| 14 |  | Woods | 26 | 26 | 1 213 |
| 15 |  | Building-Grass-Trees-Drives | 8 | 8 | 370 |
| 16 |  | Stone-Steel-Towers | 2 | 2 | 89 |
| 总计 | | | 212 | 212 | 9 845 |

表 3 Pavia University 数据集划分

Tab. 3 Sample partition of the Pavia University dataset


























| 类别 | 颜色 | 类别名 | 训练 | 验证 | 测试 |
|----|---|--------------|----|----|--------|
| 1 |  | Asphalt | 14 | 14 | 6 555 |
| 2 |  | Meadows | 38 | 38 | 18 573 |
| 3 |  | Gravel | 5 | 5 | 2 089 |
| 4 |  | Trees/Grass | 7 | 7 | 3 050 |
| 5 |  | Metal sheets | 3 | 3 | 1 339 |
| 6 |  | Bare soil | 11 | 11 | 5 007 |
| 7 |  | Bitumen | 3 | 3 | 1 320 |
| 8 |  | Bricks | 8 | 8 | 3 666 |
| 9 |  | Shadows | 2 | 2 | 938 |
| 总计 | | | 91 | 91 | 42 573 |

表4 Salinas数据集划分

Tab. 4 Sample partition of the Salinas dataset

| 类别 | 颜色 | 类别名 | 训练 | 验证 | 测试 |
|----|---|---------------------------|-----|-----|--------|
| 1 |  | Broccoli green weeds 1 | 5 | 5 | 1 999 |
| 2 |  | Broccoli green weeds 2 | 8 | 8 | 3 710 |
| 3 |  | Fallow | 4 | 4 | 1 968 |
| 4 |  | Fallow rough plow | 3 | 3 | 1 388 |
| 5 |  | Fallow smooth | 6 | 6 | 2 666 |
| 6 |  | Stubble | 8 | 8 | 3 943 |
| 7 |  | Celery | 8 | 8 | 3 563 |
| 8 |  | Grapes untrained | 23 | 23 | 11 225 |
| 9 |  | Soil vinyard develop | 13 | 13 | 6 177 |
| 10 |  | Corn senesced green weeds | 7 | 7 | 3 264 |
| 11 |  | Lettuce romaine 4wk | 3 | 3 | 1 062 |
| 12 |  | Lettuce romaine 5wk | 4 | 4 | 1 919 |
| 13 |  | Lettuce romaine 6wk | 2 | 2 | 912 |
| 14 |  | Lettuce romaine 7wk | 3 | 3 | 1 064 |
| 15 |  | Vinyard untrained | 15 | 15 | 7 238 |
| 16 |  | Vinyard vertical trellis | 4 | 4 | 1 807 |
| 总计 | | | 116 | 116 | 53 879 |

在实验中,本文采用总体分类精度(overall accuracy, OA)、平均分类精度(average accuracy, AA)以及Kappa系数作为评价指标。OA、AA和Kappa取值越大,表示模型分类性能越好。为保证实验公平性,所有对比方法均基于公开可用代码,在相同实验环境和尽可能一致的参数设置下进行复现与比较。

为验证所提方法的有效性,本文将HFRCG-FN与2DCNN^[20]、FDSSC^[21]、MCTGCL^[22]、CEGCN^[23]和AMGCFN^[18]等代表性方法进行对比。其中,2DCNN和FDSSC主要属于卷积建模方法,MCTGCL结合了卷积、Transformer与图对比学习机制,CEGCN和AMGCFN则属于卷积与图结构协同建模方法。每种方法均独立运行10次,并取10次实验结果的平均值作为最终结果。表5~表7给出了各模型在3个数据集上的OA、AA和Kappa对比结果。

从表5~表7可以看出,HFRCGFN在3个公开高光谱数据集上均取得了稳定且具有竞争力的分类结果,并在多个核心指标上表现出较强的综合竞争力。其中,在Indian Pines数据集上,OA和Kappa系数均为最优;在Pavia University数据集上,OA达到最优;在Salinas数据集上,OA、AA和Kappa均达到最优。结果表明,所提方法在不同类型高光谱分类场景下具有较好的综合分类性能,尤其在Indian Pines和Salinas数据集上优势更为明显。

在Indian Pines数据集上,由于类别分布不均衡且训练样本极少,模型需要同时具备较强的局部细节提取能力和全局结构建模能力。HFRCGFN取得了92.94%的OA、88.66%的AA和91.94%的Kappa,在总体分类精度和Kappa系数上均为最优,说明该方法在复杂农业小样本场景下具有较好的整体判别能力和分类一致性。需

表5 各方法在Pavia University数据集上的分类精度对比

Tab. 5 Classification accuracy comparison of different methods on the Pavia University dataset

| NO. | 2DCNN | CEGCN | FDSSC | MCTGCL | AMGCFN | HFRCGFN |
|----------|-------------|------------|------------|------------|-------------|-------------------|
| 1 | 80.81±12.01 | 96.02±1.76 | 95.73±3.22 | 90.84±3.41 | 92.08±6.06 | 94.50±3.55 |
| 2 | 96.59±2.09 | 97.28±1.31 | 97.13±2.01 | 99.28±0.48 | 99.86±0.13 | 99.46±0.76 |
| 3 | 35.70±13.95 | 85.28±6.83 | 74.77±7.26 | 75.84±5.45 | 81.33±12.70 | 86.01±10.86 |
| 4 | 81.53±8.99 | 83.71±5.83 | 91.41±5.81 | 77.54±4.12 | 83.03±10.65 | 81.94±7.92 |
| 5 | 94.45±5.23 | 98.12±0.11 | 99.84±0.36 | 99.88±0.16 | 98.56±3.12 | 99.94±0.16 |
| 6 | 69.73±23.13 | 96.47±2.15 | 98.27±2.04 | 98.03±2.55 | 97.91±2.38 | 99.21±1.08 |
| 7 | 69.16±12.14 | 95.68±2.42 | 94.32±3.12 | 90.69±3.89 | 90.70±9.03 | 86.72±18.63 |
| 8 | 73.44±8.37 | 94.86±3.53 | 90.62±9.68 | 84.03±5.54 | 94.27±4.21 | 94.70±4.03 |
| 9 | 93.39±6.87 | 88.64±5.80 | 97.59±1.71 | 92.85±4.80 | 76.43±17.57 | 61.28±18.33 |
| OA(%) | 83.94±4.93 | 95.01±0.51 | 94.99±0.58 | 93.42±0.89 | 94.98±1.69 | 95.11±1.23 |
| AA(%) | 77.20±4.83 | 92.90±1.01 | 93.30±1.26 | 89.89±3.38 | 90.46±3.95 | 89.31±2.71 |
| Kappa(%) | 78.33±7.04 | 93.97±0.67 | 93.38±0.76 | 91.24±1.17 | 93.32±2.26 | 93.50±1.64 |

表6 各方法在 Indian Pines 数据集上的分类精度对比

Tab. 6 Classification accuracy comparison of different methods on the Indian Pines dataset

| NO. | 2DCNN | CEGCN | FDSSC | MCTGCL | AMGCFN | HFRCGFN |
|----------|-------------|-------------|-------------|-------------|-------------|-------------------|
| 1 | 29.56±14.37 | 5.45±5.40 | 68.21±39.84 | 98.14±0.93 | 82.32±17.86 | 70.14±8.26 |
| 2 | 58.08±28.77 | 86.17±3.77 | 88.13±5.02 | 85.32±1.95 | 92.30±2.00 | 92.88±3.26 |
| 3 | 43.46±28.28 | 84.51±4.71 | 84.97±9.88 | 89.51±3.04 | 90.17±4.20 | 89.53±5.46 |
| 4 | 39.18±20.38 | 47.05±12.87 | 87.25±27.94 | 77.07±5.81 | 93.35±7.47 | 91.86±8.45 |
| 5 | 79.77±12.01 | 89.22±5.16 | 97.86±3.42 | 83.28±0.34 | 89.42±6.11 | 87.13±6.67 |
| 6 | 95.40±3.92 | 99.24±0.52 | 95.91±4.76 | 98.71±0.55 | 93.72±3.93 | 95.29±2.91 |
| 7 | 40.00±19.58 | 29.62±17.71 | 85.74±20.63 | 100.00±0.00 | 92.34±8.98 | 88.30±13.20 |
| 8 | 95.37±7.10 | 99.80±0.33 | 96.41±3.65 | 100.00±0.00 | 99.41±0.69 | 98.32±1.95 |
| 9 | 0.00±0.00 | 33.33±29.61 | 74.58±36.92 | 77.22±17.29 | 96.32±11.05 | 77.95±27.71 |
| 10 | 62.34±32.25 | 86.01±4.38 | 84.89±13.17 | 92.07±1.63 | 86.09±5.93 | 89.98±3.15 |
| 11 | 72.04±27.38 | 95.69±1.92 | 89.76±6.83 | 95.78±1.35 | 96.49±1.48 | 96.59±1.16 |
| 12 | 37.80±15.94 | 75.82±13.81 | 86.95±5.94 | 76.43±5.17 | 80.27±11.65 | 83.64±5.31 |
| 13 | 82.04±17.13 | 99.44±0.74 | 97.18±4.02 | 97.77±0.82 | 95.47±6.93 | 91.34±8.73 |
| 14 | 87.15±28.35 | 99.18±1.62 | 94.11±2.97 | 99.13±0.32 | 97.66±1.25 | 97.72±3.91 |
| 15 | 65.63±21.60 | 71.03±14.81 | 95.03±5.16 | 96.67±1.03 | 92.03±6.71 | 87.96±9.13 |
| 16 | 81.54±21.81 | 77.19±21.51 | 96.88±3.01 | 93.71±2.72 | 90.53±11.99 | 79.91±11.25 |
| OA(%) | 68.73±12.79 | 89.12±1.96 | 89.34±3.12 | 92.18±0.36 | 92.83±0.91 | 92.94±1.01 |
| AA(%) | 60.59±10.44 | 73.67±4.44 | 88.76±4.55 | 91.30±2.69 | 91.74±2.19 | 88.66±3.07 |
| Kappa(%) | 64.24±14.35 | 87.51±2.28 | 87.95±3.68 | 91.08±0.41 | 91.82±1.05 | 91.94±1.16 |

表7 各方法在 Salinas 数据集上的分类精度对比

Tab. 7 Classification accuracy comparison of different methods on the Salinas dataset

| NO. | 2DCNN | CEGCN | FDSSC | MCTGCL | AMGCFN | HFRCGFN |
|----------|-------------|-------------|-------------|-------------|-------------|--------------------|
| 1 | 74.66±36.02 | 99.26±1.56 | 99.03±2.06 | 99.99±0.02 | 99.05±1.42 | 99.35±0.86 |
| 2 | 98.25±3.12 | 100.00±0.00 | 100.00±0.01 | 99.91±0.19 | 99.85±0.22 | 99.91±0.17 |
| 3 | 82.99±29.30 | 96.37±6.84 | 95.01±11.69 | 100.00±0.00 | 98.34±3.45 | 98.31±3.37 |
| 4 | 89.41±29.69 | 97.34±6.30 | 97.93±3.89 | 99.38±0.54 | 96.42±1.83 | 97.69±3.90 |
| 5 | 87.64±29.28 | 98.67±1.15 | 97.38±1.49 | 98.17±0.42 | 90.09±6.59 | 90.69±9.15 |
| 6 | 88.54±29.45 | 99.63±0.48 | 99.85±0.39 | 99.79±0.31 | 98.54±2.04 | 99.49±0.84 |
| 7 | 88.28±29.45 | 99.91±0.14 | 99.86±0.19 | 99.99±0.01 | 99.40±1.00 | 99.56±0.77 |
| 8 | 83.30±6.40 | 92.97±2.20 | 93.05±2.53 | 77.79±3.43 | 91.41±3.57 | 95.21±2.14 |
| 9 | 99.88±0.09 | 100.00±0.00 | 100.00±0.01 | 99.89±0.10 | 99.94±0.14 | 100.00±0.00 |
| 10 | 75.30±26.05 | 92.09±6.42 | 90.76±7.51 | 94.62±2.18 | 95.52±3.97 | 97.23±2.43 |
| 11 | 62.66±27.84 | 97.18±2.71 | 98.74±2.14 | 99.99±0.03 | 92.80±7.15 | 96.76±3.66 |
| 12 | 84.83±28.71 | 99.66±0.93 | 99.98±0.03 | 99.54±0.38 | 98.01±2.89 | 99.72±0.41 |
| 13 | 86.50±29.01 | 94.58±9.08 | 97.70±3.28 | 98.93±1.12 | 97.11±3.06 | 98.72±1.45 |
| 14 | 84.21±28.42 | 97.71±1.98 | 98.58±1.34 | 99.20±0.48 | 94.35±10.03 | 98.45±1.07 |
| 15 | 63.65±23.35 | 91.82±6.17 | 86.03±3.70 | 89.39±5.88 | 91.94±7.11 | 96.20±5.36 |
| 16 | 92.19±7.11 | 95.63±4.12 | 94.05±5.10 | 99.59±0.29 | 96.41±10.14 | 99.56±0.89 |
| OA(%) | 83.87±14.05 | 96.28±0.95 | 95.40±0.66 | 93.41±0.55 | 95.52±0.71 | 97.50±1.00 |
| AA(%) | 83.89±19.75 | 97.05±0.87 | 96.75±0.56 | 97.26±0.96 | 96.20±1.22 | 97.93±0.64 |
| Kappa(%) | 81.79±16.36 | 95.86±1.06 | 94.88±0.73 | 92.68±0.61 | 95.02±0.79 | 97.22±1.11 |

要指出的是,本文方法在该数据集上的AA并非最优,表明其在部分类别的均衡识别方面仍有进一步提升空间。

在Pavia University数据集上,该场景主要面向城市地物精细分类,具有空间分辨率高、地物边界清晰但局部纹理差异复杂的特点。HFRCGFN在该数据集上的优势主要体现在整体分类精度提升上,取得了95.11%的OA,而在平均分类精度和类别一致性方面仍有进一步提升空间。结合表5可以看出,在极低标注比例下,Metal sheets、Bitumen和Shadows等类别训练样本极少,且Bitumen和Shadows类别识别结果相对较弱,这在一定程度上影响了AA和Kappa表现。因此,本文方法在该数据集上的效果更多体现为整体判别能力的提升,而在少样本类别的均衡识别方面仍需进一步加强。

对于Salinas数据集,由于同类区域分布更加集中,地物内部一致性较强,卷积特征与图结构特征的协同优势能够得到更充分发挥。HFRCGFN在该数据集上取得了97.50%的OA、97.93%的AA和97.22%的Kappa,3项指标均达到最优,表明所提方法能够兼顾边缘细节、空间上下文与区域拓扑结构信息的联合表征,在区域结构清晰、类内一致性较强的农田场景中具有

更明显的优势。

综合3个数据集的实验结果可以看出,HFRCGFN的优势主要体现在整体分类精度提升以及不同类型典型高光谱分类场景下较强的综合竞争力上。一方面,高低频残差增强有助于兼顾边缘细节与区域结构信息;另一方面,跨层图卷积加权聚合与跨分支注意力融合增强了卷积局部特征与图结构特征之间的互补建模能力。与此同时,在Pavia University等极少样本类别占比较高的场景中,模型在平均类别精度和类别均衡识别方面仍存在一定提升空间。总体而言,HFRCGFN能够在农业小样本混合场景、城市地物精细分类场景和农田连片种植场景中取得较好的综合结果,验证了所提网络结构设计的有效性。

3.3 分类可视化结果分析

图6~图8给出了不同算法在3个数据集上的分类可视化结果。总体来看,HFRCGFN在同类区域内部完整性、边界过渡和噪声抑制方面表现较好。为便于比较不同方法的局部分类差异,图中以红色矩形框标记了相同区域。由图可见,HFRCGFN在局部区域的分类结果更接近真实标注,在小区域地物和边缘过渡区域的误分类现象相对较少。

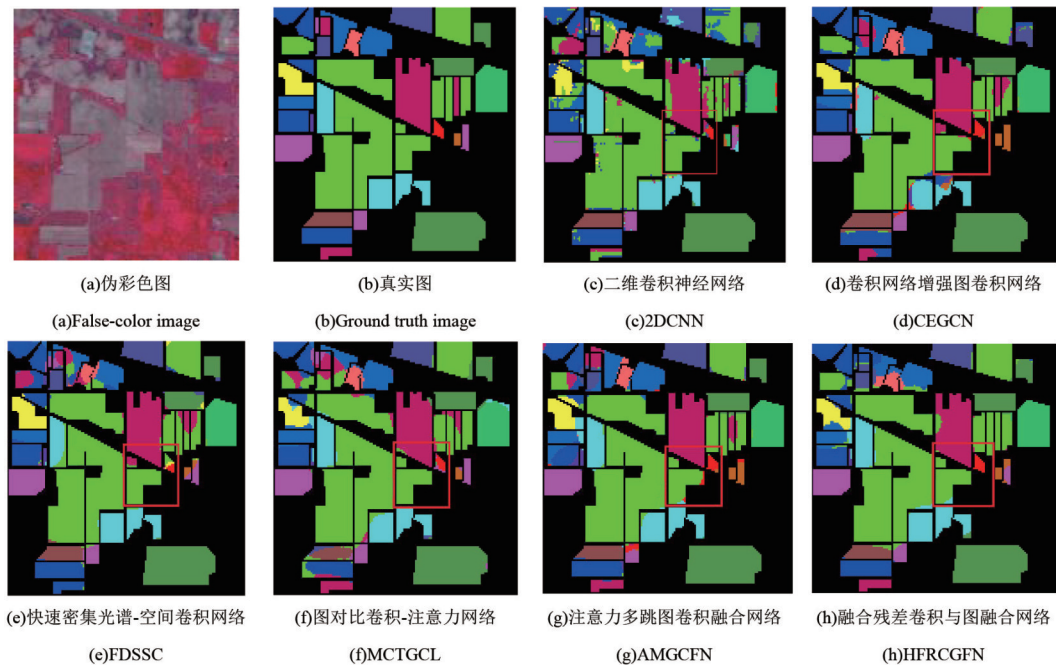


图6 不同算法在Indian Pines数据集上的分类结果

Fig. 6 Classification results of different algorithms on the Indian Pines dataset

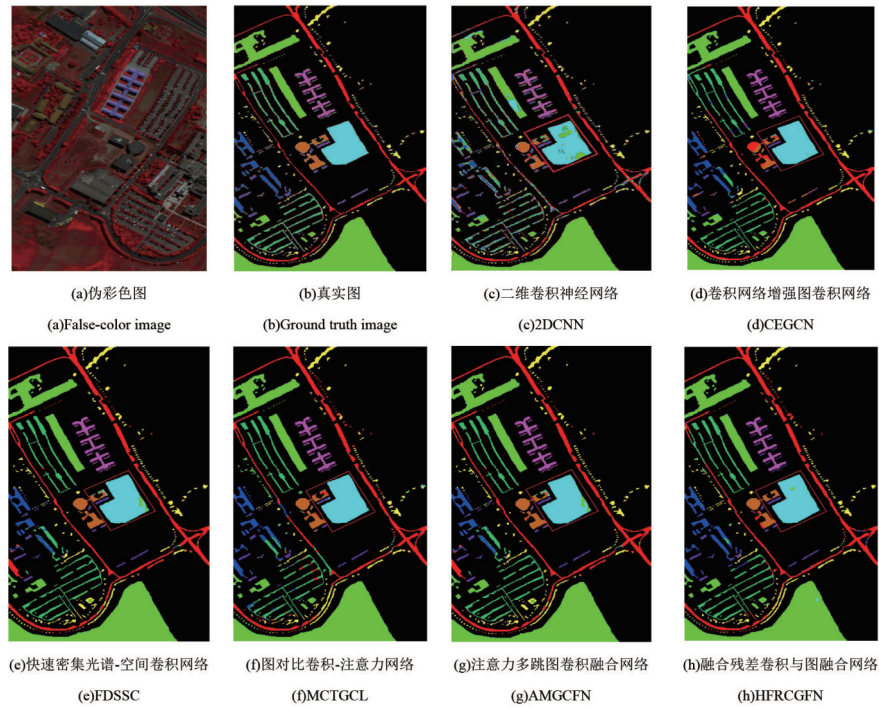


图7 不同算法在Pavia University数据集上的分类结果

Fig. 7 Classification results of different algorithms on the Pavia University dataset

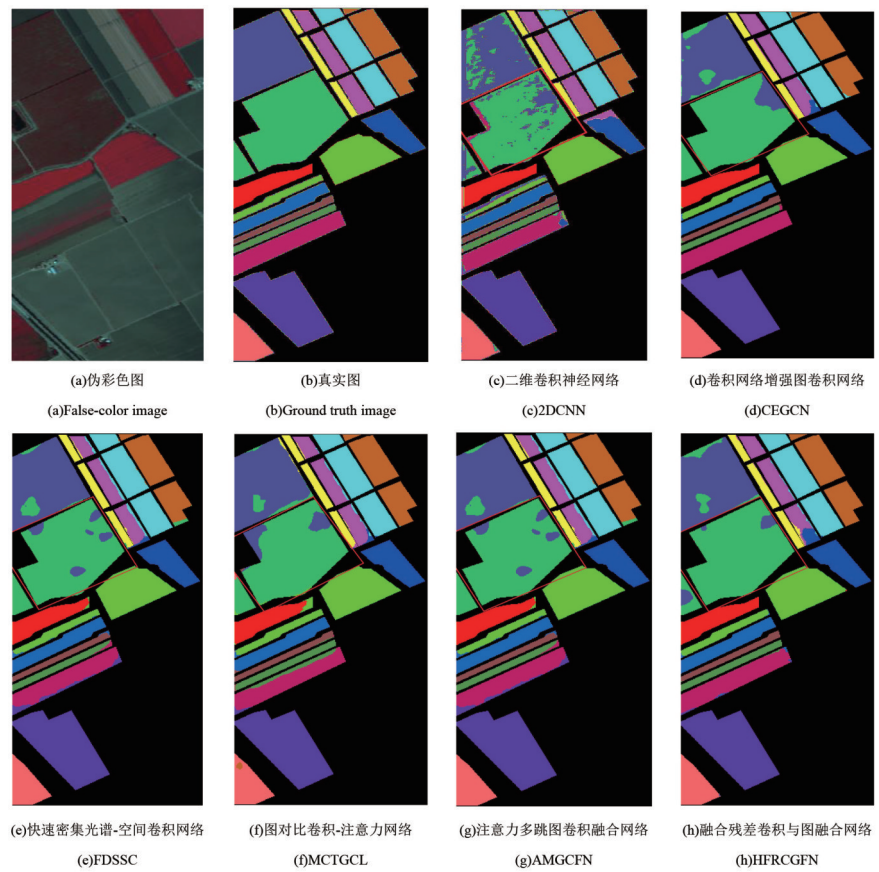


图8 不同算法在Salinas数据集上的分类结果

Fig. 8 Classification results of different algorithms on the Salinas dataset

3.4 消融实验

为验证各关键模块对模型性能的贡献,本文

采用逐步叠加的方式对 HFDR、MDCE、RGCWA 和 CAFM 进行消融分析,结果见表 8。

表 8 不同模块组合在 3 个数据集上的 OA 对比

Tab. 8 OA comparison of different module settings on three datasets

| Setting | 1 | 2 | 3 | 4 |
|------------------|------------|------------|------------|-------------------|
| HFDR | ✓ | ✓ | ✓ | ✓ |
| MDCE | ✓ | — | ✓ | ✓ |
| RGCWA | — | ✓ | ✓ | ✓ |
| CAFM | — | — | — | ✓ |
| Indian Pines | 92.36±0.67 | 92.55±0.60 | 92.57±0.87 | 92.94±1.01 |
| Pavia University | 93.89±1.73 | 94.60±1.18 | 94.81±1.78 | 95.11±1.23 |
| Salinas | 95.04±0.71 | 96.11±0.60 | 97.13±0.47 | 97.50±1.00 |

实验表明,随着 HFDR、MDCE、RGCWA 和 CAFM 模块逐步加入,模型在 3 个数据集上的 OA 持续提升;当 4 个模块同时使用时,Indian Pines、Pavia University 和 Salinas 上的 OA 分别达到 92.94%、95.11% 和 97.50%,均为最优。这说明本文提出的各组成模块对分类性能提升具有稳定的积极作用,也表明所提方法的改进并非来源于单一模块,而是多模块协同设计共同发挥作用的结果。

3.5 模型复杂度与效率分析

为评估 HFRCGFN 的计算效率与部署代价,

采用训练时间(s/epoch)和参数量(K)对不同算法进行比较,结果如表 9 所示。HFRCGFN 的参数量为 371.0 K,明显小于 FDSSC 复杂模型,并与 AMGCFN 接近,说明本文模型在保持相对紧凑结构的同时取得了较好的分类性能。在训练效率方面,HFRCGFN 在 Indian Pines、Pavia University 和 Salinas 数据集上的单轮训练时间分别为 11.1 s、66.2 s 和 40.3 s,在 Indian Pines 数据集上具有较高的训练效率,在另外两个数据集上也保持在可接受范围内。综合分类精度与计算代价来看,HFRCGFN 在精度与效率之间取得了较好的平衡。

表 9 不同算法在 3 个数据集上的训练时间与参数量对比

Tab. 9 Comparison of training time and parameter amount of different methods on three datasets

| 数据集 | 训练时间/(s/epoch) | | | 参数量/K |
|---------|----------------|------------------|---------|--------------|
| | Indian Pines | Pavia University | Salinas | Indian Pines |
| MCTGCL | 41.1 | 45.3 | 53.1 | 239.1 |
| AMGCFN | 11.8 | 71.8 | 37.2 | 368.2 |
| 2DCNN | 75.2 | 44.2 | 40.3 | 152.5 |
| FDSSC | 125.8 | 45.6 | 65.3 | 1 230.7 |
| HFRCGFN | 11.1 | 66.2 | 40.3 | 371.0 |

4 结 论

本文提出了一种卷积-图卷积联合的高光谱图像分类模型,通过高低频残差增强提升输入特征质量,利用多尺度动态卷积编码强化不同感受野下空间-光谱特征提取,并结合跨层图特征加权聚合与跨分支注意力融合,实现了卷积特征与图结构特征

的有效联合建模。实验结果表明,本文方法在 Indian Pines、Pavia University 和 Salinas 数据集上的总体分类精度分别达到 92.94%、95.11% 和 97.50%。消融实验和复杂度分析进一步验证了模型设计的有效性,说明该方法在保持较轻量参数规模的同时具有较好的分类性能。未来将进一步围绕少样本条件下的分类性能提升、噪声干扰和光谱

失真条件下的鲁棒分类,以及不同数据场景下模型 适应能力增强等方向开展研究。

参 考 文 献:

- [1] 何明一,李强,郭英,等. 高光谱图像智能分类研究综述与展望[J]. 中国图象图形学报, 2025,30(06):2207-2238.
He M Y, Li Q, Guo Y, *et al.* Overview and prospects of intelligent classification of hyperspectral images [J]. *Journal of Image and Graphics*, 2025,30(06):2207-2238. (in Chinese)
- [2] Park J, Choi Y, Kwon S, *et al.* Microsphere-assisted hyperspectral imaging: super-resolution, non-destructive metrology for semiconductor devices[J]. *Light: Science & Applications*, 2024, 13: 122.
- [3] Cen Q, Pian S, Liu X, *et al.* Microtaper leaky-mode spectrometer with picometer resolution[J]. *eLight*, 2023, 3: 9.
- [4] Kuhn J, Lodieu N, Rebolo López R, *et al.* Creating ground-based telescopes for imaging interferometry: SELF and ELF[J]. *Light: Advanced Manufacturing*, 2025, 6: 33.
- [5] Bai L, Chen Z, Zhou L, *et al.* HSI Classification: A Comprehensive Review, Dataset, and Future Trends[J]. *Journal of the Indian Society of Remote Sensing*, 2025, 53(12): 3983-4004.
- [6] Asker M E. Hyperspectral image classification method based on squeeze-and-excitation networks, depthwise separable convolution and multibranch feature fusion[J]. *Earth Science Informatics*, 2023,16(2):1427-1448.
- [7] 景海钊,陶丽杰,张号逵. 3D-CNN与Transformer混合结构的高光谱图像空谱联合分类[J]. 光学精密工程, 2024, 32(23): 3504-3512.
JING H Z, TAO L J, ZHANG H K. Spectral-spatial classification of hyperspectral imagery with hybrid architecture of 3D-CNN and Transformer[J]. *Optics and Precision Engineering*, 2024, 32(23): 3504-3512. (in Chinese)
- [8] 刘和,宋璿珞,胡龙湘,等. 基于空间金字塔注意力机制残差网络的高光谱图像分类[J]. 液晶与显示, 2024,39(06):833-843.
LIU H, SONG Y L, HU L X, *et al.* Hyperspectral image classification based on spatial pyramid attention mechanism combined with ResNet[J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(6): 833-843. (in Chinese)
- [9] 陈海松,张康,吕浩然,等. 结合高效注意力机制的神经架构搜索高光谱图像分类[J]. 液晶与显示, 2025,40(04):630-641.
CHEN H S, ZHANG K, LYU H R, *et al.* Neural architecture search combined with efficient attention for hyperspectral image classification[J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(4): 630-641. (in Chinese)
- [10] 李英超,赵喆浩,王祺,等. 面向地物混杂背景的偏振光谱图像融合方法[J]. 中国光学, 2024, 17(05): 1098-1111.
LI Y C, ZHAO Z H, WANG Q, *et al.* Polarization spectral image fusion method for hybrid backgrounds of ground objects[J]. *Chinese Optics*, 2024, 17(05): 1098-1111. (in Chinese).
- [11] 刘敬,李银桥,刘逸. 主动学习联合聚类分组网络的高光谱遥感图像分类[J]. 光学精密工程, 2024, 32(09): 1395-1407.
LIU J, LI Y Q, LIU Y. Active learning-clustering-group convolutions network for hyperspectral images classification[J]. *Optics and Precision Engineering*, 2024, 32(09): 1395-1407. (in Chinese).
- [12] 邱敬,梁婵,刘冀钊,等. 基于跨域交互注意力和对比学习引导的红外与可见光图像融合[J]. 中国光学, 2025, 18(02): 317-332.
DI J, LIANG C, LIU J Z, *et al.* Infrared and visible image fusion guided by cross-domain interactive attention and contrastive learning[J]. *Chinese Optics*, 2025, 18(02): 317-332. (in Chinese).
- [13] 吴海滨,戴诗语,王爱丽,等. CNN-Transformer结合对比学习的高光谱与LiDAR数据协同分类[J]. 光学精密工程, 2024, 32(07): 1087-1100.
WU H B, DAI S Y, WANG A L, *et al.* Collaborative classification of hyperspectral and LiDAR data based on

- CNN-transformer[J]. *Optics and Precision Engineering*, 2024, 32(07): 1087-1100. (in Chinese)
- [14] Zhang Z T, Zhang K, Zhang C L, *et al.* LDS2MLP: A Novel Learnable Dilated Spectral-Spatial MLP for Hyperspectral Image Classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17:17207-17220.
- [15] Zhao X, Ma J, Wang L, *et al.* A review of hyperspectral image classification based on graph neural networks[J]. *Artificial Intelligence Review*, 2025, 58(6):172.
- [16] Hanachi R, Sellami A, Farah I R, *et al.* Multi-view graph representation learning for hyperspectral image classification with spectral-spatial graph neural networks[J]. *Neural Computing and Applications*, 2024, 36(7): 3737-3759.
- [17] Liu J, Li T, Zhao F, *et al.* Dual Graph Convolutional Network for Hyperspectral Images With Spatial Graph and Spectral Multigraph[J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21:1-5.
- [18] Zhou H, Luo F, Zhuang H, *et al.* Attention Multihop Graph and Multiscale Convolutional Fusion Network for Hyperspectral Image Classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61:1-14.
- [19] Gao H, Sheng R, Su Y, *et al.* Multiscale Segmentation-Guided Fusion Network for Hyperspectral Image Classification[J]. *IEEE Transactions on Image Processing*, 2025, 34:6152-6167.
- [20] Yue J, Zhao W, Mao S, *et al.* Spectral-spatial classification of hyperspectral images using deep convolutional neural networks[J]. *Remote Sensing Letters*, 2015, 6(6):468-477.
- [21] Wang W, Dou S, Jiang Z, *et al.* A fast dense spectral-spatial convolution network framework for hyperspectral images classification[J]. *Remote Sensing*, 2018, 10(7):1068.
- [22] Xi B, Zhang Y, Li J, *et al.* MCTGCL: Mixed CNN-Transformer for Mars Hyperspectral Image Classification With Graph Contrastive Learning[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63:1-14.
- [23] Liu Q, Xiao L, Yang J, *et al.* CNN-Enhanced Graph Convolutional Network With Pixel- and Superpixel-Level Feature Fusion for Hyperspectral Image Classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(10):8657-8671.

作者简介:



马 鑫,男,硕士,讲师,2017年于宁夏大学获得硕士学位,主要从事遥感图像处理方面的研究。
E-mail: 2023012@nxgs.edu.cn。