

文章编号 1004-924X(2026)02-0279-17

## 高斯交叉特征融合的高光谱图像分类方法

王文龙<sup>1</sup>, 王海荣<sup>1\*</sup>, 易之航<sup>1</sup>, 杨振业<sup>1</sup>, 杨建玲<sup>2</sup>

(1. 北方民族大学 计算机科学与工程学院, 宁夏 银川 750021;

2. 宁夏气象防灾减灾重点实验室(宁夏气象科学研究所), 宁夏 银川 750002)

**摘要:**针对现有高光谱图像(Hyperspectral Image, HSI)分类方法存在的局部特征和全局特征间关系不平衡问题,本文构建了高斯交叉特征融合模型。通过逐元素相乘操作实现不同特征之间的交互连接,设计了高斯交叉注意力特征融合算法,依据映射向量之间的相似度分析两种特征的内在联系,采用高斯函数量化融合权重,并通过优化关键参数实现对局部和全局特征的动态加权,从而确保两者在融合中保持均衡。为验证方法的有效性在农作物场景 Indian Pines、城市地物场景 Pavia University、农业植被场景 Salinas 和异构混合场景 LongKou 四类典型应用场景的公开数据集上进行实验,并将实验结果与 DCSST、SMESC 和 Vit-cov 等 11 种主流方法进行对比,使用总体准确度(Overall Accuracy, OA)、平均准确度(Average Accuracy, AA)和 Kappa 系数进行方法评价,本文方法的效果最佳,表明该方法在植物、人工地物和异构混合场景中的分类优势,也在一定程度上体现了方法较好的泛化能力。

**关键词:**高光谱图像分类;注意力机制;高斯函数;特征提取;特征融合

中图分类号:TP751 文献标识码:A

doi:10. 37188/OPE. 20263402. 0279

CSTR:32169. 14. OPE. 20263402. 0279

## Gaussian cross-based feature fusion method for hyperspectral image classification

WANG Wenlong<sup>1</sup>, WANG Hairong<sup>1\*</sup>, YI Zhihang<sup>1</sup>, YANG Zhenye<sup>1</sup>, YANG Jianling<sup>2</sup>

(1. College of Computer Science and Engineering, North Minzu University, Yinchuan 750021, China;

2. Ningxia Key Laboratory of Meteorological Disaster Prevention and Reduction

(Ningxia Institute of Meteorological Sciences), Yinchuan 750002, China)

\* Corresponding author, E-mail: wanghr@nmu.edu.cn

**Abstract:** To address the persistent imbalance between local and global representations in hyperspectral image (HSI) classification, a Gaussian cross-feature fusion method (GCFFM) was proposed to explicitly balance the contributions of heterogeneous cues during feature integration. Interactive couplings between local and global feature streams were established via element-wise multiplication, enabling direct cross-modulation of complementary information. Building on this interaction, a Gaussian cross-attention fusion algorithm was devised to infer intrinsic relationships from the similarity of projected feature vectors. Fu-

收稿日期:2025-09-03;修订日期:2025-10-22.

基金项目:宁夏自然科学基金项目(No. 2025AAC030032);中国气象局旱区特色农业气象灾害监测预警与风险管理重点实验室宁夏气象防灾减灾重点实验室开放研究项目(No. CAMF-202502);北方民族大学研究生教育质量提升项目(No. YJZT202424);国家自然科学基金联合基金项目(No. U22A20577)

sion weights were parameterized by a Gaussian function, and the associated key parameters were optimized end-to-end so that the model could dynamically reweight local and global features according to scene content, thereby maintaining a balanced contribution throughout the fusion process. This design targeted common failure modes in HSI classification-such as over-emphasis on fine textures at the expense of scene context or, conversely, dominance of broad context that blurred class boundaries. Comprehensive experiments were conducted on four public benchmarks-Indian Pines, Pavia University, Salinas, and LongKou-against eleven mainstream baselines, including DCSST, SMESC, and ViT-cov. Performance was evaluated by using Overall Accuracy (OA), Average Accuracy (AA), and the Kappa coefficient. The proposed method achieves the highest OA on each dataset: 96.67% on Indian Pines, 98.16% on Pavia University, 98.81% on Salinas, and 97.09% on LongKou. These gains are accompanied by consistent improvements in AA and Kappa, indicating that the model not only raises overall correctness but also enhances per-class reliability and agreement beyond chance. Overall, GCFFM delivers consistently superior classification across agricultural, urban, and heterogeneous mixed scenes, which demonstrates strong generalization and robustness. By coupling element-wise cross-feature interactions with Gaussian-parameterized attention, the method provides a principled and effective solution to balancing local detail and global context in HSI classification.

**Key words:** hyperspectral image classification; attention mechanism; Gaussian function; feature extraction; feature fusion

## 1 引言

高光谱图像是一种包含数十至数百个连续波段的遥感图像。它能全面捕捉地物的光谱信息与空间信息,被广泛应用于农业监测<sup>[1-2]</sup>、矿产勘探<sup>[3]</sup>和医学诊断<sup>[4]</sup>等领域。在实际应用中,高光谱图像分类是其重要组成部分,其目标是将每个像素进行类别标注并区分地物类型。

近年来,基于深度学习的方法被广泛应用于高光谱图像分类并取得较好效果,因为这类方法能够自动提取高维特征并支持端到端分类<sup>[5-6]</sup>。其中,卷积神经网络(Convolutional Neural Network, CNN)可以结合空间上下文信息,有效减少光谱噪声并克服光谱特征的空间变异,但针对高光谱图像地物种类繁多且特征形状差异大的场景,固定形状的卷积核难以契合特征形状。为此,MRCA<sup>[7]</sup>在标准卷积中增加随机偏移参数,使卷积核形状能随机变化,提高了复杂场景下的特征提取能力。然而,随机形状卷积核处理地物边界时会产生信息混淆和分类错误。为解决此问题,MFAF<sup>[8]</sup>设计了互补的双分支网络,结合深度可分离卷积和膨胀深度卷积技术,扩大特征捕捉范围并提升边界区域分类准确度。上述方法

通过CNN捕获局部特征,但是存在感受野限制,存在长期依赖关系捕捉不充分的问题,而图卷积网络(Graph Convolutional Network, GCN)擅长从非欧几里得结构的数据中挖掘样本特征并建立特征间的远距离关联<sup>[9]</sup>,进而弥补CNN的短板。当将GCN应用于超像素特征更新时,模型会面临像素级特征丢失的问题。为处理该问题,DMSGer<sup>[10]</sup>利用动态像素级特征更新策略,在保留像素级特征的基础上更新超像素级特征,但该方法GCN仅依赖单通道二维矩阵获取特征,限制了模型对复杂关系的捕捉能力。鉴于这一局限性,MG<sup>2</sup>A<sup>[11]</sup>采用多通道GCN结合类别引导注意力机制,提升了有标签像素的特征捕捉能力。

由于局部和全局特征在高光谱图像分类中具有互补集成的特点,特征联合表示才能实现地物精确识别<sup>[12-14]</sup>。如DGAT<sup>[15]</sup>采用加权融合策略,整合全局特征与多尺度纹理特征,实现像素与超像素特征结合,然而此方法处理同质区域时会丢失细节。为弥补上述特征缺失问题,CAF<sup>[16]</sup>提出交叉注意力融合策略,将局部和全局特征映射为特征矩阵,利用矩阵相乘实现特征融合。

综上,目前主流方法采用CNN和GCN分别挖掘局部细节信息和全局整体结构信息并相结

合的思想,但依然存在以下问题:(1)GCN超像素分割尺度固定且单一问题。多数地物边界被包含在超像素内部,GCN无法分析节点内部信息。(2)特征不兼容问题。加权融合不同层级的特征表示会引入大量噪声,影响空间一致性。(3)重要特征挖掘不充分问题。加权融合未计算中心特征与邻域特征间的权重,导致关键信息遗漏。针对上述问题,本文提出一种高斯交叉特征融合的高光谱图像分类方法(Gaussian Cross Feature Fusion Method, GCFFM)。该方法设计了动态多尺度超像素分割算法,引入动态因子将固定尺度扩展为多尺度,通过动态变化的超像素分割尺度适配不同规模的数据集,并逐步提升分

割精细度。此外,融合高斯交叉注意力,基于图结构与注意力机制的适配性,将局部和全局特征映射到统一特征空间,减少冗余噪声并确保特征的空间分布一致性。

## 2 原理

高斯交叉特征融合方法聚焦于局部特征与全局特征融合过程中存在的关系不平衡问题,并以高斯函数作为权重调节的核心依据。先将局部特征与全局特征分别通过线性转换映射至公共特征空间,对两组特征向量进行交叉相乘运算后拼接,由线性分类器完成分类决策。方法模型如图1所示。




图1 高斯交叉特征融合方法模型图

Fig. 1 Diagram of the Gaussian crossover feature fusion method model

该方法包含三个核心处理:(1)局部特征提取模块(Local Feature Extraction Module, LFEM),利用不同尺寸的卷积核提取原始图像细节信息。(2)全局特征提取模块(Multi-scale Superpixel Global Feature Extraction Module, MSGM),采取动态多尺度超像素分割技术构建多个图结构,结合直接邻居节点与间接邻居节点捕捉全局特征。(3)高斯交叉特征融合模块(Gaussian Cross-Attention Feature Fusion Module, GCAF),将局部和全局特征提取模块挖掘的光谱空间特征投影为向量,借助交叉注意力将不同特征的查询向量与键向量相乘,应用高斯函数动态调节各种特征的权重,拼接加权后的特征

完成融合。

### 2.1 局部特征提取

高光谱图像有数百个波段,使用单个尺寸的卷积核提取特征会限制模型的表达能力。为此,局部特征提取模块选择不同尺寸的多个卷积核,扩展特征捕获范围并提升特征的层次深度。该模块结构如图2所示。

原始高光谱图像 $X(X \in R^{h \times w \times b})$ , $h$ , $w$ 和 $b$ 表示高度、宽度和波段数)同时经过 $7 \times 7$ 卷积(路径1)、 $5 \times 5$ 卷积(路径2)和 $3 \times 3$ 卷积(路径3),每条路径均包含两个串联的卷积块。在单个卷积块中,先通过批归一化(Batch Normalization, BN)降低波段间数据分布波动,再通过 $1 \times 1$ 卷积压缩




图2 局部特征提取模块

Fig. 2 Local feature extraction module

冗余波段,随后平均池化(Average Pooling, AP)保留关键信息并减少计算量,接着采用 $n \times n$ 卷积提取局部结构特征,二维卷积作用于每个波段对应的特征图,强化局部纹理与边缘信息捕获,最后通过LeakyReLU激活函数引入非线性表达能力。 $n \times n$ 卷积执行过程见公式(1):

$$Conv_{n \times n}^l(x, y) = \sum_{h=0}^{n-1} \sum_{w=0}^{n-1} K^l(h, w) O^l(x+h, y+w) + b_n^l, \quad (1)$$

其中: $K^l(h, w)$ 为第 $l$ 层卷积核在 $(h, w)$ 的权重, $O^l(x+h, y+w)$ 为第 $l$ 层 $(x, y)$ 处偏移 $(h, w)$ 位置的特征值, $b_n^l$ 为 $n \times n$ 卷积第 $l$ 层偏置。卷积块的输出见公式(2):

$$X_n = LR \left( Conv_{n \times n} \left( AP \left( Cov_{1 \times 1} (BN(X)) \right) \right) \right), \quad (2)$$

其中: $X_n$ 为卷积块产生的特征图, $LR$ 为LeakyReLU激活函数, $n \times n$ 为卷积核尺寸。

图2中的每条路径经两层卷积块处理后,会同步生成一组激活图,由于各路径卷积核均针对地物的判别性特征设计,因此激活值高的区域代表该位置的局部特征与卷积核目标特征匹配度高,激活值低的区域表示该位置特征与卷积核目标特征匹配度低,多为背景或噪声干扰区域。经两层卷积块协同处理后,激活值高的地物目标区域被强化,与背景区分度显著提升。

完成三条路径的特征提取后,将路径1、路径2和路径3输出的特征图 $X_{7 \times 7}$ 、 $X_{5 \times 5}$ 和 $X_{3 \times 3}$ 沿通道维度拼接,局部特征提取模块的输出 $X_c$ 见公式(3):

$$X_c = cat(X_{7 \times 7}, X_{5 \times 5}, X_{3 \times 3}), \quad (3)$$

其中: $cat()$ 为拼接函数, $X_c$ 为特征融合模块输入。

## 2.2 全局特征提取

传统图卷积使用固定尺度的超像素分割,限制了超像素数量和图结构的灵活性。为此,动态

多尺度超像素全局特征提取模块采用多种不同的尺度同时进行超像素分割,并构建多阶邻居图。该模块可以增加图的多样性并扩展图节点的感受野,提升特征提取的全面性和准确性。该模块结构如图3所示。




图3 动态多尺度超像素全局特征提取模块

Fig. 3 Dynamic multi-scale superpixel global feature extraction module

经过主成分分析(Principal Components Analysis, PCA)法降维的高光谱图像记作 $X' \in R^{h' \times w' \times b'}$ 。其中, $b'$ 为保留的波段数。用简单线性迭代聚类(Simple Linear Iterative Clustering, SLIC)算法对 $X'$ 进行动态超像素分割。统一固定的分割尺度会使超像素不能根据数据集进行自适应变化,为此,设计了动态多尺度超像素分割算法,在固定多尺度超像素分割的基础上,引入动态因子,确保分割尺度能适应大小各异的数据集,提升图卷积捕获领域特征信息能力。动态



多尺度超像素分割处理流程,如算法1所示。

---

算法1 动态多尺度超像素分割算法

---

输入:降维后的图像  $X' \in \mathbb{R}^{h \times w \times b'}$ , 根据数据集尺寸基准超像素分割尺度集合  $ScaleOri_i, i=1, 2, 3$

输出:动态多尺度超像素分割图像  $\{X'_{up}, X'_{mid}, X'_{low}\}$

BEGIN

1:  $X' \in \mathbb{R}^{h \times w \times b'} \rightarrow h, w$  //提取降维图像的高度和宽度

2:  $h, w \rightarrow \hat{h}, \hat{w}$  //计算标准尺寸

3:  $\sqrt{\frac{\hat{h} \times \hat{w}}{h \times w}} \rightarrow \eta$  //计算动态因子

4:  $\text{round}(ScaleOri_i \times \eta) \rightarrow Scale_i$  //动态尺度调整

5:  $X', Scale_i \rightarrow X'_{up}, X'_{mid}, X'_{low}$  //动态超像素分割

END

---

将  $X'$  的空间维度解析为原始高度  $h$  和原始宽度  $w$  (见算法第1行)。对任意正整数  $m$  的数量级取整算子  $S(\cdot)$  定义如下:

$$S(m) = d(m) \times 10^{L(m)-1}, \quad (4)$$

其中:  $d(m)$  表示  $m$  的十进制首位数字,  $L(m)$  表示  $m$  的十进制位数。由此规定标准尺寸  $\hat{h} = S(h)$ ,  $\hat{w} = S(w)$  (见算法第2行)。对标准尺寸和原始尺寸进行平方根运算,得到动态因子  $\eta$  (见算法第3行),  $\eta$  可以协助超像素分割数量的动态调整。以基准超像素分割尺度集合  $ScaleOri_i$  为基础,将每个基准尺度与动态因子  $\eta$  执行乘法运算,再通过  $\text{round}(\cdot)$  函数取整,得到动态分割尺度  $Scale_i$  (见算法第4行)。由于  $\eta < 1$ , 调整后的  $Scale_i$  会小于对应的基准尺度  $ScaleOri_i$ , 实现基准尺度的适应性缩小。 $X'$  依据  $Scale_i$  分割为三个不同空间分辨率的部分  $X'_{up}$ ,  $X'_{mid}$  和  $X'_{low}$  (见算法第5行)。 $X'_{up}$  中较大超像素有利于GCN提取背景信息,适合如Pavia University数据集中树木等大型场景; $X'_{mid}$  中超像素能获取背景与细节之间的信息; $X'_{low}$  中较小超像素擅长捕捉沥青等微小特征。

将边界定义为  $X'$  上一阶梯度幅值较大的像素。对每个主成分通道  $X'_c$  使用  $3 \times 3$  Sobel算子计算梯度幅值并求通道平均,归一化后得到边缘强度函数:

$$E(h', w') = \text{Norm} \left( \frac{1}{b'} \sum_{c=1}^{b'} \left[ (S_x * X'_c)^2 + (S_y * X'_c)^2 \right] \right), \quad (5)$$

其中:  $S_x$  与  $S_y$  为 Sobel 水平与垂直算子,  $*$  为离散卷积,  $(h', w')$  为像素坐标,  $\text{Norm}(\cdot)$  为 min-max 归一化,  $E(h', w') \in (0, 1]$  即边缘强度函数。根据经验将阈值设置为 0.85, 当  $E(h', w')$  高于阈值时判为边界像素。在超像素被编码为图节点的过程中,以红色中心节点为起点,向外扩展至绿色的一阶邻接节点,形成关注直接联系的一阶邻居图;进一步扩展到黄色的二阶邻接节点(彩图见期刊电子版),构建出能够增强GCN感受野并探索远距离关联的二阶邻居图。通过融合一阶与二阶邻居图,能够更加深入地利用图结构信息。

像素与超像素之间的关联矩阵  $Q \in \mathbb{R}^{h \times w \times Z}$  ( $Z$  表示超像素个数)表示为:

$$Q_{i,j} = \begin{cases} 1, & \text{if } \widehat{X}'_i \in S_j \\ 0, & \text{if } \widehat{X}'_i \notin S_j \end{cases}, \quad (6)$$

其中:  $\widehat{X}' = \text{Flatten}(X')$ ,  $\widehat{X}'_i$  为  $\widehat{X}'$  第  $i$  个像素,  $S_j$  为第  $j$  个超像素,  $Q_{i,j}$  为第  $i$  个像素  $\widehat{X}'_i$  与第  $j$  个超像素  $S_j$  之间的关系。关联矩阵  $Q$  为编码器和解码器的输入。像素与图节点之间的转化过程见公式(7)和公式(8):

$$V = \text{Encoder}(X'; Q) = \bar{Q}^T \widehat{X}', \quad (7)$$

$$\widehat{X}' = \text{Decoder}(V; Q) = QV, \quad (8)$$

其中:  $V$  为图节点,  $\text{Encoder}(\cdot)$  表示将像素编码为图节点,  $\bar{Q}^T$  表示将  $Q$  列归一化并转置。  $\text{Decoder}(\cdot)$  表示将图节点解码为像素。不同超像素间的权重矩阵  $W \in \mathbb{R}^{Z \times Z}$  表示为:

$$W(i, j) = \begin{cases} e^{-\frac{\|S_i - S_j\|^2}{2\sigma^2}}, & S_j \in \mathfrak{s}(S_i) \\ 0, & S_j \notin \mathfrak{s}(S_i) \end{cases}, \quad (9)$$

其中:  $\mathfrak{s}(S_i)$  为  $S_i$  的相邻超像素,  $\|S_i - S_j\|^2$  为第  $i$  个与第  $j$  个超像素之间的欧氏距离。

为得到图卷积所需的邻接矩阵,对权重矩阵  $W$  进行对称化处理并为每个节点增加自环,得到一阶邻接矩阵。由于一阶邻接图仅能捕捉超像素间直接关联,感受野有限,难以挖掘远距离地物潜在关联,因此进一步构建  $k$  阶邻居图以扩展特征捕获范围。以每个超像素为中心节点,执行深度固定为  $k$  且路径无重复节点的深度优先搜索 (Depth First Search, DFS),筛选中心节点的  $k$  步可达节点,单条  $k$  步路径强度取其加权平均值;若

中心节点与同一末端节点存在多条  $k$  步路径,取平均边权最大者作为二者的  $k$  阶连接强度。将该强度记入  $k$  阶邻接矩阵  $A_k$  对应条目并保留节点自环,矩阵条目值越大,代表  $k$  步传播的关联越强。

$k$  阶邻接矩阵  $A_k$  作为输入矩阵,图卷积执行过程见公式(10):

$$H^{(l+1)} = \phi\left(\tilde{D}^{-\frac{1}{2}} \tilde{A}_k \tilde{D}^{-\frac{1}{2}} H^l W^l\right), \quad (10)$$

其中: $\phi$  为激活函数, $D$  为  $A_k$  的度矩阵, $H^l$  为第  $l$  层输入, $W^l$  为第  $l$  层权重矩阵。将  $X'_{up}$  一阶和二阶邻居图卷积结果记作  $H_{up,1}$  和  $H_{up,2}$ ,融合过程见公式(11):

$$H_{up} = H_{up,1} + H_{up,2}, \quad (11)$$

其中: $H_{up}$  为  $X'_{up}$  特征提取的结果。同理, $X'_{mid}$  和  $X'_{low}$  特征提取结果记作  $H_{mid}$  和  $H_{low}$ ,拼接过程见公式(12):

$$H_G = cat(H_{up}, H_{mid}, H_{low}), \quad (12)$$

其中, $H_G$  为全局特征提取模块的输出,也是高斯交叉特征融合模块的输入。

### 2.3 高斯交叉特征融合

常规特征融合即局部和全局特征直接相加,但这会产生数据不兼容问题并放大冗余噪声,且无法衡量特征的相对贡献。为此,设计高斯交叉注意力特征融合算法,将两种特征转换为向量形式后进行交叉相乘,确保数据一致性并准确计算出每种特征的相对贡献。高斯交叉注意力特征融合处理流程如算法 2 所示。

算法 2 高斯交叉注意力特征融合算法

输入:局部特征  $X_C$ ,全局特征  $H_G$ ,高斯函数  $Gau$

输出:融合后的特征  $X_{out}$

BEGIN

1:Linear( $X_C$ ) $\rightarrow Q_C, K_C, V_C$  //局部特征线性映射

2:Linear( $H_G$ ) $\rightarrow Q_G, K_G, V_G$  //全局特征线性映射

3: $G(Q_C \cdot K_G^T) \rightarrow G_C$  //计算卷积特征对应的高斯分布

4: $G(Q_G \cdot K_C^T) \rightarrow G_G$  //计算图卷积特征对应的高斯分布

5:softmax( $Q_C K_G^T + G_C$ ) $V_C \rightarrow X_{CA}$  //计算局部特征输出

6:softmax( $Q_G K_C^T + G_G$ ) $V_G \rightarrow X_{GA}$  //计算全局特征输出

7:cat( $X_{CA}, X_{GA}$ ) $\rightarrow X_{out}$  //特征拼接

END

局部和全局特征经过线性层(见算法第 1 行和第 2 行)。算法的核心是在交叉注意力的打分中引入二维高斯空间先验作为缩放因子,以动态刻画中心特征和邻域特征的空间关联强度。高斯函数  $Gau$  计算公式如下:

$$Gau(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{(x-\mu_x)^2}{2\sigma_x^2} - \frac{(y-\mu_y)^2}{2\sigma_y^2}\right), \quad (13)$$

其中: $x$  表示中心特征, $y$  表示邻域特征, $\sigma$  表示标准差, $\mu$  表示均值。高斯函数中的关键参数为  $\sigma_x, \sigma_y, \mu_x$  和  $\mu_y$ 。采用直接赋值的初始化策略: $\sigma_x$  和  $\sigma_y$  取 1.0,表示空间分布处于均衡状态。 $\mu_x$  和  $\mu_y$  取 0,表示中心位于空间坐标原点。上述参数均为可训练变量,通过反向传播更新。参数选取标准包含:(1)优先保证整体分类准确性,同时兼顾类别均衡表现和预测一致性;(2)通过控制不同随机种子、跨数据集测试开展多次独立重复实验,验证参数选取的稳健性与可复现性,该验证结果作为确定参数的辅助依据。参数优化策略包括:(1)训练阶段按固定轮次进行验证集评估,实时保存最优参数权重;(2)采用固定学习率和权重衰减参数,保障训练过程稳定收敛。上述设置使关键参数从标准初始化状态出发,逐步优化至更契合局部与全局匹配的中心和尺度。依据  $\sigma$  动态调整邻域范围和  $\mu$  自适应偏移坐标原点的策略,高斯分布  $G$  能够量化中心特征与邻域特征的关联强度,该值越高表明中心与邻域关联性越强。将  $Q_C$  和  $K_G^T$  代入  $Gau$  获得卷积高斯分布  $G_C$ (见算法第 3 行),将  $Q_G$  和  $K_C^T$  代入  $Gau$  获得图卷积高斯分布  $G_G$ (见算法第 4 行)。

在得到高斯分布  $G$  后,还需要计算相似度矩阵  $SM$ ,并将二者相加获得注意力分数  $SM\_G$ 。计算过程见公式(14)和公式(15):

$$SM = Sim(Query, Key) = Query \cdot Key^T, \quad (14)$$

$$SM\_G = SM + G, \quad (15)$$

其中: $Query$  为查询向量, $Key$  为键向量。 $G$  会对空间上更接近的  $Query, Key$  组合给予更高附加分,距离越远附加分越小,由此可引导注意力聚焦于空间上可信局部邻域,抑制远距离偶然相关。对注意力分数  $SM\_G$  的归一化和加权过程

见公式(16)和公式(17):

$$Att\_Wei = Softmax(SM\_G) = \frac{e^{Sim_i}}{\sum_{j=1}^n e^{Sim_j}}, \quad (16)$$

$$Output = Att\_Wei \cdot V, \quad (17)$$

其中: $Att\_Wei$ 为归一化后的注意力权重, $Sim_i$ 为 $SM\_G$ 第*i*个元素, $Output$ 为 $V$ 加权的结果。特征融合时得到局部注意力权重矩阵 $A_c = softmax(Q_c K_c^T + G_c)$ 和全局注意力权重矩阵 $A_g = softmax(Q_g K_g^T + G_g)$ ,高斯项已加入权重矩阵并经过归一化。 $A_c, A_g$ 分别与对应值向量 $V_c, V_g$ 进行加权,得到局部特征 $X_{CA} = A_c V_c$ (见算法第5行)和全局特征 $X_{GA} = A_g V_g$ (见算法第6行)。

为量化两种特征的贡献度,设序列长度为 $N'$ ,采用值向量的L2范数衡量有效信息强度,局部分支贡献度 $Cont_c$ 计算过程见公式(18):

$$Cont_c = \frac{1}{N'} \sum_{i'=1}^{N'} \sum_{j'=1}^{N'} A_c(i', j') \|V_c(j')\|_2, \quad (18)$$

其中: $i'$ 为查询位置, $j'$ 为值位置。同理可得全局分支贡献度 $Cont_g$ 。对两者进行归一化处理,得到局部分支贡献系数 $\gamma_c$ 和全局分支贡献系数 $\gamma_g$ 。具体计算过程见公式(19)和公式(20):

$$\gamma_c = \frac{Cont_c}{Cont_c + Cont_g}, \quad (19)$$

$$\gamma_g = 1 - \gamma_c. \quad (20)$$

系数越大表示该分支的相对贡献越高。 $X_{CA}$ 和 $X_{GA}$ 沿通道维度拼接形成融合特征 $X_{out}$ (见算法第7行)。

## 2.4 复合损失函数

采用交叉熵损失函数量化预测值与真实值之间的差异,计算过程见公式(21):

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M Y_j(p_i) \log(\hat{Y}_j(p_i)), \quad (21)$$

其中: $M$ 为样本总量, $N$ 为类别总量, $p_i$ 为第*i*个像素, $Y_j(p_i)$ 为像素真实标签的第*j*个元素, $\hat{Y}_j(p_i)$ 为预测像素属于第*j*类的概率。

在模型训练过程中,复合损失函数 $\mathcal{L}_{sum}$ 是局部特征损失 $\mathcal{L}_{LFEM}$ 、全局特征损失 $\mathcal{L}_{MSGM}$ 和特征融合损失 $\mathcal{L}_{GCAF}$ 的线性组合,三种损失共同参与反向传播,确保参数更新平衡,结合梯度下降法有效提升了模型整体性能,计算过程见公式(22):

$$\mathcal{L}_{sum} = \mathcal{L}_{LFEM} + \mathcal{L}_{MSGM} + \mathcal{L}_{GCAF}. \quad (22)$$

## 3 实验结果与分析

### 3.1 数据集和参数设置

为验证本文方法的有效性,在Indian Pines(IP), Pavia University(PU), Salinas(SA)和WHU-Hi-LongKou(LK)数据集上进行实验。基本信息见表1。

表1 IP,PU,SA和LK数据集基本信息

Tab. 1 Basic information of IP, PU, SA and LK data sets

| Dataset | Sensor                  | Size    | Bands | Wavelength range/ $\mu m$ | Classes | Samples |
|---------|-------------------------|---------|-------|---------------------------|---------|---------|
| IP      | AVIRIS                  | 145×145 | 200   | 0.45~2.5                  | 16      | 10 366  |
| PU      | ROSIS                   | 610×340 | 103   | 0.43~0.86                 | 9       | 42 776  |
| SA      | AVIRIS                  | 512×217 | 204   | 0.4~2.5                   | 16      | 54 129  |
| LK      | Headwall Nano-Hyperspec | 550×400 | 270   | 0.4~1.0                   | 9       | 204 542 |

本文采用自适应矩估计(Adaptive moment estimation, Adam)优化器优化模型参数,引入L2正则化以防止模型过拟合。学习率设置为 $5 \times 10^{-4}$ ,该取值通过验证集上的粗粒度网格搜索确定。对比多个候选学习率后发现, $5 \times 10^{-4}$ 的表现最优,模型训练的方差较小且收敛过程更平稳。模型采用复合损失,在少量监督样本的训练

场景下,梯度方差相对更大, $5 \times 10^{-4}$ 作为偏保守的固定学习率,有效兼顾训练稳定性与泛化能力。训练迭代次数设为300,该迭代次数依据训练与验证性能曲线的变化趋势确定。训练与验证性能曲线在240轮左右进入性能平台期,继续训练至300轮可确保最佳结果的稳定复现,并降低由不同随机种子与数据划分导致的实验波动。

每个实验独立重复 10 次,取 10 次结果的平均值作为最终实验结果。采用总体准确度(Overall Accuracy, OA)、平均准确度(Average Accuracy, AA)和 Kappa 系数为评价指标。各评价指标的计算基于以下设定,样本总量为  $M$ ,类别总量为  $N$ ,混淆矩阵记为  $C=[c_{ij}]$ ,即真实为第  $i$  类而被判定为第  $j$  类的样本数。OA 的计算过程见公式(23):

$$OA = \frac{\sum_{i=1}^N c_{ii}}{M}. \quad (23)$$

AA 的计算过程见公式(24):

$$AA = \frac{1}{N} \sum_{i=1}^N \frac{c_{ii}}{c_{i.}}. \quad (24)$$

Kappa 的计算过程见公式(25):

$$\kappa = \frac{OA - \sum_{i=1}^N \frac{c_{i.}}{M} \cdot \frac{c_{.i}}{M}}{1 - \sum_{i=1}^N \frac{c_{i.}}{M} \cdot \frac{c_{.i}}{M}}, \quad (25)$$

其中:  $c_{i.} = \sum_{j=1}^N c_{ij}$  表示真实为第  $i$  类的样本总数,  $c_{.i} = \sum_{j=1}^N c_{ji}$  表示被判为第  $i$  类的样本总数。

### 3.2 对比方法和性能评价

为评估方法的性能,与 DCSST, SMESC 和 Vit-cov 等 11 种方法进行对比,表中粗体代表结果最优,对比的方法介绍如下:

DCSST<sup>[17]</sup>结合域级判别器与对比学习,并配合交叉注意力以缓解域偏移并增强类间分离度。

SMESC<sup>[18]</sup>采用转置卷积强化空间分辨率,利用通道调制残差模块抑制光谱冗余。

Vit-cov<sup>[19]</sup>以 3D-CNN 提取局部特征,ViT 建模全局依赖,通过二维卷积进行特征投影降低计算复杂度。

Swi-MSP<sup>[20]</sup>通过单轴互相关与频带平移获取多尺度光谱特征,并结合移窗自注意力进行建模。

MFormer<sup>[21]</sup>将浅层光谱-空间特征转化为记忆标记,以增强注意力对关键上下文的聚焦。

GTFN<sup>[22]</sup>在图卷积中引入光谱注意力,并级联邻域卷积以融合局部光谱信息。

CGCN<sup>[23]</sup>面向小样本场景,通过对比损失拉近同类、拉远异类,提升类间可分性。

DMSGer<sup>[10]</sup>基于度量学习动态构图,并以像

素级节点更新同时优化像素级与区域级特征。

AMGCfn<sup>[24]</sup>使用多尺度卷积获取像素特征,结合多头注意力与多阶邻居图聚合上下文信息。

CSGNet<sup>[25]</sup>基于超图卷积挖掘高阶社区结构,用 CNN 捕捉像素级特征,通过可信超图构建与核映射增强节点连接质量。

S2Mamba<sup>[26]</sup>用跨块扫描建模长程空间依赖,通过双向扫描建模连续光谱特征,再以混合门自适应融合。

上述方法在 IP 数据集的实验结果如表 2 所示。

在 IP 数据集上,GCFFM 的 OA, AA 和 Kappa 均最优。GCFFM 领先于 DCSST 和 SMESC。因为 IP 数据集尺寸较小且地物边缘复杂,使用 CNN 和 GCN 技术能捕捉到不同层次的空间上下文信息,解决了仅依赖像素级特征所存在的局限性。相较于 Vit-cov, Swi-MSP, MFormer, GT-FN 和 CSGNet, GCFFM 结果领先。因为 GCFFM 利用高斯函数动态调整局部与全局特征间的权重,确保地物边界得到精细解析,实现了精准特征表达。与 CGCN, DMSGer, AMGCfn 和 S2Mamba 相比, GCFFM 结果亦有提高。该方法突破单一尺度和固定超像素数量的限制,通过动态多尺度超像素分割获取多样化的特征表示,利用多阶邻居图聚合邻近特征,增强了对复杂场景的理解能力。

PU 数据集上的实验结果如表 3 所示。

在 PU 数据集中, GCFFM 的 OA, AA 和 Kappa 均最高。与 DCSST 和 SMESC 相比, GCFFM 结果领先。因为 PU 数据集尺寸较大且边界复杂, GCFFM 能充分发挥优势: CNN 精准捕捉树木等细节特征, GCN 能有效处理草地等连续分布的大面积特征, GCFFM 在复杂场景中提取出更准确的特征表示。与 Vit-cov, Swi-MSP, MFormer, GTFN 和 CSGNet 对比, GCFFM 结果仍然较优。在小样本簇条件下使用高斯函数增强了不同特征间的区分度,确保该方法在不同样本密度下具备稳健性。此外,该方法利用动态分割产生的多阶图聚合更远距离信息,强化局部特征学习的同时提升对整体场景理解,实现更全面的信息融合,所以比 CGCN, DMSGer, AMGCfn 和 S2Mamba 表现更好。



表 2 IP 数据集上方法性能比较

Tab. 2 Method performance comparison on the IP data set

(%)

| Class       | DCSST        | SMESC        | Vit-cov      | Swi-MSP      | MForm-<br>er | GTFN         | CGCN         | DMS-<br>Ger  | AMGCf<br>n   | CSG-<br>Net | S2Mam-<br>ba | GCFFM        |
|-------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|-------------|--------------|--------------|
| 1           | 98.05        | <b>100.0</b> | 11.11        | 92.68        | 47.72        | <b>100.0</b> | <b>100.0</b> | 98.29        | 77.27        | 50.00       | 36.36        | 88.55        |
| 2           | 51.78        | 87.60        | 88.01        | 91.48        | 92.99        | 87.30        | 69.53        | <b>95.85</b> | 91.13        | 91.90       | 91.80        | 94.62        |
| 3           | 55.43        | 83.49        | 96.52        | 96.92        | 95.98        | 91.79        | 77.71        | 91.45        | <b>97.49</b> | 97.34       | 91.40        | 95.12        |
| 4           | 77.28        | 92.82        | 88.26        | 90.56        | 87.28        | 98.71        | 97.46        | <b>98.84</b> | 80.86        | 78.28       | 95.95        | 94.76        |
| 5           | 80.61        | 95.44        | 98.50        | 87.44        | <b>99.78</b> | 94.19        | 89.91        | 95.70        | 94.63        | 85.78       | 95.39        | 96.06        |
| 6           | 91.26        | <b>100.0</b> | 98.72        | 99.23        | 98.43        | 96.71        | 99.15        | 97.95        | 95.09        | 97.82       | 98.40        | 98.87        |
| 7           | 98.7         | <b>100.0</b> | <b>100.0</b> | 98.15        | <b>100.0</b> | 94.87        | <b>100.0</b> | 55.55        | 96.29        | 100.0       | 73.08        | 97.96        |
| 8           | 83.07        | 99.37        | <b>100.0</b> | 98.91        | <b>100.0</b> | 99.85        | 99.23        | <b>100.0</b> | <b>100.0</b> | 100.0       | 99.33        | 99.83        |
| 9           | 98.67        | <b>100.0</b> | 89.47        | 66.67        | 84.21        | <b>100.0</b> | <b>100.0</b> | 41.17        | <b>100.0</b> | 68.42       | 66.67        | 79.09        |
| 10          | 66.61        | 74.27        | 95.97        | <b>96.57</b> | 94.31        | 96.04        | 78.64        | 93.62        | 85.04        | 88.53       | 87.83        | 95.00        |
| 11          | 63.53        | 81.95        | 96.38        | 98.36        | <b>99.61</b> | 88.38        | 46.76        | 93.94        | 98.01        | 92.87       | 88.12        | 97.67        |
| 12          | 53.91        | 71.50        | 93.56        | 96.19        | 91.56        | 80.70        | 70.52        | 92.92        | 84.99        | 78.88       | 68.87        | <b>93.79</b> |
| 13          | 99.05        | <b>100.0</b> | 98.49        | 97.81        | <b>100.0</b> | 94.62        | <b>100.0</b> | 99.81        | <b>100.0</b> | 98.94       | 98.96        | 99.45        |
| 14          | 83.76        | 97.62        | 99.67        | <b>100.0</b> | 99.25        | 95.43        | 95.84        | 99.16        | 98.92        | 96.12       | 97.98        | 99.04        |
| 15          | 82.10        | 90.93        | 90.10        | 92.52        | 94.07        | <b>99.16</b> | 98.09        | 96.03        | 79.61        | 99.73       | 94.52        | 96.72        |
| 16          | <b>100.0</b> | <b>100.0</b> | 76.66        | 76.82        | 77.52        | 99.47        | <b>100.0</b> | 87.34        | <b>100.0</b> | 69.41       | 91.95        | 93.59        |
| OA          | 69.46        | 87.48        | 94.92        | 96.12        | 96.38        | 94.00        | 89.93        | 95.13        | 93.74        | 92.25       | 90.92        | <b>96.67</b> |
| AA          | 80.24        | 92.19        | 88.84        | 92.52        | 91.42        | 94.83        | 88.93        | 89.85        | 92.46        | 87.13       | 86.04        | <b>95.01</b> |
| Kappa       | 65.69        | 85.70        | 94.19        | 95.58        | 95.86        | 93.15        | 88.18        | 94.46        | 92.85        | 91.18       | 89.65        | <b>96.20</b> |
| Parameter/K | 6 216        | 430          | 1 095        | 5 029        | 372          | 5 063        | 316          | 720          | 368          | <b>63</b>   | 120          | 430          |

表 3 PU 数据集上方法性能比较

Tab. 3 Method performance comparison on the PU data sets

(%)

| Class       | DCSST | SMESC        | Vit-cov      | Swi-MSP      | MForm-<br>er | GTFN  | CGCN  | DMS-<br>Ger  | AMGCf<br>n | CSG-<br>Net | S2Mam-<br>ba | GCFFM        |
|-------------|-------|--------------|--------------|--------------|--------------|-------|-------|--------------|------------|-------------|--------------|--------------|
| 1           | 78.77 | 92.61        | 98.04        | 92.22        | <b>99.40</b> | 89.62 | 91.77 | 97.29        | 94.48      | 78.50       | 81.05        | 97.47        |
| 2           | 83.54 | 96.94        | <b>100.0</b> | 97.26        | 99.94        | 97.24 | 99.28 | 99.66        | 98.91      | 99.29       | 97.45        | 99.80        |
| 3           | 68.83 | <b>97.99</b> | 90.90        | 88.12        | 88.27        | 84.52 | 35.95 | 89.24        | 87.52      | 82.08       | 64.63        | 95.97        |
| 4           | 93.11 | 86.81        | 94.49        | <b>100.0</b> | 80.87        | 94.91 | 87.10 | 98.35        | 93.58      | 93.12       | 83.76        | 90.96        |
| 5           | 99.71 | 99.62        | <b>100.0</b> | 97.45        | 99.85        | 98.71 | 92.64 | <b>100.0</b> | 99.86      | 97.41       | 97.45        | 96.22        |
| 6           | 79.72 | 90.81        | 97.35        | 98.74        | 98.68        | 99.59 | 94.13 | 92.00        | 98.85      | 96.38       | 96.17        | <b>99.88</b> |
| 7           | 89.26 | 87.51        | <b>100.0</b> | 95.14        | <b>100.0</b> | 98.97 | 92.54 | 99.30        | 95.45      | 94.07       | 91.94        | 97.24        |
| 8           | 73.39 | 87.94        | 90.26        | 92.19        | 91.15        | 91.59 | 95.20 | 89.92        | 97.90      | 90.59       | 91.17        | <b>98.34</b> |
| 9           | 96.36 | 99.78        | 94.77        | <b>99.97</b> | 91.93        | 96.07 | 85.52 | 97.93        | 81.01      | 87.79       | 94.47        | 93.15        |
| OA          | 82.41 | 93.95        | 97.59        | 94.42        | 96.83        | 95.14 | 92.45 | 96.91        | 96.71      | 94.81       | 92.53        | <b>98.16</b> |
| AA          | 84.74 | 93.34        | 96.20        | 95.68        | 94.45        | 94.58 | 86.01 | 95.97        | 94.17      | 91.03       | 88.68        | <b>96.56</b> |
| Kappa       | 77.40 | 92.00        | 96.80        | 93.79        | 95.79        | 93.58 | 89.96 | 95.90        | 95.65      | 93.13       | 90.04        | <b>97.57</b> |
| Parameter/K | 6 185 | 398          | 1 103        | 5 045        | 377          | 5 071 | 309   | 709          | 358        | <b>70</b>   | 125          | 405          |

在 SA 数据集上的实验结果如表 4 所示。

GCFFM 在 OA,AA 和 Kappa 上均表现出最佳性能。通过对比 OA 可知:GCFFM 结果远高于 DCSST 和 SMESC。SA 数据集地物种类多且边缘整齐,GCN 高阶邻接图提供的较大感受野能有效捕捉复杂空间结构信息,提升分类效果。GCFFM 的结果明显超过 Vit-cov, Swi-MSP, MFormer, GTFN 和 CSGNet。SA 数据集中异类地物样本的间距较小,但是高斯函数有助于区分不同样本,确保该方法在密集样本区域的效果。与 CGCN, DMSGer, AMGCfn 和 S2Mamba, GCFFM 结果进一步提升。由于 SA 数据集样本标签较为集中,采用动态多尺度超像素分割时,超像素内部包含同种样本的概率增大,使图卷积能更好地融合相似特征,提升整体分类效果。

LK 数据集上的实验结果如表 5 所示。

GCFFM 在 OA,AA 和 Kappa 方面均具有显著优势。全局特征提取模块中的动态多尺度超像素分割通过自适应调整分割粒度,有效解决了 DCSST 和 SMESC 中因固定尺度导致的边界模糊问题,并且多尺度特性在复杂地物类别中提升了图结构的表征能力。高斯交叉注意力融合克服了 Vit-cov, Swi-MSP, MFormer, GTFN 和 CSGNet 因简单特征拼接引发的噪声干扰,通过空间一致性映射使关键类别的局部与全局特征协同效果最大化。与 CGCN, DMSGer, AMGCfn 和 S2Mamba 相比,通过高斯动态特征加权,使 GCFFM 实现了关键特征的精准强化,达成 OA 的突破性提升。对比所有方法多个数据集的参数数量可知,GCFFM 在确保 OA 的情况下参数量也在合理范围内。

表 4 SA 数据集上方法性能比较

Tab. 4 Method performance comparison on the SA data sets (%)

| Class       | DCSST | SMESC | Vit-cov | Swi-MSP | MFormer | GTFN  | CGCN  | DMSGer | AMGCfn | CSGNet | S2Mamba | GCFFM |
|-------------|-------|-------|---------|---------|---------|-------|-------|--------|--------|--------|---------|-------|
| 1           | 99.65 | 100.0 | 99.65   | 99.44   | 100.0   | 100.0 | 99.83 | 99.55  | 99.04  | 68.99  | 51.85   | 99.65 |
| 2           | 99.97 | 100.0 | 100.0   | 100.0   | 100.0   | 99.97 | 99.52 | 100.0  | 99.99  | 100.0  | 100.0   | 99.89 |
| 3           | 89.37 | 81.88 | 100.0   | 99.77   | 100.0   | 99.97 | 92.40 | 100.0  | 100.0  | 87.92  | 100.0   | 99.83 |
| 4           | 99.47 | 99.85 | 99.64   | 95.64   | 98.48   | 99.59 | 96.62 | 99.78  | 99.07  | 99.85  | 99.84   | 92.08 |
| 5           | 91.18 | 99.58 | 96.85   | 91.91   | 100.0   | 95.89 | 92.13 | 95.35  | 93.18  | 97.67  | 98.28   | 94.76 |
| 6           | 99.93 | 100.0 | 99.21   | 96.78   | 99.97   | 99.84 | 94.12 | 98.45  | 99.89  | 92.51  | 99.49   | 97.74 |
| 7           | 99.06 | 100.0 | 100.0   | 98.70   | 99.91   | 99.72 | 99.13 | 100.0  | 99.95  | 88.53  | 92.12   | 98.59 |
| 8           | 79.85 | 79.30 | 92.96   | 98.86   | 93.28   | 92.18 | 89.89 | 90.44  | 94.02  | 100.0  | 93.90   | 99.32 |
| 9           | 99.90 | 100.0 | 100.0   | 100.0   | 100.0   | 99.80 | 99.57 | 100.0  | 100.0  | 84.21  | 89.57   | 99.93 |
| 10          | 87.17 | 98.74 | 97.95   | 98.06   | 99.54   | 95.42 | 43.61 | 97.15  | 98.22  | 100.0  | 96.06   | 98.83 |
| 11          | 98.67 | 100.0 | 100.0   | 97.79   | 99.81   | 99.77 | 97.72 | 100.0  | 98.67  | 96.43  | 87.12   | 99.00 |
| 12          | 99.27 | 95.84 | 99.95   | 98.55   | 100.0   | 99.66 | 97.85 | 99.95  | 99.46  | 98.69  | 99.94   | 99.41 |
| 13          | 98.40 | 98.25 | 100.0   | 98.91   | 93.85   | 99.50 | 96.86 | 100.0  | 96.05  | 100.0  | 100.0   | 98.83 |
| 14          | 98.78 | 100.0 | 90.14   | 99.47   | 98.59   | 99.17 | 84.31 | 87.89  | 98.50  | 97.17  | 99.34   | 98.37 |
| 15          | 78.08 | 86.07 | 93.78   | 96.08   | 89.18   | 93.06 | 98.26 | 94.44  | 94.36  | 97.78  | 99.91   | 98.91 |
| 16          | 92.50 | 99.66 | 99.89   | 99.87   | 99.83   | 99.18 | 99.81 | 100.0  | 99.46  | 99.90  | 99.62   | 99.52 |
| OA          | 90.79 | 92.87 | 97.14   | 98.13   | 96.93   | 96.81 | 92.41 | 96.48  | 97.32  | 93.41  | 94.28   | 98.81 |
| AA          | 94.77 | 96.20 | 98.13   | 98.11   | 98.27   | 98.30 | 92.60 | 97.69  | 98.12  | 94.35  | 94.19   | 98.46 |
| Kappa       | 89.69 | 92.07 | 96.82   | 97.92   | 96.58   | 96.45 | 91.56 | 96.09  | 97.02  | 92.66  | 93.63   | 98.67 |
| Parameter/K | 6 226 | 410   | 1 112   | 5 003   | 380     | 5 072 | 310   | 715    | 355    | 65     | 123     | 431   |

表5 LK数据集上方法性能比较

Tab. 5 Method performance comparison on the LK data set

(%)

| Class       | DCSST | SMESC | Vit-cov | Swi-MSP | MForm-<br>er | GTFN  | CGCN  | DMS-<br>Ger | AMGCf<br>n | CSG-<br>Net | S2Mam<br>ba | GCCFM |
|-------------|-------|-------|---------|---------|--------------|-------|-------|-------------|------------|-------------|-------------|-------|
| 1           | 55.12 | 23.80 | 76.74   | 100.0   | 100.0        | 89.93 | 99.38 | 67.46       | 99.70      | 70.23       | 99.81       | 99.81 |
| 2           | 61.34 | 95.36 | 89.58   | 94.78   | 99.65        | 100.0 | 50.06 | 100.0       | 96.55      | 99.79       | 95.65       | 99.35 |
| 3           | 63.78 | 95.71 | 96.63   | 97.79   | 62.43        | 76.17 | 89.97 | 98.08       | 83.32      | 92.64       | 97.53       | 99.60 |
| 4           | 69.45 | 98.63 | 89.09   | 64.56   | 98.35        | 74.76 | 97.86 | 92.82       | 91.21      | 80.34       | 73.31       | 99.68 |
| 5           | 71.39 | 97.21 | 77.95   | 100.0   | 97.55        | 95.90 | 68.12 | 90.25       | 94.15      | 98.47       | 99.98       | 98.07 |
| 6           | 75.67 | 98.46 | 100.0   | 94.91   | 98.66        | 100.0 | 94.58 | 98.49       | 98.39      | 99.47       | 99.66       | 97.64 |
| 7           | 78.82 | 93.73 | 57.69   | 97.93   | 88.13        | 98.08 | 98.02 | 100.0       | 98.01      | 99.98       | 87.64       | 98.81 |
| 8           | 83.45 | 89.65 | 100.0   | 79.95   | 98.51        | 51.40 | 49.50 | 92.75       | 91.42      | 91.54       | 85.27       | 83.63 |
| 9           | 84.49 | 93.65 | 91.35   | 88.11   | 85.01        | 97.11 | 94.07 | 91.08       | 58.21      | 79.85       | 84.12       | 61.77 |
| OA          | 69.17 | 86.06 | 90.54   | 96.67   | 93.42        | 91.65 | 88.28 | 95.38       | 96.25      | 96.07       | 92.36       | 97.09 |
| AA          | 71.50 | 87.36 | 86.56   | 90.89   | 92.03        | 87.04 | 82.40 | 92.33       | 90.11      | 90.26       | 91.44       | 93.15 |
| Kappa       | 68.42 | 80.75 | 90.47   | 95.63   | 92.92        | 88.57 | 89.80 | 94.79       | 95.08      | 96.14       | 96.53       | 97.01 |
| Parameter/K | 6 233 | 423   | 1 120   | 5 050   | 373          | 5 081 | 316   | 720         | 340        | 130         | 118         | 438   |

### 3.3 基准超像素影响分析

为验证动态、多尺度和逐步增加分割精细度三项设计在超像素分割中的作用,在全局特征提取模块中进行控制变量实验。对每个数据集,采用多尺度 $\{X'_{up}, X'_{mid}, X'_{low}\}$ 并行分割,对应的基准超像素设为 $\{S_0, S_0 + \Delta, S_0 + 2\Delta\}$ 。依据动态因子,在不同数据集上对 $\{S_0, \Delta\}$ 组合进行等比例调整,使有效图节点数随数据尺寸自适应变化。同一数据集内逐步增加分割精细度,从 $X'_{up}$ 到 $X'_{mid}$ 再到 $X'_{low}$ ,超像素数量增加。选取三组初始规模 $S_0 \in \{100, 200, 300\}$ 与三组步长 $\Delta \in \{30, 50, 70\}$ 进行组合。在IP, PU, SA和LK数据集上进行10次重复实验,OA平均值如图4所示。

小尺寸场景IP在 $(S_0, \Delta) = (100, 30)$ 即 $\{100, 130, 160\}$ 时取得最高OA,进一步增大规模会提升异类像素混叠的风险;中等规模即可完整表达边界细节并保持干净的节点语义。中等尺寸场景PU和SA,最优组合均为 $\{100, 150, 200\}$ 。PU地物边缘更为曲折,适度增加超像素有助于分离异质边界;SA边界更清晰,对超像素数量变化更为鲁棒,在一定范围内性能变化平稳。大尺寸且类别较少的场景LK,  $\{100, 170, 240\}$ 最优,较大的超像素更易将同质区域聚合到同一图节点,从而提升整体一致性与分类稳定性。随着超像素数量逐步增加,OA稳定提升;不同数据集在最优 $(S_0, \Delta)$ 组合上存在差异,但均可通过动态因子与




图4 动态多尺度验证

Fig. 4 Dynamic multi-scale validation

多尺度设计实现对数据规模的自适应匹配。

### 3.4 高斯函数效率分析

本文用二维高斯函数作为注意力机制中的缩放因子,计算不同特征的重要程度。为验证该做法的有效性,在 IP, PU, SA 和 LK 数据集上进行了四组实验: $X_{CA}$  和  $X_{GA}$  均不用高斯函数; $X_{CA}$  用高斯函数,  $X_{GA}$  保留缩放因子; $X_{CA}$  用缩放因子,  $X_{GA}$  用高斯函数; $X_{CA}$  和  $X_{GA}$  均采用高斯函数。实验结果如图 5 所示。




图 5 高斯函数对总体准确度的影响

Fig. 5 Influence of Gaussian function on OA

在四个数据集中,当  $X_{CA}$  和  $X_{GA}$  均采用高斯函数作为缩放因子时,OA 显著提升,优于对照组。这表明高斯函数不仅能捕捉特征间的细微差异,还能强调关键信息表示。仅在交叉注意力的一侧加入高斯函数,也能有效提高 OA,高斯函数能够在融合中对局部与全局特征之间的关系进行建模,突出各个部分特征的重要性,进一步证明了此种做法的可行性和高效性。

### 3.5 高斯核参数敏感性分析

为评估高斯核参数对模型性能与稳定性的影响,本节在保持高斯核参数可学习的前提下,分析不同初始化对结果的影响。固定  $c_x=c_y=0$  不变,对  $\sigma_x=\sigma_y$  进行 6 组初始化,包括基线尺度  $\sigma=1$  与归一化尺度  $0.25L, 0.5L, 1.0L, 2.0L$  和  $4.0L$ ,其中,  $L=\sqrt{hw}/8$ 。不同标准差初始化的 OA 如图 6 所示。

从图 6 可以看出,四个数据集对  $\sigma$  的初值均不敏感,跨组最大波动均小于 1%。当  $\sigma=1$  (默认值)时效果最好,且其他初始化未观察到对性能的影响,故选择  $\sigma_x=\sigma_y=1$  作为标准差初始值。

固定  $\sigma$ ,对均值  $(\mu_x, \mu_y)$  的 6 组初始化分别为




图 6 标准差初始化

Fig. 6 Standard-deviation initialization ( $\sigma$ )

$(0,0), (c_x, c_y), (c_x \pm 0.2w, c_y)$  和  $(c_x, c_y \pm 0.2h)$ , 其中  $c_x=(w-1)/2, c_y=(h-1)/2$ 。不同均值初始化的 OA 如图 7 所示。




图 7 均值初始化

Fig. 7 Mean initialization ( $\mu$ )

从图 7 可知,  $\mu$  设置不同值时对 OA 影响不大,当  $\mu_x=\mu_y=0$  (默认值)达到最高,沿 X 轴或 Y 轴偏移  $0.2w$  或  $0.2h$  时产生微小下降,未出现方向性偏置。综上,本文采用默认设置  $\sigma_x=\sigma_y=1.0, \mu_x=\mu_y=0$  是合理且有效的,在保持参数可学习的条件下能稳定收敛到相近的最优解,并在多个数据集上均获得较优性能。

### 3.6 训练集数量影响分析

为评估训练集数量对 OA 的影响,在 IP, PU, SA 和 LK 数据集上选取已标记样本总量的若干比例作为训练集进行实验,每组实验重复 10 次并取 OA 平均值。实验结果如图 8 所示。

对于小规模 IP 数据集, GCFM 在 5% 的训练集中实现了性能提升,其分类效果接近更高比例的饱和和区间,表明该比例可以有效捕捉光谱-空间特征关联,又能避免冗余标注带来的效益递减。面对 PU 和 SA 中等大小的数据集,通过高斯交叉






图8 不同训练集数量下的总体准确度

Fig. 8 OA under different number of training sets

特征融合使GCFM在5%的标注样本中充分挖掘判别信息,其分类效果稳定超越对比方法,证明了该方法的高效特征学习能力。针对较大的LK数据集,选择0.5%比例训练集即可让GCFM保持优异性能,其整体性能逼近多数方法在1%标注样本下的表现,突出了该方法通过动态图结构与特征交互优化对稀疏样本的适应力。

### 3.7 消融实验

为评估LFEM,MSGM和GCAF等对网络性能的影响,进行以下消融实验。结果如表6所示。

表6中,“w/o”代表移除相应的模块。单独移除LFEM,模型细节感知能力显著下降,影响复杂地物边界判别。单独移除MSGM会削弱网络多尺度适应性,引发偏差。单独移除GCAF会使特征协同不足、信息整合不充分。同时移除多个模块,性能衰减叠加,由此验证各模块在特征提取与融合中的协同作用。

移除融合模块中的注意力交叉相乘和高斯分布,不再用注意力做加权,但仍在统一空间拼接两种特征并用同一个分类头学习融合。注意与w/o GCAF区分,它指整个高斯交叉注意力模块被整体移除,并用直接相加替代。与完整模型相比,移除QKV & Softmax后,OA均有下降,说明仅靠直接相加难以根据内容自适应调整两路特征的相对权重;而加入注意力交叉相乘和高斯分布后,融合权重能更集中于空间可信邻域与跨分支高相似度匹配区域,从而带来稳定增益。

为了验证多阶邻居图效果,去掉1阶邻居图仅保留2阶邻居图,则四个数据集的OA均小幅下降,说明2阶邻居图在边界与细小结构的刻画上存在不足。去掉2阶邻居图仅保留1阶邻居图,则OA也会下降,这表明1阶邻居图缺少长距离依赖。当1阶和2阶邻居图协同处理时,如在地物边界用1阶邻居图,在大范围同质区域用2阶邻居图,可提高OA。

表 6 不同模块对总体准确度的影响  
Tab. 6 Impact of different modules on OA (%)

| Num | Ablation setting        | IP    | PU    | SA    | LK    |
|-----|-------------------------|-------|-------|-------|-------|
| 1   | GCFM                    | 96.67 | 98.16 | 98.81 | 97.09 |
| 2   | w/o LFEM                | 96.39 | 98.02 | 98.62 | 96.41 |
| 3   | w/o MSGM                | 91.68 | 91.09 | 96.66 | 94.95 |
| 4   | w/o GCAF                | 95.97 | 96.64 | 98.22 | 95.09 |
| 5   | w/o LFEM and GCAF       | 95.08 | 97.93 | 98.28 | 94.87 |
| 6   | w/o MSGM and GCAF       | 86.97 | 89.39 | 87.88 | 91.91 |
| 7   | w/o LFEM, MSGM and GCAF | 85.55 | 79.35 | 77.65 | 91.50 |
| 8   | w/o QKV and Softmax     | 96.21 | 97.03 | 98.54 | 95.49 |
| 9   | w/o 1 hop               | 96.18 | 97.80 | 98.17 | 96.90 |
| 10  | w/o 2 hop               | 96.23 | 97.73 | 98.33 | 96.88 |

3.8 高斯交叉特征融合前后性能分析

本文采用高斯交叉特征融合策略实现局部与全局特征的融合,该策略借助多头注意力完成多重特征的映射与交叉融合,再通过高斯函数量化动态融合权重,有效改善传统融合方式中特征交互不足问题。为验证该策略的优越性,本节在四个数据集上设计对比实验,将其与仅局部分支、仅全局分支和拼接融合三类常见特征利用方式进行性能比较。结果如表 7 所示。

由表 7 可知,交叉融合策略充分考虑了不同数据集下局部与全局特征的重要性差异,如 PU 数据集更依赖局部特征,IP,SA 与 LK 数据集则更依赖全局特征,可自适应适配不同数据集的特征需求差异。同时弥补了仅局部分支缺乏长距

离依赖、仅全局分支易丢失细节边界和拼接融合因权重固定无法充分挖掘特征关联的不足,有效提升了 OA。

为验证不同融合策略的分类效果差异,凸显交叉融合方法的有效性,以 PU 数据集为例,对各融合策略的分类结果进行可视化对比。具体如图 9 所示。

表 7 融合策略对总体准确度的影响  
Tab. 7 Impact of fusion strategy on OA (%)

| Setting | IP    | PU    | SA    | LK    |
|---------|-------|-------|-------|-------|
| 仅局部分支   | 88.14 | 92.65 | 91.60 | 89.52 |
| 仅全局分支   | 92.73 | 91.12 | 94.18 | 90.45 |
| 拼接融合    | 94.10 | 95.27 | 95.91 | 93.88 |
| 交叉融合    | 96.67 | 98.16 | 98.81 | 97.09 |




图 9 PU 数据集上不同融合策略的可视化对比

Fig. 9 Visual comparison of different fusion strategies on the PU

从图9可知:仅局部分支因缺乏长距离依赖关系,在碎石地和沥青路区域容易产生边界粘连,且明显存在错误分类;仅全局分支受到图卷积过渡平滑特性的影响,在沥青路、碎石地和部分草地区域出现断裂和错误分类;拼接融合虽较减少了地物的错误分类,但在地物密集区域仍存在类别混淆;交叉融合策略通过对局部和全局特征进行动态加权,充分平衡了两类特征的优势,使地物内部的错误分类基本消失,并在一定程度上解决了地物边缘断裂和粘连问题,分类结果的空间一致性和细节精准度得到提升。

## 4 结 论

本文提出了一种高斯交叉特征融合的高光谱图像分类方法,该方法通过所设计的动态多尺度超像素分割算法,实现超像素数量可调节。利用动态因子改变超像素数量,也进一步探索了超像素与数据集之间的潜在关系。设计高斯交叉注意力融合算法,实现局部与全局特征的自调整交叉融合。应用高斯函数作为缩放因子改进了传统注意力机制,使特征自适应融合。实验结果显示,本文方法在Indian Pines, Pavia University,

Salinas 和 LongKou 数据集上均达到最优分类效果,IP 的 OA, AA 和 Kappa 分别为 96.67%, 95.01% 和 96.20%; PU 的 OA, AA 和 Kappa 分别为 98.16%, 96.56% 和 97.57%; SA 的 OA, AA 和 Kappa 分别为 98.81%, 98.46% 和 98.67%; LK 的 OA, AA 和 Kappa 分别为 97.09%, 93.15% 和 97.01%。

虽然此方法整体表现优异,但处理 Indian Pines 此类小规模数据集时,超像素分割尺度较大,导致不同类型的地物信息被错误地划分到同一超像素中,从而影响了 OA,使得 Indian Pines 数据集的结果仍有提升空间。为解决此问题,建议在未来的研究中引入迁移学习或多任务学习策略,持续优化超像素分割尺度选择,特别针对小规模或复杂多样的数据集。这些技术有助于模型适应特定的数据分布,提高分类精度。

### 作者贡献声明:

王文龙:论文构思,验证,可视化呈现,初稿撰写,数据管理,项目管理;

王海荣:论文构思,方法论,获取自主,审核与编辑写作,指导,形式分析;

易之航、杨振业:调查研究;

杨建玲:提供资源。

### 参考文献:

- [1] ZHANG W D, LI Z X, LI G H, *et al.* GACNet: generate adversarial-driven cross-aware network for hyperspectral wheat variety identification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5503314.
- [2] 车森,王海荣,徐玺,等. PSO-DF: 基于高光谱的水稻叶片氮含量估测方法[J]. *遥感技术与应用*, 2024, 39(2): 280-289.  
CHE M, WANG H R, XU X, *et al.* PSO-DF: a hyperspectral model for estimating nitrogen content in rice leaves[J]. *Remote Sensing Technology and Application*, 2024, 39(2): 280-289. (in Chinese)
- [3] WANG Z Y, ZUO R G. An evaluation of convolutional neural networks for lithological mapping based on hyperspectral images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 6414-6425.
- [4] WANG M L, XU Y C, WANG Z S, *et al.* Deep margin cosine autoencoder-based medical hyperspectral image classification for tumor diagnosis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 2520512.
- [5] 景海钊,陶丽杰,张号远. 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]. *Opt. Precision Eng.*, 2024, 32(23): 3504-3512. (in Chinese)
- [6] 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(9): 1395-1407.  
LIU J, LI Y Q, LIU Y. Active learning-clustering-group convolutions network for hyperspectral images classification [J]. *Opt. Precision Eng.*, 2024, 32

- (9): 1395-1407. (in Chinese)
- [7] GAO H M, SHENG R H, CHEN Z H, *et al.* Multiscale random-shape convolution and adaptive graph convolution fusion network for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5516017.
- [8] LIU X, NG A H, GE L L, *et al.* Multibranch fusion: a multibranch attention framework by combining graph convolutional network and CNN for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5528817.
- [9] 李军, 余龙, 段依琳, 等. 基于图神经网络的高光谱遥感图像分类前沿进展[J]. *遥感学报*, 2025, 29(6): 1681-1704.
- LI J, YU L, DUAN Y L, *et al.* Advances in graph neural network-based hyperspectral remote sensing image classification[J]. *National Remote Sensing Bulletin*, 2025, 29(6): 1681-1704. (in Chinese)
- [10] YANG Y Q, TANG X, ZHANG X R, *et al.* Semi-supervised multiscale dynamic graph convolution network for hyperspectral image classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(5): 6806-6820.
- [11] FENG H, WANG Y C, CHEN C, *et al.* Hyperspectral image classification framework based on multichannel graph convolutional networks and class-guided attention mechanism[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5515115.
- [12] 宫学亮, 李玉, 贾淑涵, 等. 基于张量字典学习的高光谱图像稀疏表示分类[J]. *光谱学与光谱分析*, 2025, 45(3): 798-807.
- GONG X L, LI Y, JIA S H, *et al.* Tensor-based dictionary learning sparse representation classification for hyperspectral image[J]. *Spectroscopy and Spectral Analysis*, 2025, 45(3): 798-807. (in Chinese)
- [13] 刘敬, 李洋, 刘逸. 基于分数阶微分的高光谱图像特征提取与分类[J]. *光学精密工程*, 2023, 31(21): 3221-3236.
- LIU J, LI Y, LIU Y. Hyperspectral images feature extraction and classification based on fractional differentiation[J]. *Opt. Precision Eng.*, 2023, 31(21): 3221-3236. (in Chinese)
- [14] 王碧琳, 王生生, 张哲. 面向领域自适应的部分最优传输高光谱图像分类[J]. *光学精密工程*, 2023, 31(17): 2555-2563.
- WANG B L, WANG S S, ZHANG Z. Partial optimal transport-based domain adaptation for hyperspectral image classification[J]. *Opt. Precision Eng.*, 2023, 31(17): 2555-2563. (in Chinese)
- [15] CUI Y, LUO L, WANG L, *et al.* Hyperspectral image classification based on double-hop graph attention multiview fusion network[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 20080-20097.
- [16] XU F L, MEI S H, ZHANG G, *et al.* Bridging CNN and transformer with cross-attention fusion network for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5522214.
- [17] LIU C, YANG L W, LI Z, *et al.* Multi-level relation learning for cross-domain few-shot hyperspectral image classification[J]. *Applied Intelligence*, 2024, 54(5): 4392-4410.
- [18] YU C Y, ZHU Y C, SONG M P, *et al.* Unseen feature extraction: spatial mapping expansion with spectral compression network for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5521915.
- [19] WANG Y F, YU X D, WEN X Y, *et al.* Learning a 3-D-CNN and convolution transformers for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 5504505.
- [20] TIAN R, LIU D Q, BAI Y, *et al.* Swin-MSP: a shifted windows masked spectral pretraining model for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 4509114.
- [21] SUN L, ZHANG H, ZHENG Y H, *et al.* MASSFormer: memory-augmented spectral-spatial transformer for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5516415.
- [22] 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.
- [23] LIU C, DONG A, DONG D M, *et al.* Contrastive graph convolution network with skip connec-



- tions for few-shot hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 5502005.
- [241] 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.
- [25] WANG Q W, HUANG J B, WANG S Y, *et al.* Community structure guided network for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 4404115.
- [26] WANG G C, ZHANG X R, PENG Z L, *et al.* S2Mamba: a spatial-spectral state space model for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5511413.

## 作者简介:



王文龙(1999—),男,宁夏银川人,硕士研究生,2022年于电子科技大学成都学院获得学士学位,主要从事高光谱图像分类研究。E-mail: 2811862998@qq.com

## 通讯作者:



王海荣(1977—),女,宁夏石嘴山人,教授,博士,2017年于东北大学获得博士学位,主要从事大数据知识工程与智能信息处理研究, E-mail: wanghr@nun.edu.cn