

DOI: 10.20189/j.cnki.CN/61-1527/E.202505009

多尺度卷积与超像素级图卷积融合的高光谱 图像分类网络

赵晓枫, 段永屹, 马鋆懿, 石家一, 侯榜焕, 张志利
(火箭军工程大学, 西安 710025)

摘要: 为了实现高光谱图像 (hyperspectral image, HSI) 分类中传统卷积神经网络 (convolutional neural network, CNN) 与图卷积网络 (graph convolutional network, GCN) 的优势互补以及局部特征与全局语义特征的充分融合, 提出一种基于多尺度卷积与超像素级图卷积融合的高光谱图像分类网络 (multiscale-convolutional and superpixel-level graph convolutional fusion network for hyperspectral image classification, MC-SGN), 通过采用双分支架构实现异构特征互补。多尺度卷积子网络分支通过并行 3×3 、 5×5 、 7×7 卷积核分层提取从局部细节语义到区域级空间语义的多尺度空间特征, 增强模型对复杂地物细节的感知能力; 超像素图卷积子网络分支基于简单线性迭代聚类算法实现超像素分割构建区域图结构, 并引入动态邻接矩阵学习机制, 结合多层图卷积操作自适应捕捉超像素间的长距离依赖关系, 能够在降低计算量的同时生成图像的全局空间结构信息。最后, 通过通道级联融合两类特征, 实现多尺度细节感知与结构化语义表达复合特征空间的构建。在 Indian Pines、Pavia University 和 Salinas 3 个公开数据集上进行实验, 结果表明: MCSGN 的总体分类精度 (overall accuracy, OA) 分别达到 98.31%、98.95% 和 99.35%, Kappa 系数均接近 0.98, 相较于 8 种代表性的高光谱分类方法, 其分类精度最优。

关键词: 高光谱图像; 卷积神经网络; 图卷积网络; 特征融合; 分类模型

中图分类号: TJ410

文献标志码: A

文章编号: 2097-2741(2025)05-0094-13

Multiscale-Convolutional and Superpixel-Level Graph Convolutional Fusion Network for Hyperspectral Image Classification

ZHAO Xiaofeng, DUAN Yongyi, MA Junyi, SHI Jiayi,
HOU Banghuan, ZHANG Zhili
(Rocket Force University of Engineering, Xi'an 710025, China)

ABSTRACT: To achieve the complementary advantages of the traditional convolutional neural network (CNN) and graph convolutional network (GCN), and to achieve comprehensive integra-

收稿日期: 2025-05-13

修回日期: 2025-06-17

录用日期: 2025-07-10

基金项目: 国家自然科学基金 (41404022); 国防科技 173 技术领域基金 (2021-JCJO-JJ-0871)

第一作者: 赵晓枫 (1979—), 男, 教授, 主要从事定位定向与光电防护研究。E-mail: xife_zhao@163.com

引用格式: 赵晓枫, 段永屹, 马鋆懿, 等. 多尺度卷积与超像素级图卷积融合的高光谱图像分类网络[J]. 火箭军工程大学学报, 2025, 39 (5): 94-106. ZHAO Xiaofeng, DUAN Yongyi, MA Junyi, et al. Multiscale-convolutional and superpixel-level graph convolutional fusion network for hyperspectral image classification [J]. Journal of Rocket Force University of Engineering, 2025, 39 (5): 94-106.

tion of local and global semantic features in hyperspectral image (HSI) classification, a hyperspectral image classification network based on fusion of the multi-scale and superpixel-level graph convolution network (MSGCN) for hyperspectral image classification was proposed. It achieved heterogeneous feature complementarity using a dual-branch architecture. The multi-scale convolutional sub-network branch extracted multi-scale spatial features ranging from local detail semantics to regional-level spatial semantics, by employing parallel 3×3 , 5×5 , and 7×7 convolution kernel layers, enhancing the model's ability to perceive complex ground object details. The superpixel graph convolution branch achieved superpixel segmentation and constructed regional graph structures based on the simple linear iterative clustering (SLIC) algorithm. A dynamic adjacency matrix learning mechanism was incorporated, together with multi-layer graph convolution operations, to adaptively capture long-range dependencies between superpixels. It generated global spatial structural information for the image while significantly reducing the computational load. The two types of features were fused through channel cascading, constructing a composite feature space for multi-scale detail perception and structured semantic expression. Experimental results on three public datasets, namely Indian Pines, Pavia University, and Salinas, show that the overall accuracies of MCSGN reach 98.31%, 98.95%, and 99.35%, respectively, with Kappa coefficients all exceeding 0.98. Compared with eight representative hyperspectral classification methods, the MCSGN achieves the optimal classification accuracy.

KEYWORDS: hyperspectral image; convolutional neural network; graph convolutional network; feature fusion; classification model

高光谱图像 (hyperspectral image, HSI) 分类作为遥感信息处理的核心任务, 其方法演进经历了从传统机器学习到深度特征学习的转变。早期的监督学习框架依赖光谱高维可分性假设, 以构建最优特征映射函数和超平面划分策略为核心。典型算法如逻辑回归^[1]与极限学习机^[2], 虽能实现逐像素光谱分析初步分类, 但受局部光谱波动与噪声干扰影响, 分类图斑噪声干扰显著。为突破线性可分性限制, 核函数映射机制被引入分类器设计, 如核支持向量机^[3]与多重核学习框架^[4]等方法增强了分类边界判别能力和特征表达能力, 却过度侧重分类器结构优化, 未能系统克服底层特征表征能力不足的核心缺陷。

随着研究的深入, 基于表示学习的理论体系成为技术主流, 稀疏表示^[5]、低秩约束^[6]与协同表示^[7-8]等技术分支相继出现, 通过构建光谱信号的稀疏分解模型, 揭示数据内在流形结构, 在标记样本稀缺场景下显著提升分类鲁棒性。在经典机器学习框架中, 支持向量机径向基函数^[9]、 K 近邻算法^[10]、随机森林^[11]与马尔可夫随机场^[12]构成了技术体系的核心。然而, 传统机器学习方法依赖专家驱动的特征工程策略, 需人工设计波段选择与纹理特征提取模块, 导致算法可复现性受限。

近年来, 深度学习技术凭借强大的特征捕捉能力推动高光谱图像分类研究发展。卷积神经网络 (convolutional neural network, CNN) 作为常用模型, 通过局部连接和权值共享机制有效捕捉光谱-空间联合特征, 克服了传统方法在光谱噪声抑制和特征空间异质性处理方面的不足。其技术演进呈现多维度发展趋势: 在模型架构维度, 从一维卷积神经网络^[13]演进至三维卷积神经网络^[14], 并衍生出残差网络^[15]、动态卷积网络^[16]等深度结构; 在特征表征维度, 发展了多尺度特征融合^[17]、双流卷积神经网络^[18]以及注意力机制^[19]等增强策略, 例如语义-空谱特征融合变换器^[20]通过多层级特征交互提升表征能力。然而, 传统CNN模型基于欧几里得数据的卷积运算难以捕捉复杂地物拓扑结构, 且深层网络易引发梯度消失与过拟合现象。针对此问题, 研究者提出引入图卷积网络 (graph convolutional network, GCN)^[21]将卷积的思想推广到任意结构的图中, 例如非局部图卷积网络^[22]。由于高光谱图像像素数量庞大, 难以构建以单个像素为节点的图, 因此, Wan等^[23]提出根据光谱相似性将空间距离相近的像素聚合为超像素节点, 即采用超像素分割技术, 极大地减少了图中的节点数量, 也使得自适应学习的超像素

节点突破了原始欧几里得数据结构的限制,能够更清晰地定义相邻不规则区域之间的相关性。

CNN 和 GCN 都是能够捕捉深层特征的深度学习方法,两者分别侧重于像素级特征和图结构特征。当前技术前沿主要聚焦于 CNN 与 GCN 的协同优化,然而,直接组合的混合网络存在数据结构不兼容的问题,即 CNN 获得的像素级特征无法直接与 GCN 通过超像素分割构建的图结构所提取的特征相融合。因此,需要构建一个直接融合 CNN 和 GCN 的网络,以匹配 HSI 的特性。此外,融合网络还应考虑如何在训练过程中平衡 CNN 和 GCN 2 个子网络,因为任一子网络训练不充分都会降低分类性能。现有方法如卷积神经网络增强的图卷积网络 (CNN-enhanced graph convolutional network with pixel- and superpixel-level feature fusion for hyperspectral image classification, CEGCN)^[24],通过编码和解码图结构将 CNN 和 GCN 集成到一个单一网络中。然而,CEGCN 构建的图结构较为固定,难以自适应学习超像素间的动态空间关系,且多尺度特征融合机制不够充分;多尺度动态图卷积网络^[23]通过构建多邻域图结构实现空谱特征的层次化聚合,却未充分考虑像素级局部细节信息,导致在复杂地物边界处的分类精度受限;加权特征融合网络^[25]将 CNN 的局部特征提取能力与图注意力网络^[26]的全局关系建模优势相结合,但忽略了多尺度卷积特征与图卷积特征的深度交互,且超像素分割的固定性可能引入边界误差;注意力多跳图和多尺度卷积融合网络 (hyperspectral image classification with context-aware dynamic graph convolutional network, AMGCFN)^[27]通过多跳图卷积聚合网络中的上下文信息,利用多尺度卷积网络捕获不同大小卷积核的特征,实现不同抽象层级特征的互补增强。然而,AMGCFN 却存在图卷积计算复杂度较高、未能充分探索不同尺度特征间的深度交互等问题。

为了保留卷积神经网络和图卷积网络在像素级和超像素级提取信息的优势,增强卷积神经网络提取多尺度信息的能力,并充分融合 2 种网络,提出了一种基于多尺度卷积与超像素级图卷积融合的高光谱图像分类网络 (multiscale-convolutional and superpixel-level graph convolutional fusion network for hyperspectral image classification, MCSGN),创新性工作主要有以下 3 个方面。

1) 针对传统 CNN 因单一尺寸卷积核设计而

导致的局部信息提取不足问题,提出了一种多尺度卷积子网络 (multi-scale convolutional sub-network, MCsN),通过并行运用 3×3 、 5×5 、 7×7 多个尺寸卷积核,分层提取图像的多尺度空间特征,不仅能够增强对局部细节的感知能力,还可以实现模型对不同尺度图像特征的捕捉,从而更全面地理解复杂地物的细节信息。

2) 鉴于传统 GCN 在处理高光谱图像时计算量庞大的难题,采用基于线性判别分析与简单线性迭代聚类算法的超像素分割方法来构建图结构,并设计了超像素级图卷积子网络 (superpixel-level graph convolutional sub-network, SGCsN)。SGCsN 引入动态邻接矩阵学习机制并结合双层图卷积操作,有效提取了图像的全局空间结构特征,在大幅降低计算量的同时,提升了模型对全局语义信息的把握能力。

3) 采用编码和解码图结构的方法,将 MCsN 和 SGCsN 所提取的特征信息集成到一个统一的网络中。通过通道级联策略,实现了多尺度局部特征与全局空间结构特征的充分融合,构建了一个能够同时利用 CNN 和 GCN 优势的高效分类网络,为高光谱图像分类提供了一种全新的参考。

1 卷积神经网络和图卷积神经网络模型

高光谱图像分类的核心在于有效融合光谱特征与空间结构信息。CNN 与 GCN 作为 2 类具有代表性的深度学习方法,分别擅长处理规则网格数据与非欧几里得空间关系。如图 1 所示, CNN 和基于超像素节点的 GCN 作为 2 种深层特征提取的常用方法,分别侧重于像素级和超像素级特征处理。图 1 (a) 中的 CNN 在小规模且规则的区域内部执行卷积操作,从而生成细致的像素级特征,其中蓝色区域表示采样网络的覆盖范围。图 1 (b) 中呈现的基于超像素节点的 GCN 在广泛且不规则的区域进行卷积操作,从而生成更宏观的超像素级特征。红色点表示超像素的中心,而蓝色虚线描绘的是边缘权重的分布。

1.1 卷积神经网络

CNN 作为深度学习的核心架构,通过局部连接、权值共享和层次化特征提取机制,在高光谱图像分类任务中展现出卓越的光谱-空间特征建模能力。其核心思想是通过卷积核在输入数据上的滑动操作,实现对局部区域特征的抽象与聚合。




图1 不同模型卷积采样示意

Fig. 1 Schematic of convolution sampling of different models

给定输入高光谱图像张量 $\mathbf{X} \in \mathbb{R}^{H \times W \times B}$, H 、 W 和 B 分别为高度、宽度和波段数, 给定输入特征图 $\mathbf{F}^{(l-1)} \in \mathbb{R}^{H \times W \times C}$, C 为输入维度, 卷积层操作可定义为

$$\mathbf{F}^{(l)} = f(\mathbf{W}^{(l)} * \mathbf{F}^{(l-1)} + \mathbf{b}^{(l)}) \quad (1)$$

式中: $\mathbf{F}^{(l)}$ 为输出特征图; $\mathbf{W}^{(l)} \in \mathbb{R}^{C \times C' \times k \times k}$ 为可学习卷积核, C' 为输出维度, k 为卷积核尺寸; $*$ 表示卷积操作; $f(\cdot)$ 为非线性激活函数; $\mathbf{b}^{(l)}$ 为偏置向量。批量归一化常插入卷积层, 以加速收敛:

$$\text{BN}(\mathbf{F}) = \gamma \frac{\mathbf{F} - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} + \beta \quad (2)$$

式中: μ_B 、 σ_B^2 分别为小批量均值和方差; ε 为数值稳定项, 通常取 10^{-5} ; γ 和 β 为可学习参数。

传统 CNN 在高光谱图像分类中存在双重局限性。一是其局部连接性质限制了模型捕获空间长距离依赖关系的能力, 难以有效对图像中的非欧几里得结构特征进行建模。二是固定尺寸的卷积核在面对任意形状区域时缺乏空间适应性, 难以灵活应对高光谱图像复杂多变的空间特征分布, 从而限制了分类精度的进一步提升。

1.2 图卷积网络

GCN 能够将卷积操作推广至非欧几里得空

间, 通过图结构建模节点间的复杂拓扑关系, 可有效解决 CNN 在非规则数据中建模的局限性。定义一个图结构 $\mathbf{G} = (\mathbf{V}, \mathbf{E}, \mathbf{A})$, $\mathbf{V}$ 为节点集 (节点对应像素或超像素), $\mathbf{E}$ 为边集合, $\mathbf{A}^{(l)} \in \mathbb{R}^{K \times K}$ 为邻接矩阵, 表示节点之间的连接关系 (K 为节点数)。图结构拉普拉斯算子为 $\mathbf{G} = \mathbf{D} - \mathbf{A}$, 基于图谱理论, 图傅里叶变换能够将信号投影到拉普拉斯矩阵特征基上, 得出归一化图拉普拉斯矩阵为

$$\mathbf{L}_n = \mathbf{I} - \mathbf{D}^{-1/2} \mathbf{A} \mathbf{D}^{-1/2} \quad (3)$$

式中: $\mathbf{I}$ 为单位矩阵; $\mathbf{D}$ 为度矩阵; $\mathbf{L}_n$ 为归一化拉普拉斯矩阵。拉普拉斯矩阵具有特征值非负, 且最小特征值为 0 的重要性质^[28], 能够反映图信号的局部平滑度, 是图卷积操作的基础。

图卷积操作通过聚合节点及其邻居信息来更新节点的特征表示。假设图 $\mathbf{G}$ 的输入节点特征矩阵为 $\mathbf{H}^{(l)}$, 图卷积操作的一般形式为

$$\mathbf{H}^{(l+1)} = \sigma(\hat{\mathbf{D}}_l^{-1/2} \mathbf{A}'_l \hat{\mathbf{D}}_l^{-1/2} \mathbf{H}^{(l)} \mathbf{W}_g^l) \quad (4)$$

式中: $\mathbf{A}'_l = \mathbf{A}_l + \mathbf{I}$ 为添加自连接后的邻接矩阵; $\hat{\mathbf{D}}_l$ 为对应的度矩阵; $\mathbf{W}_g^l$ 为第 l 层的可学习权重矩阵; σ 为激活函数。

GCN 在处理图结构数据方面具有独特的优势, 能够有效地捕捉节点之间的复杂关系, 并利用图的拓扑结构信息提升模型的性能。在高光谱图像分类中, GCN 可以通过构建超像素图来捕获图像的全局空间结构信息, 从而弥补传统 CNN 在处理非欧几里得数据时的不足。

2 基于多尺度卷积与超像素级图卷积融合的高光谱图像分类网络设计

2.1 MCSGN 网络架构设计

提出一种基于多尺度卷积与超像素级图卷积融合的高光谱图像分类网络, 构建了双分支异构特征互补架构。其中, MCsN 分支能够并行提取像素级多尺度局部空谱特征, 而 SGCSN 分支可以实现超像素级全局结构化特征的获取。所设计的特征融合模块采用矩阵映射和通道降维策略构建复合特征空间, 实现了多尺度局部特征与全局结构化特征的有效融合, 最终输入 Softmax 分类器生成像素级地物类别概率分布。MCSGN 能够在弥补传统 CNN 和 GCN 缺陷的同时, 实现 2 类异构特征的充分融合与分类性能的提升。

MCSGN 网络架构如图 2 所示, 输入的高光谱

图像首先经过光谱压缩与优化模块 (spectral compression and optimization module, SCOM) 进行波段降维和特征增强预处理。同时, 超像素图生成器 (superpixel graph generator, SPGG) 为 SGCsN 构建图结构基础, 解决 CNN 与 GCN 数据结构不兼容的问题。经过预处理后的特征输入至 MCsN 和 SGCsN 分支, 分别提取像素级多尺度局部特征和超像素级全局结构特征。最后, 将 2 类异构特征进行特征融合并输入到分类器中完成分类。

2.2 超像素图生成器

SPGG 模块作为整个 MCSGN 网络的前端处理模块, 负责构建图结构并定义特征转换机制。为了能够利用数据集中已标注的训练样本, 使分类模型实现对高光谱图像中所有像素标签的预测, 将高光谱图像表示为 $X \in \mathbb{R}^{H \times W \times B}$ 。首先, 为了快速生成一个兼具光谱判别性与空间连续性的超像素图结构, SPGG 模块应用线性判别分析方法对高光谱图像进行降维预处理。SPGG 采用线性判别分析投影矩阵 $W_{LDA} \in \mathbb{R}^{B \times d}$ 将原始高光谱数据 $X \in \mathbb{R}^{H \times W \times B}$ 降维至 d 维 ($d \ll B$), 即

$$Z = XW_{LDA} \in \mathbb{R}^{H \times W \times d} \quad (5)$$

式中: W_{LDA} 为通过最大化类间方差 S_B 和最小化类内方差 S_W 求解的投影矩阵 $J(W) = \frac{W^T S_B W}{W^T S_W W}$ 。而简单线性迭代聚类技术则用于将降维后的高光谱图像分割成 $K = (H \times W) / \lambda$ 个超像素, λ ($\lambda \geq 1$) 表示用于控制超像素平均大小的分割尺度, 即对降维后的 Z 执行 SLIC 算法, 生成 K 个超像素 $\{S_k\}_{k=1}^K$ 。

由于超像素内部包含的像素数量不一致, 导致网络难以直接建模。同时, 高光谱图像像素级

计算存在维度高、效率低的问题, 通过构建关联矩阵可对超像素内光谱特征进行聚合与降维, 同时利用半监督策略联合优化光谱一致性约束与空间邻接关系, 可以在降低计算复杂度的同时维持地物边界的连续性, 因此, 构建关联矩阵为 $Q \in \mathbb{R}^{N \times K}$, $N = H \times W$, 则有

$$Q_{i,k} = \begin{cases} 1, \hat{X}_i \in S_k \\ 0, \hat{X}_i \notin S_k \end{cases} \quad (6)$$

式中: $\hat{X} = \text{Flatten}(X)$, $\text{Flatten}(\cdot)$ 表示按空间维度对高光谱图像数据进行展平; $\hat{X}_i$ 为 X 中的第 i 个像素; S_k 为第 k 个超像素; $Q_{i,k}$ 为 Q 在 (i, k) 位置的。2 个空间维度被展平以组合成一个矩阵, 因此, $Q_{i,k}$ 反映了第 i 个像素元素 $\hat{X}_i$ 与第 k 个超像素元素 S_k 之间的关系。因此, 使用式 (7)、(8) 实现图空间特征 H 与像素空间特征 F 之间的转换:

$$H = \text{Encoder}(X; Q) = Q^T \text{Flatten}(X) \quad (7)$$

$$F = \text{Decoder}(H; Q) = \text{Reshapetten}(QH) \quad (8)$$

式中: $\text{Reshapetten}(\cdot)$ 表示恢复的展平数据的空间维度; 图编码器 $\text{Encoder}(\cdot)$ 表示将像素图转换为图节点; 图解码器 $\text{Decoder}(\cdot)$ 表示将超像素节点映射到像素。

针对传统图拓扑对动态空间关系建模不足的问题, 构建邻接掩码 $M \in \{0, 1\}^{K \times K}$ 用于初始拓扑约束和动态调整, 能够防止冗余连接和噪声干扰:

$$M_{k,l} = \begin{cases} 1, S_k \text{ 与 } S_l \text{ 邻接} \\ 0, S_k \text{ 与 } S_l \text{ 不邻接} \end{cases} \quad (9)$$

式中: $M_{k,l}$ 为 M 在 (k, l) 位置的值。

SPGG 利用超像素分割技术为高光谱图像生成了一个无权图, 图的节点连接关系由邻接掩码 M 来编码, 而边权重后续由超像素级图卷积子网络学习。图编码器能够将图像特征从原始空间投




图 2 MCSGN 网络模型架构

Fig. 2 Architecture of MCSGN network model

影到图结构空间, 而图解码器则能够把图节点的特征重新分配到像素的各个位置。关联矩阵与邻接掩码协同作用通过多维度特征聚合与动态结构优化, 能够显著提升模型对复杂地物结构的表征能力。此外, 邻接掩码 M 记录了土地覆盖之间的邻接关系, 与图卷积神经网络一起学习边权重。

2.3 光谱压缩与优化模块

高光谱图像的频谱信息包含了丰富的地物类别判别信息, 由于数据的高维度和复杂性, 直接处理原始频谱信息可能会导致模型的性能下降。为减少高光谱图像的光谱冗余并增强判别性, SCOM 模块采用 2 个 1×1 卷积层, 通过全波段线性组合实现高效的光谱特征压缩, 避免了传统空间卷积在初始阶段可能引入的局部偏差。SCOM 的输入为原始高光谱图像频谱信息, 输出为增强后的特征 F_{sc} 。

光谱压缩层公式为

$$F^{(1)} = \text{LeakyReLU}(\text{BN}(\text{Conv}_{1 \times 1}(X; W_1))) \in \mathbb{R}^{H \times W \times 128} \quad (10)$$

式中: $W_1 \in \mathbb{R}^{B \times 128 \times 1 \times 1}$ 为 1×1 卷积核; $\text{Conv}_{1 \times 1}$ 为 1×1 卷积操作; LeakyReLU 为激活函数, 形式为 $f(x) = \max(0, x) + \alpha \cdot \min(0, x)$, α 为控制负斜率的超参数, 当输入 $x \geq 0$ 时, 输出等于输入, 否则, 输出为 αx ; BN 为批量归一化层。 1×1 卷积主要用于调整特征图的通道数。在高光谱图像中, 可以对不同通道的信息进行线性组合, 从而实现特征的降维或升维。由于卷积核大小为 1×1 , 不会改变特征图的空间尺寸, 只会改变通道数。这种操作可以在不引入过多计算量的情况下增加模型的非线性表达能力。

特征增强层公式为

$$F_{sc} = \text{LeakyReLU}(\text{BN}(\text{Conv}_{1 \times 1}(F^{(1)}; W_2))) \in \mathbb{R}^{H \times W \times 128} \quad (11)$$

式中: $W_2 \in \mathbb{R}^{128 \times 128 \times 1 \times 1}$ 为 1×1 卷积核, 输出通道数为 128。

特征增强层则保持 128 维特征以维持表达能力, 并且每层卷积后接批量归一化和 LeakyReLU 激活函数, 负斜率为 0.1, 以加速收敛并增强非线性。SCOM 摒弃了传统 HSI 分类中复杂的 3D 卷积或空间-光谱分离卷积设计, 通过双层频谱卷积和批量归一化, 逐步优化了 HSI 的光谱特征表示, 同时抑制了噪声和冗余信息, 从而提高了特征的判别能力, 为后续的分类任务提供更有效的特征输入。

2.4 超像素级图卷积子网络

SGCsN 是 MCSGN 网络中专门用于处理超像素级图结构数据的模块, 基于图卷积网络能够有效提取非欧几里得数据信息的原理, 对超像素节点之间的复杂关系进行建模和学习。该模块接收 SCOM 模块的输出特征 F_{sc} , 通过与多尺度卷积子网络的并行协同处理, 融合局部细节与全局拓扑信息, 是 MCSGN 网络实现空谱特征深度融合的核心组件之一。

在高光谱图像分类任务中, 图像的空间上下文信息对于准确分类至关重要。SGCsN 通过图卷积操作, 能够捕捉超像素之间的长距离依赖关系, 从而挖掘图像的全局空间结构信息。具体而言, SGCsN 利用图卷积层对超像素节点的特征进行更新和传播, 使得每个节点的特征能够融合其邻接节点的信息。首先, 进行图初始化, 将 SCOM 输出特征 $F_{sc} \in \mathbb{R}^{H \times W \times 128}$ 映射至超像素节点:

$$H^{(0)} = Q^T \cdot \text{Flatten}(F_{sc}) \in \mathbb{R}^{K \times 128} \quad (12)$$

为解决传统 GCN 固定邻接矩阵难以适应复杂空间关系的问题, SGCsN 采用层间独立动态邻接矩阵学习机制, 即每层进行独立的动态邻接矩阵学习:

$$A'_l = \text{Sigmoid}((H^{(l-1)} W_1^l) (H^{(l-1)} W_2^l)^T) \odot M + I \quad (13)$$

式中: A'_l 为动态邻接矩阵; $W_1^l, W_2^l \in \mathbb{R}^{128 \times 256}$ 为邻接学习权重矩阵; $\odot$ 为哈达玛积 (逐元素相乘); Sigmoid 函数将权重归一化至 $[0, 1]$ 区间, 实现边权重的软调整。

多层图卷积公式为

$$H^{(l)} = \text{LeakyReLU}(\hat{D}_l^{-1/2} A'_l \hat{D}_l^{-1/2} H^{(l-1)} W_g^l) \quad (14)$$

式中: $\hat{D}_l$ 为度矩阵, 对角元素 $\hat{D}_{l,ii} = \sum_j A'_{l,ij}$; W_g^l 为

第 l 层图卷积权重矩阵。在动态权重学习方面, 每层独立学习邻接矩阵 A'_l 可以增强对 HSI 内容的适应性。而多层图卷积可以避免单层表达能力的不足, 多次图卷积操作能够不断地聚合和传播节点特征, 从而生成具有全局上下文信息的超像素级特征表示。SGCsN 通过双图卷积层级联架构, 首层提取空间结构特征 $H^{(1)} \in \mathbb{R}^{K \times 64}$, 次层融合全局语义特征 $H^{(2)} \in \mathbb{R}^{K \times 64}$, 为后续的分类决策提供更丰富的信息。

2.5 多尺度卷积子网络

针对单一卷积核尺寸难以捕捉多尺度空间特

征的问题,设计了一种基于深度可分离卷积的多分支结构。每个分支包含3层级联的卷积块,依次执行3层卷积块。

输入层采用 1×1 卷积调整通道数(由128降至64),得到输入层特征 F_{in} 为

$$F_{in} = \text{LeakyReLU}(\text{BN}(\text{Conv}_{1 \times 1}(F_{sc}; W_{in}))) \in \mathbb{R}^{H \times W \times 64} \quad (15)$$

深度卷积层执行 $k \times k$ 卷积,提取不同尺度局部空间特征 $F_{k \times k}^{(0)}$ 为

$$F_{k \times k}^{(0)} = \text{LeakyReLU}(\text{BN}(\text{Conv}_{k \times k}(F_{in}; W_k))) \in \mathbb{R}^{H \times W \times 64} \quad (16)$$

1×1 逐点卷积层融合通道信息为

$$F_{k \times k} = \text{LeakyReLU}(\text{BN}(\text{Conv}_{1 \times 1}(F_{k \times k}^{(0)}; W_{out}))) \in \mathbb{R}^{H \times W \times 64} \quad (17)$$

式中: $W_{in} \in \mathbb{R}^{128 \times 64 \times 1 \times 1}$ 、 $W_{out} \in \mathbb{R}^{64 \times 64 \times 1 \times 1}$ 为 1×1 卷积核, $W_k \in \mathbb{R}^{64 \times 64 \times 3 \times 3}$ 为 3×3 卷积核,输出通道均为64; $\text{Conv}_{k \times k}$ 表示卷积核尺寸为 $k \times k$ 的卷积操作。

设卷积核尺寸集合为 $K = \{3, 5, 7\}$,输入特征图为 $F_{sc} \in \mathbb{R}^{H \times W \times 128}$,则 $F_{k \times k}$ 为第 $k \in K$ 的分支输出特征图。不同大小的卷积核具有不同的感受野,能够捕捉不同尺度的图像特征。较小的 3×3 卷积核能够捕捉图像的局部细节特征,对于识别图像中的纹理和边缘信息非常有效; 5×5 的卷积核能够捕获图像的中尺度特征;而 7×7 卷积核具有较大的感受野,能够捕捉图像中的区域级特征(如农田地块的整体形状),从而为模型提供更宏观的语义特征。

除了多尺度特征提取,MCsN还实现了跨尺度信息交互。在特征融合层,不同尺度卷积核得到的特征图会在通道维度上进行拼接,得到多尺度特征拼接结果 F_{concat} ,即

$$F_{concat} = [F_{3 \times 3}; F_{5 \times 5}; F_{7 \times 7}] \in \mathbb{R}^{H \times W \times 192} \quad (18)$$

通过将不同尺度的卷积核并行使用,MCsN能够提取图像的多尺度空间特征,从而丰富特征的表达能力。这种多尺度特征融合的方式使得不同尺度的特征信息能够相互交流和融合,能够提高网络对不同大小和形状地物的识别能力,从而提升分类的准确性。

2.6 特征融合模块

MCsN输出的多尺度特征拼接结果 F_{concat} 为高维特征,包含大量冗余信息,直接使用会导致计算负担增加和过拟合风险。因此,特征融合模块

采用一个 1×1 卷积层进行特征降维,将通道数从192压缩至64。该操作通过可学习的权重矩阵 $W_J \in \mathbb{R}^{192 \times 64 \times 1 \times 1}$ 实现跨通道特征重组,得到多尺度空间特征 F_{MC} 为

$$F_{MC} = \text{Conv}_{1 \times 1}(F_{concat}; W_J) \in \mathbb{R}^{H \times W \times 64} \quad (19)$$

SGCsN输出的是超像素节点特征,而最终分类需要像素级预测,因此,需要将超像素特征映射回像素空间。特征融合模块基于SPGG预定义的关联矩阵 $Q \in \mathbb{R}^{N \times K}$ 确保超像素特征与像素位置精确对应,将 $H^{(2)} \in \mathbb{R}^{K \times 64}$ 映射至像素空间:

$$F_{graph} = Q \cdot H^{(2)} \in \mathbb{R}^{H \times W \times C_2} \quad (20)$$

式中: F_{graph} 表示映射回像素空间的超像素级结构特征,该操作通过矩阵乘法将每个超像素的特征值分配至所属像素,形成与MCsN特征空间对齐的语义特征图。

实现特征空间对齐之后,采取通道级联融合策略实现多尺度空间特征与超像素级结构特征的拼接,得到最终融合特征 F_{final} 为

$$F_{final} = [F_{MC}; F_{graph}] \in \mathbb{R}^{H \times W \times 128} \quad (21)$$

最终通过Softmax分类器生成像素级地物类别概率分布,可表示为

$$Y = \text{Softmax}(F_{final} W_c + b_c) \in \mathbb{R}^{H \times W \times N_{class}} \quad (22)$$

式中: $W_c \in \mathbb{R}^{128 \times N_{class}}$ 为分类权重矩阵; N_{class} 为地物类别数; $b_c \in \mathbb{R}^{N_{class}}$ 为偏置向量,每个类别对应一个偏置。 $\text{Softmax}(\cdot)$ 为多分类概率归一化函数; Y 为分类结果,表示每个像素位置上属于各个类别的概率。

3 实验与分析

利用3个公开的高分辨率遥感数据集,分别为Indian Pines、Pavia University和Salinas数据集,来检验MCSGN网络的分类性能。为全面评估MCSGN的性能,选取8种常见的高光谱分类方法与MCSGN网络进行比较,并选择总体准确率(overall accuracy, OA)、平均准确率(average accuracy, AA)和Kappa统计量(KPP)作为分类性能的评估指标。

3.1 数据集介绍

3.1.1 Indian Pines数据集

Indian Pines数据集是高光谱遥感分类经典基准数据集,由NASA机载可视红外成像光谱仪AVIRIS于1992年6月在美国印第安纳州农业区采

集。该区域以种植多种农作物为主, 地物类型丰富。原始图像尺寸 145×145 像素, 含 224 个光谱波段 ($400 \sim 2\,500\text{ nm}$), 剔除 24 个噪声波段后保留 200 个有效波段。此数据集共标注 16 类地物, 如玉米、牧场草地等, 总计 10 249 个标签样本, 部分类别分布不均衡。每个类别分别随机选择 5%、1% 和 94% 的样本用于训练、验证和测试。

3.1.2 Pavia University 数据集

Pavia University 数据集由德国反射光学系统成像光谱仪 ROSIS-03 获取, 其覆盖区域为意大利帕维亚大学校园及其周边地区。图像尺寸为 610×340 像素, 原始包含 115 个光谱波段, 光谱范围在 $430 \sim 860\text{ nm}$ 之间。经过剔除 12 个噪声干扰严重的波段后保留 103 个有效波段。其空间分辨率高达 1.3 m, 能够清晰区分城市地物细节, 如沥青路面、涂漆金属板和自锁砖等, 共标注 9 类地物, 总计 42 776 个样本。城市环境中的地物分布较为复杂, 不同地物之间的边界可能不够清晰, 且部分地物在光谱上存在一定的重叠。每个类别分别随机选择 0.5%、0.5% 和 99% 的样本用于训练、验证和测试。

3.1.3 Salinas 数据集

Salinas 数据集同样由 AVIRIS 传感器采集, 其覆盖的是美国加利福尼亚州萨利纳斯山谷的农业区, 图像尺寸为 512×217 像素, 原始有 224 个光谱波段, 光谱范围为 $400 \sim 2\,500\text{ nm}$, 剔除 20 个受水吸收影响的波段后, 保留的有效波段为 204 个。其空间分辨率为 3.7 m, 显著高于 Indian Pines, 能够捕捉农田作物的精细光谱特征, 共标注 16 类农作物, 如休耕地、芹菜、未修剪的葡萄植株等, 包含 54 129 个有标签样本。其中训练样本数为 480 个, 占比 0.89%, 测试样本数为 53 649 个。不同农作物在生长过程中, 其光谱特征会随着时间发生变化, 而且同一类农作物在不同种植区域也可能存在一定的光谱差异。每个类别分别随机选择 0.5%、0.5% 和 99% 的样本用于训练、验证和测试。

3.2 实验设置

3.2.1 评估指标

使用 OA、AA 和 KPP 作为定量评估指标。此外, 通过可视化分类方法对结果进行分析。

3.2.2 对比实验设置

在对比实验中, 将 MCSGN 与支持向量机 (support vector machine, SVM)^[29]、三维卷积神

经网络 (3D-CNN)^[30]、结合 2D 与 3D 卷积的混合光谱网络 (HybridSN)^[31]、基于三维卷积神经网络的光谱空间残差网络 (SSRN)^[32]、卷积神经网络增强的图卷积网络 (CEGCN)^[24]、加权特征融合网络 (weighted feature fusion of convolutional neural network and graph attention network for hyperspectral image classification, WFCG)^[25]、注意力多跳图与多尺度卷积融合网络 (AMGCFN)^[27] 以及结合图卷积网络与 Transformer 的图变换融合网络 (GTFN)^[33] 8 种代表性的高光谱图像分类方法进行比较, 以验证分析算法的分类效果。

3.2.3 参数设置

MCSGN 网络由 5 个模块组成, 各模块参数设置如表 1 所示。整个 MCSGN 网络中所有的激活函数均采用 LeakyReLU 函数, 实验使用学习率等于 0.000 5 的 Adam 优化器, 而训练的网络迭代次数为 600 次。MCSGN 网络代码实验是使用 Python-3.7 和 PyTorch-1.13.1 来完成的, 实验环境为 i7-11800H CPU。

表 1 MCSGN 架构配置

Table 1 Architecture configuration of MCSGN

模块	卷积层数	卷积核大小和输出通道数
SCOM	CNN 1	$1 \times 1 @ 128$
	CNN 2	$1 \times 1 @ 128$
SGCsN	GCN 1	@128
	GCN 2	@64
MCsN	CNN 1	$1 \times 1 @ 64$
	CNN 2	$3 \times 3 @ 64$
	CNN 3	$1 \times 1 @ 64$
	CNN 1	$1 \times 1 @ 64$
	CNN 2	$5 \times 5 @ 64$
	CNN 3	$1 \times 1 @ 64$
	CNN 1	$1 \times 1 @ 64$
	CNN 2	$7 \times 7 @ 64$
	CNN 3	$1 \times 1 @ 64$
特征融合模块	CNN 1	$1 \times 1 @ 64$
SPGG	$\lambda=100$	

3.3 对比实验结果及分析

将 MCSGN 与 8 种典型高光谱分类方法进行比较, 9 种不同方法在每个数据集上的分类准确率分别如表 2~4 所示。

由表 2 可以看出, 在 Indian Pines 数据集上, MCSGN 的总体分类精度 (OA) 达到 98.31%, 具体而言, MCSGN 在免耕玉米、净耕大豆等光谱相似性较高的类别中表现尤为突出, 表明其多尺度卷积与超像素特征融合机制能够有效区分局部细

表 2 Indian Pines数据集上的分类结果

Table 2 Classification results on the Indian Pines dataset

%

地物类别	SVM	3D-CNN	HybridSN	SSRN	CEGCN	WFCG	AMGCFN	GTFN	MCSGN
苜蓿	98.66±1.88	93.33±9.42	100.00±0.00	95.46±2.55	80.02±2.31	93.16±1.95	95.35±0.83	97.67±1.44	100.00±0.00
免耕玉米	41.14±6.51	80.76±7.72	88.18±1.00	93.89±0.63	95.09±0.64	87.73±2.23	92.94±2.05	94.33±2.58	95.16±2.32
少耕玉米	45.53±3.15	80.21±1.68	91.25±0.25	95.82±1.71	93.63±0.37	96.25±0.31	98.72±1.74	97.18±0.58	98.33±0.31
玉米	78.70±7.68	99.32±0.24	97.56±0.11	83.01±1.47	99.48±0.24	86.67±0.16	81.78±0.77	99.11±0.35	92.72±0.16
牧场草地	74.91±4.70	86.12±2.45	90.35±0.55	92.66±1.36	96.38±1.05	85.84±4.57	94.69±2.65	96.69±0.63	95.42±4.57
树草混合区	82.18±1.90	98.89±0.96	99.50±0.21	95.74±2.34	97.09±1.23	92.46±0.15	99.56±2.04	99.56±0.45	99.69±0.15
已收割牧场	97.22±3.92	100.00±0.00	87.54±4.21	96.02±3.29	100.00±0.00	92.38±4.31	92.31±0.69	88.03±1.75	100.00±0.00
风干草堆	97.44±2.37	99.01±1.40	100.00±0.00	100.00±0.00	98.62±0.72	83.24±0.12	99.77±0.67	100.00±0.00	99.88±0.12
燕麦	100.00±0.00	83.33±1.78	71.12±5.34	100.00±0.00	100.00±0.00	95.24±3.69	100.00±0.00	68.42±1.53	100.00±0.00
免耕大豆	71.34±0.84	78.42±3.44	91.75±1.76	92.18±4.16	87.84±1.62	92.73±0.33	90.87±0.87	97.04±2.94	98.97±0.33
少耕大豆	72.59±4.78	85.13±2.83	94.16±1.22	97.82±1.43	96.22±0.66	98.47±0.31	98.61±0.94	95.39±3.06	99.46±0.31
净耕大豆	47.43±1.42	72.66±4.53	94.14±0.71	76.67±3.47	80.39±0.95	86.11±0.18	93.18±0.73	95.32±3.74	99.44±0.18
小麦	99.82±3.92	99.39±0.86	100.00±0.00	100.00±0.00	98.17±0.73	99.68±0.09	100.00±0.00	97.41±0.93	98.92±0.09
森林	67.63±3.25	95.31±4.55	96.96±0.12	100.00±0.00	98.69±1.27	84.87±0.13	99.41±0.35	96.47±0.58	99.78±0.13
建筑-草地-树木-车道混合区	71.96±1.02	97.39±3.28	99.58±0.14	92.39±5.09	98.26±0.87	92.59±0.69	99.72±0.18	99.17±1.27	98.14±0.69
石钢塔	100.00±0.00	100.00±0.00	98.38±0.07	95.55±4.44	98.07±0.92	89.57±5.68	93.02±2.56	98.84±2.09	100.00±0.00
OA	66.60±0.83	86.76±3.28	94.08±0.32	94.77±1.86	94.81±0.35	91.74±2.71	96.41±0.63	96.48±0.94	98.31±0.71
AA	77.91±0.69	90.58±1.67	93.77±0.98	94.19±1.99	94.87±0.41	90.49±1.97	95.62±1.35	95.04±1.19	98.49±0.97
KPP	61.67±0.98	84.77±3.82	93.21±0.36	94.04±2.13	94.01±1.25	90.58±2.79	95.91±0.45	96.07±1.26	98.07±0.79

注：表中加粗字体为最优结果。

表 3 Pavia University数据集上的分类结果

Table 3 Classification results on the Pavia University dataset

%

地物类别	SVM	3D-CNN	HybridSN	SSRN	CEGCN	WFCG	AMGCFN	GTFN	MCSGN
沥青路面	66.98±0.41	98.39±1.52	95.94±0.65	90.80±0.61	96.15±1.04	91.61±3.62	92.74±4.45	93.76±0.43	99.18±0.44
草地	100.00±0.00	96.92±0.86	88.46±0.54	96.31±1.12	96.83±0.12	100.00±0.00	99.12±0.49	100.00±0.00	100.00±0.00
碎石	80.98±2.49	45.86±9.35	98.20±1.65	91.50±0.58	99.37±0.19	92.16±1.28	86.58±4.49	97.08±1.71	97.97±1.21
树木	34.63±4.46	85.46±2.87	98.41±1.21	98.01±1.21	92.94±1.75	72.08±6.44	78.51±0.78	78.53±1.26	96.67±1.47
涂漆金属板	99.15±0.49	98.26±1.68	100.00±0.00	99.61±0.26	99.96±0.04	99.69±0.09	98.16±0.34	99.30±0.82	99.17±0.83
裸土	57.54±2.69	84.14±1.23	94.02±1.64	94.60±0.59	95.91±0.07	97.96±1.35	91.73±5.17	95.68±0.79	99.81±0.05
沥青屋顶	95.65±2.17	95.96±3.44	99.53±0.41	97.74±0.84	99.62±0.08	97.02±1.24	90.69±4.54	98.99±0.68	98.33±1.67
自锁砖	50.97±5.07	82.58±2.58	98.51±1.18	97.17±1.10	96.35±0.12	88.29±6.24	93.63±3.34	98.13±2.38	94.53±3.85
阴影	96.57±2.68	95.81±0.95	100.00±0.00	100.00±0.00	99.51±0.27	99.89±0.08	77.74±0.93	99.77±0.49	99.62±0.27
OA	79.84±0.71	91.09±0.15	93.26±0.93	95.41±0.83	96.66±0.22	94.97±2.19	93.93±1.24	96.63±0.32	98.95±0.51
AA	75.83±3.41	87.04±1.73	97.01±2.57	96.14±0.64	97.40±0.25	93.19±1.57	89.88±1.87	95.69±0.97	98.36±0.93
KPP	70.72±1.68	88.05±0.78	91.21±1.65	93.94±0.70	95.59±0.29	93.33±2.76	91.90±1.69	95.46±0.83	98.61±0.67

注：表中加粗字体为最优结果。

表 4 Salinas数据集上的分类结果

Table 4 Classification results on the Salinas dataset

%

地物类别	SVM	3D-CNN	HybridSN	SSRN	CEGCN	WFCG	AMGCFN	GTFN	MCSGN
花椰菜田间杂草 ₁	50.15±0.45	99.40±0.89	99.51±0.54	99.80±1.01	96.52±1.72	98.62±0.65	99.13±0.88	100.00±0.00	100.00±0.00
花椰菜田间杂草 ₂	99.81±0.12	89.45±1.02	86.25±2.35	99.76±0.43	100.00±0.00	100.00±0.00	99.89±0.11	100.00±0.00	100.00±0.00
休耕地	47.04±3.83	98.73±0.96	100.00±0.00	99.85±0.47	99.93±0.07	100.00±0.00	99.21±0.79	100.00±0.00	100.00±0.00
粗犁休耕地	96.88±1.79	86.61±0.97	62.53±8.25	93.01±1.44	100.00±0.00	99.92±0.26	92.04±3.28	99.18±1.02	99.27±0.48
平整休耕地	79.42±1.70	86.11±0.71	91.36±5.28	91.31±3.07	97.30±1.72	99.01±1.54	92.07±5.71	97.36±2.92	99.54±0.04
茬地	100.00±0.00	99.04±0.48	96.48±0.92	99.32±0.56	98.79±0.90	98.99±0.50	97.31±0.10	99.91±0.11	100.00±0.00
芹菜	89.11±3.35	85.73±4.66	99.35±2.55	99.81±0.37	99.86±0.25	99.97±0.10	100.00±0.00	99.98±0.13	100.00±0.00
未修剪葡萄植株	40.45±0.67	86.04±2.16	87.38±5.36	94.45±1.48	85.28±1.77	88.36±4.22	89.15±0.85	96.53±0.46	98.85±0.29
葡萄园发育土壤	99.35±0.37	100.00±0.00	99.79±0.37	100.00±0.00	97.68±0.31	95.69±0.45	100.00±0.00	100.00±0.00	99.93±0.03
黄化玉米杂草区	71.55±1.19	95.02±1.68	93.81±3.78	98.35±1.36	96.49±0.94	97.50±0.58	97.43±0.40	96.75±2.21	99.38±0.28
生菜4周	91.08±1.59	91.16±1.03	98.59±1.54	92.19±2.48	98.72±0.43	98.78±1.54	90.48±9.24	99.41±0.58	100.00±0.00
生菜5周	67.22±1.42	70.06±6.23	80.19±8.02	96.87±1.74	99.97±0.03	96.84±0.24	91.56±2.45	99.76±0.48	99.94±0.03
生菜6周	100.00±0.00	89.39±7.89	77.08±8.33	94.06±2.94	99.28±0.39	99.81±1.45	95.93±3.52	98.55±2.06	99.66±0.23
生菜7周	80.56±2.04	30.15±4.98	96.06±3.38	92.31±0.69	99.06±0.10	98.72±1.44	97.27±0.37	99.19±1.06	99.71±0.09
粗放管理葡萄园	68.05±1.19	68.52±9.29	93.81±1.77	75.86±3.13	96.38±0.41	90.12±3.25	98.02±1.46	93.47±2.35	97.72±0.55
垂直棚架葡萄园	87.56±1.27	88.46±6.72	93.45±4.08	98.28±3.78	96.22±3.11	95.94±0.78	99.61±0.39	99.09±0.48	100.00±0.00
OA	70.46±0.45	86.53±4.04	92.06±4.34	94.20±2.11	95.69±0.53	95.13±1.24	95.83±0.06	97.95±0.59	99.35±0.17
AA	71.60±0.42	85.24±2.85	90.97±2.29	95.31±1.05	97.75±0.37	97.39±0.77	96.19±0.62	98.70±0.29	99.62±0.12
KPP	67.29±0.98	85.03±3.39	91.18±2.47	93.53±1.55	95.22±0.59	94.60±1.56	95.37±0.07	97.72±0.66	99.28±0.11

注：表中加粗字体为最优结果。

节与全局结构信息。此外，对比发现传统CNN方法（如3D-CNN）因固定卷积核限制，在复杂地物边界区域（如苜蓿）分类精度波动较大，而GCN类方法（如CEGCN、WFCG和AMGCFN）因忽略像素级细节或特征融合不足，导致局部区域（如苜蓿和净耕大豆）分类精度不足。GTFN虽引入注意力机制优化特征权重，但其动态邻接矩阵学习未与像素级特征深度耦合，在Indian Pines数据集上KPP为0.960 7，而MCSGN的KPP为0.980 7，显著优于其他方法，验证了其在类别分布不均衡场景下的鲁棒性。MCSGN通过特征空间对齐与跨尺度交互，弥补了单一网络的表征缺陷。

由表3可以看出，对于Pavia University数据集，3D-CNN受限于浅层特征提取能力，对碎石等小目标分类误差较高。AMGCFN虽引入注意力机制优化图卷积权重，但超像素分割可能破坏像

素级空间连续性，导致对树木的分类精度仅为78.51%。HybridSN虽通过三维卷积融合空谱特征，但对大规模不规则区域的建模能力有限，导致其OA显著低于MCSGN。相比之下，MCSGN在涂漆金属板和沥青道路等光谱重叠严重的类别中表现较好，表明SGCsN能够建模长距离的空间依赖，抑制城市环境中地物边界模糊的影响。值得注意的是，MCSGN的AA与KPP均为最高值，说明其在不同类别间的泛化能力更强。

由表4可以看出，在Salinas数据集上，HybridSN通过混合3D/2D卷积增强了特征表达能力，但其缺乏多尺度特征融合机制，OA为92.06%。同时，MCSGN的OA高达99.35%，已接近理论上限，且较GTFN提升1.4%。该数据集由于农作物的光谱动态变化特性，对模型的多尺度特征提取能力要求更高。实验结果显示，MCSGN在未修剪葡萄植株和生菜7周等类别中分类

误差趋近于零,验证了MCsN在捕捉作物生长周期细微差异方面的优势。此外,MCSGN在KPP上的显著优势表明,其融合机制有效降低了类别混淆概率。

3.4 消融实验结果及分析

MCSGN由SPGG、SCOM、MCsN、SGCsN 4个主要模块组成,为验证MCSGN中各模块的贡献,设计4组消融实验。由于SPGG模块对SGCsN模块的必要性,默认将这2个模块当作一个整体。不同模块组合在3个数据集上的总体分类准确率如表5所示。

表5 不同模块组合的OA指标

Table 5 OA indicators of different module combinations %

模块/数据集	实验1	实验2	实验3	实验4
SPGG	√	√	×	√
SCOM	×	√	√	√
MCsN	√	×	√	√
SGCsN	√	√	×	√
Indian Pines	92.17±0.49	83.36±0.71	85.47±0.63	98.31±0.71
Pavia University	93.21±0.42	85.53±0.18	87.22±0.53	98.95±0.51
Salinas	93.87±0.31	86.15±0.26	87.96±0.34	99.35±0.17

由表5可以看出,组合1仅移除SCOM模块时,Indian Pines的OA降至92.17%,表明光谱压缩与优化模块能显著减少冗余波段干扰,其对初始特征优化至关重要。组合2移除MCsN后,Pavia University数据集的OA降至85.53%,说明多尺度卷积对局部纹理(如沥青道路边缘)的捕获至关重要。与组合4对比发现,MCsN的引入显著提升了Salinas的OA,表明MCsN的多分支结构对局部细节捕获至关重要,在复杂农田场景中具有不可替代的作用。组合3移除SGCsN和SPGG后,在Salinas数据集上的OA降至87.96%,证明超像素级图卷积能有效建模农田作物的长程空间关联;在Pavia University数据集上的OA降低11.73%,说明SGCsN的全局空间建模能力可有效缓解城市地物边界模糊问题。同时,完整的MCSGN在3个数据集上均取得最优性能,验证了多模块协同工作的必要性。

4 结论

本文提出一种基于多尺度卷积与超像素级图

卷积融合的高光谱图像分类网络,通过多尺度卷积网络和超像素级图卷积网络的互补设计,解决了传统方法中局部细节与全局结构特征难以充分融合的问题。

多尺度卷积网络采用多尺度卷积核并行提取多层次空谱特征,能够有效捕捉不规则地物的边界信息,并通过跨尺度特征拼接提升模型对复杂场景的表征能力。超像素级图卷积网络依托图卷积网络能够有效提取非欧几里得数据信息的优势,通过结合邻接掩码与动态权重学习机制,灵活调整超像素间的空间关联性,在长距离依赖建模中显著优于传统图卷积网络。特征融合模块通过矩阵映射与通道降维策略,能够有效结合局部特征与全局语义特征的互补信息。

3个基准数据集上的实验结果表明,MCSGN在样本不均衡、光谱重叠及空间结构复杂的场景中均表现出较强的鲁棒性和分类精度。然而,MCSGN网络在复杂空间结构建模中的优异性能伴随着计算成本的提升,其动态邻接矩阵构建和多尺度并行卷积在大规模高分辨率场景(如城市遥感影像)的计算效率有待加强。

未来研究将重点探索轻量化协同优化路径,一方面,通过精简多尺度卷积分支与超像素图结构,在保持分类精度的同时显著降低计算量;另一方面,结合自监督预训练范式,利用无标注数据增强模型的泛化能力,减少对稀缺标注样本的依赖。

参考文献

- [1] LI J, BIOUCAS-DIAS J M, PLAZA A. Semi-supervised hyperspectral image segmentation using multinomial logistic regression with active learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(11): 4085-4098.
- [2] CHEN C, LI W, SU H J, et al. Spectral-spatial classification of hyperspectral image based on kernel extreme learning machine[J]. Remote Sensing, 2014, 6(6): 5795-5814.
- [3] KUO B C, HO H H, LI C H, et al. A kernel-based feature selection method for SVM with RBF kernel for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(1): 317-326.
- [4] 李广洋,寇卫利,陈帮乾,等.多核学习算法及其在高光谱图像分类中的应用研究进展[J].地球信息科

- 学学报, 2021, 23(3): 492-504.
- LI G Y, KOU W L, CHEN B Q, et al. Multiple kernel learning algorithm and its application research progress in hyperspectral image classification [J]. Journal of Geo-information Science, 2021, 23(3): 492-504.
- [5] 张明华, 罗红玲, 宋巍, 等. 基于稀疏表示和学习图正则的高光谱图像特征提取[J]. 光子学报, 2021, 50(4): 249-261.
- ZHANG M H, LUO H L, SONG W, et al. Feature extraction of hyperspectral image based on sparse representation and learning graph regularity [J]. Acta Photonica Sinica, 2021, 50(4): 249-261.
- [6] 张鹏丹, 宁纪锋. 基于混合空谱全变差和双域低秩约束的高光谱图像去噪[J]. 光子学报, 2022, 51(12): 279-293.
- ZHANG P D, NING J F. Hyperspectral image denoising based on hybrid space-spectral total variation and double domain low-rank constraint[J]. Acta Photonica Sinica, 2022, 51(12): 279-293.
- [7] SU H J, ZHAO B, DU Q, et al. Multifeature dictionary learning for collaborative representation classification of hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(4): 2467-2484.
- [8] SU H J, YU Y, DU Q, et al. Ensemble learning for hyperspectral image classification using tangent collaborative representation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(6): 3778-3790.
- [9] 赵烜赫, 潘新, 马玉宝, 等. 基于RBF-SVM的草地高光谱图像分类[J]. 扬州大学学报(农业与生命科学版), 2022, 43(1): 128-134.
- ZHAO X H, PAN X, MA Y B, et al. Grassland hyperspectral image classification based on RBF-SVM[J]. Journal of Yangzhou University (Agricultural and Life Sciences Edition), 2022, 43(1): 128-134.
- [10] GUO Y H, HAN S M, LI Y, et al. K -nearest neighbor combined with guided filter for hyperspectral image classification[J]. Procedia Computer Science, 2018, 129: 159-165.
- [11] AMINI S, HOMAYOUNI S, SAFARI A, et al. Object-based classification of hyperspectral data using random forest algorithm[J]. Geo-spatial Information Science, 2018, 21(2): 127-138.
- [12] ZHANG B, LI S S, JIA X P, et al. Adaptive Markov random field approach for classification of hyperspectral imagery[J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(5): 973-977.
- [13] HU W, HUANG Y Y, WEI L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015, 2015(1): 258619.
- [14] 张岩, 沈金悦, 邵钰奕, 等. 基于三维卷积神经网络的高光谱图像分类[J]. 计算机与数字工程, 2024, 52(3): 898-902, 949.
- ZHANG Y, SHEN J Y, SHAO Y Y, et al. Hyperspectral image classification based on three-dimensional convolutional neural network[J]. Computer & Digital Engineering, 2024, 52(3): 898-902, 949.
- [15] 易琰, 张宇航, 王清, 等. 基于改进残差网络的高光谱图像分类算法研究[J]. 兵工自动化, 2023, 42(10): 15-20.
- YI Q, ZHANG Y H, WANG Q, et al. Research on hyperspectral image classification algorithm based on improved residual network[J]. Ordnance Industry Automation, 2023, 42(10): 15-20.
- [16] 迟骋, 李向阳, 张志利, 等. 基于动态卷积的混合模型性能评估方法[J]. 火箭军工程大学学报, 2024, 38(5): 53-58, 80.
- CHI C, LI X Y, ZHANG Z L, et al. Performance evaluation method of hybrid model based on dynamic convolution[J]. Journal of Rocket Force University of Engineering, 2024, 38(5): 53-58, 80.
- [17] 邓子青, 王阳, 张兵, 等. 多尺度特征融合残差网络的高光谱地物分类[J]. 激光与光电子学进展, 2022, 59(18): 148-154.
- DENG Z Q, WANG Y, ZHANG B, et al. Hyperspectral image classification based on multi-scale feature fusion residual network[J]. Laser & Optoelectronics Progress, 2022, 59(18): 148-154.
- [18] HAO S Y, WANG W, YE Y X, et al. Two-stream deep architecture for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(4): 2349-2361.
- [19] 赵晓枫, 牛家辉, 刘春桐, 等. 基于三维注意力与混合卷积的高光谱图像分类[J]. 系统工程与电子技术, 2023, 45(9): 2673-2680.
- ZHAO X F, NIU J H, LIU C T, et al. Hyperspectral image classification based on hybrid convolution with three-dimensional attention mechanism [J]. Systems Engineering and Electronics, 2023, 45(9): 2673-2680.
- [20] SUN L, ZHAO G R, ZHENG Y H, et al. Spectral-spatial feature tokenization transformer for hyperspectral image classification[J]. IEEE Trans-

- actions on Geoscience and Remote Sensing, 2022, 60: 5522214.
- [21] 丁遥, 张志利, 赵晓枫, 等. 半监督局部特征保留图卷积高光谱图像分类[J]. 北京航空航天大学学报, 2023, 49(12): 3409-3418.
- DING Y, ZHANG Z L, ZHAO X F, et al. Semi-supervised locality preserving dense graph convolution for hyperspectral image classification[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(12): 3409-3418.
- [22] MOU L C, LU X Q, LI X L, et al. Nonlocal graph convolutional networks for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(12): 8246-8257.
- [23] WAN S, GONG C, ZHONG P, et al. Multi-scale dynamic graph convolutional network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(5): 3162-3177.
- [24] LIU Q C, XIAO L, YANG J X, 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.
- [25] DONG Y N, LIU Q W, DU B, et al. Weighted feature fusion of convolutional neural network and graph attention network for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2022, 31: 1559-1572.
- [26] WAN S, GONG C, ZHONG P, et al. Hyperspectral image classification with context-aware dynamic graph convolutional network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(1): 597-612.
- [27] ZHOU H, LUO F L, ZHUANG H P, et al. Attention multihop graph and multiscale convolutional fusion network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 5508614.
- [28] 张峰干, 何芳, 肖磊, 等. 基于拉普拉斯矩阵图的高光谱图像异常目标检测方法[J]. 火箭军工程大学学报, 2025, 39(1): 1-12.
- ZHANG F G, HE F, XIAO L, et al. Laplacian matrix graph-based anomaly target detection method for hyper-spectral graphs[J]. Journal of Rocket Force University of Engineering, 2025, 39(1): 1-12.
- [29] MELGANI F, BRUZZONE L. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(8): 1778-1790.
- [30] BEN H A, BENOIT A, LAMBERT P, et al. 3-D deep learning approach for remote sensing image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(8): 4420-4434.
- [31] 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.
- [32] 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.
- [33] YANG A T, LI M, DING Y, et al. GTFN: GCN and transformer fusion network with spatial-spectral features for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 6600115.

(编辑: 于福兴)