

基于多注意力机制与编译图神经网络的高光谱图像分类

孙杰¹ 杨静^{1,2} 丁书杰² 李少波^{1,2} 胡建军³

(1. 贵州大学机械工程学院, 贵阳 550025; 2. 贵州大学省部共建公共大数据国家重点实验室, 贵阳 550025;

3. 南卡罗莱纳州大学计算机科学与工程系, 哥伦比亚 29208)

摘要: 针对高光谱图像(Hyperspectral image, HSI)分类研究中小样本学习时,无法达到理想分类效果的问题,以多注意力机制融合、编译图神经网络与卷积神经网络有机结合提出了一种新的高光谱图像分类方法。设计了一种基于混合注意力机制的网络(Multiple mixed attention convolutional neural network, MCNN)与编译图神经网络(Compiled graph neural network, CGNN),在学习样本有限的情况下,其能有效保留 HSI 的光谱与空间信息。引入的图编码器与图解码器可以有效地映射不规则的 HSI 地物类别特征信息。设计的多注意力机制可以重点关注一些重要的空间像素特征。研究了不同训练样本下对不同算法学习示例分类的影响,在公共数据集 Botswana (BS) 的实验表明,本文方法比 CEGCN (CNN-enhanced graph convolutional network)、WFCG (Weighted feature fusion of convolutional neural network) 算法总体分类精度 (Overall classification accuracy, OA) 分别高 2.72、3.86 个百分点。同样在 IndianPines (IP) 数据集上仅用 3% 训练样本数据的实验结果显示,本研究方法比 CEGCN 与 WFCG 算法的 OA 分别高 0.44、1.42 个百分点。说明本研究提出的方法不仅对 HSI 具有良好的空间与光谱信息感知能力,而且在微小学习数据下仍然表现出强有力的分类准确性。

关键词: 高光谱图像分类; 图神经网络; 注意力机制; 超像素分割

中图分类号: TP75

文献标识码: A

文章编号: 1000-1298(2024)03-0183-10

OSID: 

Hyperspectral Image Classification Based on Multi-attention Mechanism and Compiled Graph Neural Networks

SUN Jie¹ YANG Jing^{1,2} DING Shujie² LI Shaobo^{1,2} HU Jianjun³

(1. School of Mechanical Engineering, Guizhou University, Guiyang 550025, China

2. State Key Laboratory of Public Big Data, Guizhou University, Guiyang 550025, China

3. Department of Computer Science and Engineering, University of South Carolina, Columbia 29208, USA)

Abstract: In recent years, although some scholars have achieved satisfactory research results on hyperspectral image (HSI) classification, they often fail to achieve ideal classification results when facing small sample learning. Aiming at this problem, a hyperspectral image classification method was proposed by the organic combination of multi-attention mechanism fusion, compiled graph neural network and convolutional neural network. Firstly, a type of multiple mixed attention convolutional neural network (MCNN) and compiled graph neural network (CGNN) was designed, which can effectively retain the spectral and spatial information of HSI with limited learning samples; secondly, the introduced graph encoder and graph decoder can effectively map irregular HSI feature information; finally, the designed multi-attention mechanism can focus on some important HSI feature categories. In addition, the effect of different training samples on different algorithms for learning example classification was also investigated. Experiments on the public dataset Botswana (BS) showed that the proposed method improved the overall classification accuracy (OA) by 2.72 percentage points and 3.86 percentage points compared with the current state-of-the-art algorithms (CNN-enhanced graph convolutional network, CEGCN; weighted

收稿日期: 2023-12-29 修回日期: 2024-01-14

基金项目: 国家自然科学基金项目(62166005)、国家重点研发计划项目(2018AAA0101800)、贵州省科技支撑计划项目(QKH[2022]130、QKH[2022]003、QKH[2021]335)和贵阳市科技人才培养对象及培养项目(ZKHT[2023]48-8)

作者简介: 孙杰(1997—),男,硕士生,主要从事遥感图像处理研究,E-mail: gs.sunj21@gzu.edu.cn

通信作者: 杨静(1991—),男,副教授,博士,主要从事多模态数据融合感知研究,E-mail: jyang23@gzu.edu.cn

feature fusion of convolutional neural network, WFCG). Similarly, the experimental results on the IndianPines (IP) dataset with only 3% of the training sample data showed that the method also improved the OA of the current state-of-the-art algorithms (CEGCN and WFCG) by 0.44 percentage points and 1.42 percentage points, respectively. This demonstrated that the proposed method not only had good spatial and spectral information perception for HSI, but also showed strong classification accuracy with small learning data.

Key words: hyperspectral image classification; graph neural network; attention mechanism; superpixel segmentation

0 引言

由于遥感影像技术快速发展,高光谱图像^[1]以较窄的波段区间、较多的波段数量提供了丰富的空间与光谱信息,能够对地物进行细致的分割和鉴别,因此广泛应用于农业遥感^[2-4]、地质勘探^[5]、海洋监测^[6]等领域。然而,一些常用的方法包括 SVM^[7]、贝叶斯估计^[8]等都是提取浅层光谱信息,未能深层次利用 HSI 的空间特征,从而导致了分类精度不佳。

随着深度学习领域中卷积神经网络(CNN)^[9-10]的兴起,许多研究者利用深度学习框架对高光谱图像分类做了许多尝试。例如 ROY 等^[11]结合 2DCNN 与 3DCNN 同时学习时间域与空间域特征,提出了一种 HybridSN 高光谱图像分类方法,同时在一定程度上降低了模型复杂度。WANG 等^[12]改进了一种由端到端的密集卷积分类结构框架用于空间光谱学习,该方法以密集结构重用之前的光谱空间特征,提高了特征利用率。这些卷积神经网络的实验结果表明,CNN 不仅能捕获空间与光谱上的信息^[13],还能保证 HSI 原有的数据结构不被破坏。一些学者也发现利用多注意力机制^[14]获取 HSI 数据中不同维度的光谱信息与空间信息可以取得更好的分类结果。如唐婷等^[15]提出了一种融合卷积长短期记忆和多注意力机制网络的三支高光谱图像方法。杨国亮等^[16]利用双注意力机制与三维卷积结合的方式来解决学习样本较少时的难题。由于高光谱图像传感器捕获的数据用于显示地物样本的数量有限,而传统的卷积神经网络方法必须在大量的有效样本情况下才能取得相对较为理想的结果。而图神经网络(GNN)方法不仅可以对非欧几里得结构化数据进行学习^[17-18],而且从 DONG 等^[19]的实验中可以看出,在学习数据样本非常有限的情况下也能很好地完成收敛任务。因此利用图神经网络对 HSI 进行端到端的分类学习,可以有效缓解卷积神经网络学习的缺陷。如 LIU 等^[20]探索以图神经网络与卷积神经网络相结合的方式应用于高光谱图像分类,通过超像素

分割与图编码器^[21]转换为图节点特征,再利用相邻节点构建邻接矩阵,这样能更加准确地反映相邻地物之间的空间关系。张佳宝等^[22]为了解决模型训练时间长、分类效率不高等问题提出了一种能有效融合光谱空间信息的超像素图卷积分类方法。孔毅等^[23]利用光谱注意力模块对光谱全局与局部进行交互减少冗余的波段消息提出了一种基于半监督的高光谱图像分类方法。虽然图神经网络在高光谱图像分类中取得了一定的效果,但无法随着节点特征的不同,灵活分配相应的权值系数,不能有效地保留局部特征信息而导致了 HSI 空间信息与光谱信息的丢失。

对于上述问题,本文提出一种基于混合注意力机制的编译图神经网络(HAMGCN)方法。以混合注意力机制提取空谱信息并联合编译图神经网络的超像素特征工作方式来聚合像素特征,以解决训练样本数据较少时分类精度不高的问题。通过单个训练样本与不同训练样本的实验,验证编译图神经网络(GNN)、混合注意力机制与卷积神经网络(CNN)三者的结合用于 HSI 图像分类可以形成优势互补。最后通过在 IndianPines (IP)、Botswana (BS) 和 WHU-Hi-HanChuan(WHC)3 个公共数据集上的消融实验,来证明本研究的有效性。

1 研究方法

1.1 分类网络框架搭建

首先利用主成分分析(Principal component analysis,PCA)算法^[24]对具有上百个波段的 HSI 数据进行降维处理,然后通过超像素分割算法(Simple linear iterative clustering, SLIC)^[25]使 HSI 图像的像素特征以 k 均值聚类方式生成超像素特征。同时,通道卷积神经网络(Channel convolutional neural network, CCNN)对 HSI 数据的频谱通道进行压缩,再把两者的特征图通过重塑的方式投影到编译图神经网络中,用于超像素特征的学习,然后利用神经网络的非线性特性^[26]来增加特征图的表达能力,通过学习数据的特征来进行 HSI 频谱压缩;通道注意力网络 CCNN 中的卷积层提取主要

的通道特征信息,通道注意力机制对提取到的光谱与空间信息分配权重获取重要的光谱特征信息。混合注意力子网络 MCNN 对通道子网络 CCNN 处理后的数据进行空间像素特征提取,最后

把 CGNN 与 MCNN 学习的特征进行通道叠加操作 (Contat),通过分类器输出分类结果。具体分类网络框架如图 1 所示,图中 G 、 H 、 B 分别为提取特征图的通道数、高度和宽度。




图 1 HAMGCN 网络结构图

Fig. 1 HAMGCN network structure

1.2 HSI 像素特征转换

卷积神经网络 (CNN) 通过规则的像素点来提取特征,而图神经网络则采用不规则的超像素特征进行特征采样。为了使编译图神经网络与 CNN 网络在同样的数据格式下协同工作,首先使用主成分分析使得高维的 HSI 数据线性投影到低维空间中,以低维的数据形式保留较多的原高维 HSI 的数据特征。然后通过 SLIC 超像素分割算法使 HSI 图像的像素特征以聚类方式生成超像素特征作为 GNN 的输入。具体实现过程如图 2 所示,在二者转换过程中会产生一个关联矩阵 $C \in \mathbf{R}^{H \times B \times T}$ 来记录像素点与超像素点之间的转换。图 2 中的 HSI 数据是高光谱传感器获取的数据,包含很多波段,通过遥感图像处理软件 ENVI 分配给 RGB 通道不同波长的波段实现假彩色合成显示图,其中 T 表示分割的超像素数量, R 表示空间维度。定义像素与超像素之间的关系 $C_{i,j}$ 为

$$C_{i,j} = \begin{cases} 1 & (\bar{X}_i \in S_j) \\ 0 & (\bar{X}_i \notin S_j) \end{cases} \quad (1)$$

其中

$$\bar{X} = \text{Flatten}(X)$$




图 2 像素级特征转换为超像素特征

Fig. 2 Pixel-level features converted to superpixel features

式中 $C_{i,j}$ ——在空间位置 (i,j) 关联矩阵 C 所记录的像素与超像素之间转换的详细信息

S_j ——空间位置中第 j 个超像素

$\text{Flatten}(\cdot)$ ——HSI 数据空间像素扁平化函数

$\bar{X}_i$ ——空间位置中第 i 个像素

通过图编码器生成 $G = (V, E)$ 无向图, E 表示图数据的边,即图编码为编译图神经网络的编译映射部分。再使用图编码器将关联矩阵 C 与 HSI 像素特征 X 进行编码,生成新的节点特征向量 V

$$V = \text{Encoder}(X; C) = \tilde{C}^T \text{Flatten}(X) \quad (2)$$

式中 $\tilde{C}$ ——关联矩阵 C 的归一化处理

Encoder——编码器

经过编译图卷积提取图节点中的特征,再使用图解码器将图节点中的特征投影到空间维度中。

$$\bar{X} = \text{Decoder}(V; C) = \text{Reshape}(V \cdot C) \quad (3)$$

式中 $\text{Reshape}(\cdot)$ ——恢复扁平化的 HSI 数据

Decoder——解码器

使其投影回初始的空间维度,图解码可以视为编译图神经网络的图解码还原部分。

1.3 编译图神经网络

超像素 HSI 图数据需要送到编译图神经网络进行超像素特征提取,假设其中有 P 个节点,编译后的低维超像素特征映射 $V \in \{v_1, v_2, \dots, v_n\}$ 以图数据的形式输入编译图神经网络。图神经网络公式为

$$V^{(l+1)} = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} V^{(l)} W^{(l)}) \tag{4}$$

其中 $\tilde{A} = A + I$
式中 A ——记录节点连接关系的邻接矩阵
 I ——单位矩阵
 $\tilde{D}$ ——归一化度矩阵
 $V^{(l)}$ ——第 l 层的特征
 $W^{(l)}$ ——第 l 层训练权重
 σ ——激活函数

$\tilde{A}$ ——邻接矩阵单位相加后的归一化矩阵
利用图卷积构造了双层编译图卷积层来提取 HSI 中相邻地物块中的光谱信息,表示为

$$X = f(V, A) = \text{softmax}(\hat{A} \tanh(\hat{A} V W^{(0)}) W^{(1)}) \tag{5}$$

式中 $\hat{A}$ ——标准化邻接矩阵

1.4 多注意力机制模块

经过卷积核为 1×1 的卷积操作后,所提取到的特征 $P \in R^{o \times o}, o \times o$ 表示 HSI 空间像素数,则

$$P_{ji} = \frac{\exp(Z_i \times Z_j)}{\sum_{i=1}^N \exp(Z_i \times Z_j)} \tag{6}$$

式中 P_{ji} ——在空间位置 (i, j) 处的节点特征
 Z_i, Z_j —— 1×1 卷积通过非线性特征变化生成的一对特征映射

之后再对 P_{ji} 进行空间映射使其重塑为新特征图,同时分配一个可自动学习参数 β ,最终得到通道注意力机制计算公式为

$$X_j = \beta \sum_{i=1}^N (P_{ji} Z_j) + Z_j \tag{7}$$

式中 X_j ——经过通道注意力机制处理后的特征图
通道注意力机制由图 1 HAMGCN 结构示意图中红色部分(C attention)表示,其中工作原理如图 3 所示。




图 3 通道注意力机制工作原理图

Fig. 3 Working principle of channel attention mechanism

由于 HSI 空间像素在不同地物块中的特征提取不同,所以添加 SE 通道注意力机制是为了对提取的特征图进行通道特征加强学习,使其在空间特征部分有着更高的利用率。假设此时输入 HSI 特征图的尺寸为 $X_{h,w,c}^0$,首先将全局信息压缩到通道学习中

$$X_{h,w,c}^1 = F_{sq}(f_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W f_c(i, j) \tag{8}$$

式中 $X_{h,w,c}^1$ ——经过压缩的特征图
 f_c ——滤波器学习参数输出
 F_{sq} ——挤压函数

经过压缩的特征图 $X_{h,w,c}^1$ 再进行全连接层的通道特征学习。

$$X_{h,w,c}^* = F_{ex}(X_{h,w,c}^1, W) = \sigma(g(X_{h,w,c}^1, W)) = \sigma(W_2 \delta(W_1 X_{h,w,c}^1)) \tag{9}$$

式中 F_{ex} ——全连接层函数
 W_1, W_2 ——HSI 空间特征通道学习权值系数
 δ ——ReLU 激活函数
 $X_{h,w,c}^*$ ——激活后的特征图

此时特征图尺寸不变,最后通过特征图激励操作恢复 HSI 空间像素被压缩的维度。

$$X_{h,w,c}^{\sim} = F_{scale}(f_c, X_{h,w,c}^*) = X_{h,w,c}^* f_c \tag{10}$$

2 实验结果与分析

2.1 高光谱数据集

为了评价本文所提算法的性能,选取 3 个广泛使用的 HSI 基准数据集进行对比实验,分别是 IndianPines(IP)数据集、Botswana(BS)数据集和 WHU-Hi-HanChuan(WHC)数据集。

(1)IP 数据集:由机载红外光谱仪 AVIRIS 传感器在美国印第安纳州西北部的印度松测试现场采集,它包含 145 像素 $\times$ 145 像素和 200 个光谱反射带,光谱覆盖范围 $0.4 \sim 2.5 \mu m$,真实地面标签为 16 类覆盖植被。训练样本、验证样本与测试样本见表 1。

(2)BS 数据集:由 NA EO-1 卫星于 2001—2004 年在博茨瓦纳奥卡万戈河三角洲采集的数据,包含 1 476 像素 $\times$ 256 像素与 145 个波段,光谱波长在 $0.4 \sim 2.5 \mu m$ 之间,空间分辨率为 30 m,真实地面标签为 14 类覆盖类植被。训练样本、验证样本与测试样本见表 2。

(3)WHC 数据集:数据在湖北省由焦距 17 mm 的 Head wall 纳米超规格成像传感器采集,图像尺寸为 1 217 像素 $\times$ 303 像素,有 274 个波长 $400 \sim 1\,000\,nm$ 波段,空间分辨率约为 0.109 m,地面标签物为 16 类覆盖农作物。训练样本、验证样本与测试

表 1 IP 数据集划分后的训练、验证和测试样本

Tab.1 IP dataset training, validation and test samples

类别	名称	总体数量	训练集	验证集	测试集
1	紫花苜蓿	46	5	1	40
2	非耕作玉米	1 428	71	13	1 344
3	玉米磨坊	830	41	7	782
4	玉米	237	12	2	223
5	草牧场	483	24	4	455
6	草树	730	37	6	687
7	割草的牧场	28	5	1	22
8	干草风车	478	24	4	450
9	燕麦	20	5	1	14
10	非耕作大豆	972	49	9	914
11	大豆磨房	2 455	109	23	2 323
12	大豆处理场	593	30	5	558
13	小麦	205	12	2	191
14	树林	1 265	63	12	1 190
15	建筑草坪	386	19	3	364
16	石头钢材地	93	6	1	86
总和		10 249	512	94	9 643

表 2 BS 数据集训练、验证和测试样本

Tab.2 BS dataset training, validation and test samples

类别	名称	总体数量	训练集	验证集	测试集
1	水	270	3	3	264
2	河马草	101	2	2	97
3	漫滩草 1	251	3	3	245
4	漫滩草 2	215	3	3	209
5	芦苇	269	3	3	263
6	河岸	269	3	3	263
7	消防车	259	3	3	253
8	岛内部	203	3	3	197
9	刺槐林地	314	4	4	306
10	灌木地	248	3	3	242
11	草原	305	4	4	297
12	短毛竹	181	2	2	177
13	混合毛竹	268	3	3	262
14	裸露土壤	95	1	1	93
总和		3 248	40	40	3 168

样本见表 3。通过与经典算法 SVM^[27]、卷积神经网络算法 (HybridSN^[11]、HuEtAl^[28])、图神经网络算法 GNN^[29]、GAT^[30]) 和卷积与图神经混合算法 (WFCG^[19]、CEGCN^[20]) 进行对比,验证本文方法的有效性。

2.2 对比试验

2.2.1 相同训练样本下分类结果

2.2.1.1 IP 数据集

IP 数据集的分类图和分类结果如图 4 和表 4 所示。为了保证每个类别有足够的训练数据,选取 5% 数据作为训练数据。由图 4 可以看出,经典方法 SVM 的误分类效果比较明显,而三维卷积与二维卷积结合的方法 (HybridSN) 对非耕作大豆与石头钢

材地的分类结果比 SVM 方法较为优良,这说明卷积神经网络可以挖掘出 HSI 更多的空间维度与光谱波段的信息。本文所提 HAMGCN 算法在总体分类精度 (Overall classification accuracy, OA)、平均分类精度 (Average classification accuracy, AA) 和 Kappa 系数上均获得最高数值,比 CEGCN、WFCG 算法的 OA 分别提高 0.44、1.42 个百分点。

表 3 WHC 数据集训练、验证和测试样本

Tab.3 WHC dataset training, validation and test samples

类别	名称	总体数量	训练集	验证集	测试集
1	草莓	44 735	224	43	44 468
2	豇豆	22 753	114	22	22 617
3	黄豆	10 287	52	10	10 225
4	高粱	5 353	27	5	5 321
5	空心菜	1 200	6	1	1 193
6	西瓜	4 533	23	4	4 506
7	菜地	5 903	30	6	5 867
8	树	17 978	90	18	17 870
9	草坪	9 469	48	9	9 412
10	红屋顶	10 516	53	10	10 453
11	灰色屋顶	16 911	85	17	16 809
12	塑料堆	3 679	19	4	3 656
13	土壤	9 116	46	9	9 061
14	马路	18 560	93	18	18 449
15	发光物体	1 136	6	1	1 129
16	水	75 401	388	75	74 938
总和		257 530	1 304	252	255 974

2.2.1.2 BS 数据集下分类图和分类结果

BS 数据集下的分类图和分类结果如图 5 和表 5 所示。从 BS 分类结果看出,每个类别的分类结果也都比较均衡,基于卷积神经网络的 HybridSN 与 HuEtAl 算法在较少的学习样本下,分类结果优于传统学习 SVM 算法,但是总体分类效果还是受限于卷积网络的局限性。而本文算法的 OA 比 CEGCN、WFCG 算法分别提高 2.72、3.86 个百分点。

2.2.1.3 WHC 数据集下的分类图和分类结果

WHC 数据集下的分类图和分类结果如图 6 和表 6 所示。为了使得假彩色图更加清楚,增大 RGB 通道中的绿色通道值。由于该数据集的样本丰富度较高,所以本文仅使用 0.5% 的样本作为训练数据。在表征非线性的 HSI 图像时,卷积神经网络有着明显的优势。但是,在学习样本大量缺失的条件下,卷积神经网络 CNN 相比较于 GNN 方法也有一定的局限性。本文算法在图神经网络的基础上加上多注意力机制灵活的分类权值,与 CGNN 对空间超像素的特征提取以三者协同作用的方式进一步挖掘了 HSI 的空间与光谱信息。




图 4 IP 数据集分类图

Fig. 4 Classification results of IP data set

表 4 使用 5% 训练样本的 IP 数据集分类结果

Tab. 4 Classification results of IP dataset using 5% training samples

类别	SVM 算法	HybridSN 算法	HuEtAI 算法	GCN 算法	GAT 算法	CEGCN 算法	WFCG 算法	HAMGCN 算法	%
1	0.00 ± 0.00	39.08 ± 16.50	0.00 ± 0.00	10.70 ± 21.40	0.00 ± 0.00	90.70 ± 4.16	82.33 ± 9.82	94.42 ± 4.05	
2	42.24 ± 2.34	77.86 ± 2.26	36.00 ± 6.73	76.73 ± 7.99	66.31 ± 3.24	96.22 ± 1.89	94.91 ± 3.20	96.79 ± 1.84	
3	0.00 ± 0.00	68.04 ± 5.03	6.34 ± 9.50	62.93 ± 17.04	77.09 ± 6.90	97.29 ± 1.80	97.39 ± 2.25	98.05 ± 0.75	
4	2.06 ± 4.61	57.54 ± 6.54	8.82 ± 10.69	91.45 ± 4.96	88.14 ± 10.93	97.24 ± 3.18	97.77 ± 1.65	92.86 ± 9.93	
5	16.10 ± 12.39	85.88 ± 2.19	8.70 ± 11.04	78.89 ± 8.11	59.01 ± 6.91	97.17 ± 1.33	96.38 ± 1.18	96.90 ± 1.76	
6	72.74 ± 2.52	94.62 ± 1.85	71.00 ± 5.59	78.55 ± 5.83	57.52 ± 8.39	98.01 ± 0.32	98.77 ± 0.37	98.25 ± 0.40	
7	0.00 ± 0.00	35.22 ± 29.02	0.00 ± 0.00	72.86 ± 0.43	0.00 ± 0.00	75.97 ± 2.85	3.85 ± 5.96	86.12 ± 12.99	
8	88.92 ± 0.60	95.82 ± 1.01	82.40 ± 3.80	97.46 ± 0.17	97.46 ± 0.17	99.78 ± 0.35	99.69 ± 0.39	99.91 ± 0.11	
9	0.00 ± 0.00	53.62 ± 15.15	0.00 ± 0.00	0.00 ± 0.00	0.00 ± 0.00	18.19 ± 7.50	0.00 ± 0.00	49.24 ± 22.42	
10	3.16 ± 6.36	77.20 ± 3.93	10.30 ± 14.54	65.94 ± 0.024	65.88 ± 13.21	96.08 ± 1.66	94.14 ± 2.20	97.83 ± 0.78	
11	58.34 ± 0.22	82.88 ± 3.18	58.92 ± 1.62	89.30 ± 2.98	85.33 ± 2.26	98.64 ± 0.66	98.47 ± 0.90	98.99 ± 0.52	
12	3.54 ± 7.32	68.06 ± 8.32	7.80 ± 7.48	73.18 ± 11.84	71.84 ± 4.77	97.17 ± 1.96	98.64 ± 1.34	98.49 ± 0.36	
13	51.94 ± 26.94	97.06 ± 2.07	34.90 ± 42.36	65.16 ± 22.85	8.68 ± 10.65	99.17 ± 0.70	99.68 ± 0.63	98.75 ± 1.81	
14	83.44 ± 0.27	95.32 ± 1.27	83.28 ± 0.68	93.93 ± 4.72	88.97 ± 3.52	99.83 ± 0.09	99.55 ± 0.44	99.45 ± 0.26	
15	3.24 ± 3.80	62.00 ± 7.67	14.58 ± 7.26	70.56 ± 7.09	72.56 ± 5.47	98.45 ± 1.25	95.19 ± 5.33	98.23 ± 1.51	
16	88.46 ± 3.11	89.48 ± 6.76	88.88 ± 5.67	35.96 ± 34.53	0.00 ± 0.00	94.88 ± 4.51	96.51 ± 2.65	97.44 ± 2.00	
OA	53.50 ± 0.76	80.48 ± 2.09	52.27 ± 2.56	79.78 ± 1.56	73.70 ± 1.79	97.63 ± 0.27	96.95 ± 0.58	98.07 ± 0.23	
AA	32.29 ± 1.96	73.73 ± 2.78	32.00 ± 6.49	66.48 ± 5.45	52.42 ± 1.49	90.92 ± 0.53	84.58 ± 0.66	93.86 ± 2.24	
Kappa 系数	43.66 ± 1.06	77.52 ± 2.86	42.76 ± 3.67	76.92 ± 1.79	69.83 ± 2.13	97.30 ± 0.31	96.52 ± 0.67	97.80 ± 0.27	

2.2.2 不同训练样本下分类结果

为了进一步说明本文方法的泛化性与鲁棒性，在 IP 基准数据集上，随机选取 1%、3%、5%、7% 和 9% 的数据作为训练样本。BS 数据集选取 1%、2%、3%、4% 和 5% 的数据为训练样本，WHC 选择 0.1%、0.3%、0.5%、0.7%、0.9% 的数据为训练集，图 7 为不同训练样本下不同方法的分类准确率。

(1)IP 数据集下不同训练样本的分类结果如图 7a 所示，随着学习样本从 1% 增加至 9%，基于图卷积方法的 GCN 算法比基于卷积神经网络方法的 HybridSN 算法精度高，在学习样本为 5% 左右时两方法的总体精度接近，在样本不足时 GCN 算法以图节点的特征聚合方式来提取样本特征，使其可以较好地预测地物分类结果。




图 5 BS 数据集分类图
Fig. 5 Classification results of BS data set

表 5 使用 1% 训练样本的 BS 数据集分类结果

Tab. 5 Classification results of BS dataset using 1% training samples									%
类别	SVM 算法	HybridSN 算法	HuEtAl 算法	GCN 算法	GAT 算法	CEGCN 算法	WFCG 算法	HAMGCN 算法	
1	98.28 ± 1.03	93.36 ± 3.63	99.28 ± 0.70	73.52 ± 12.67	76.03 ± 18.85	95.26 ± 6.76	89.97 ± 13.2	96.53 ± 4.92	
2	0.00 ± 0.00	37.58 ± 23.17	75.50 ± 14.41	65.21 ± 22.39	36.29 ± 44.83	92.86 ± 11.47	82.83 ± 21.41	89.74 ± 10.9	
3	0.00 ± 0.00	72.46 ± 6.83	77.04 ± 6.02	49.52 ± 31.24	52.19 ± 25.32	91.40 ± 10.69	85.51 ± 13.93	87.08 ± 10.67	
4	0.00 ± 0.00	70.84 ± 6.15	64.78 ± 10.68	45.22 ± 29.78	29.70 ± 14.13	98.67 ± 2.67	95.15 ± 5.53	97.71 ± 4.57	
5	69.24 ± 5.85	59.46 ± 13.00	70.92 ± 10.03	30.12 ± 6.78	35.61 ± 13.99	67.90 ± 9.29	84.58 ± 8.34	79.92 ± 8.39	
6	35.88 ± 14.65	42.94 ± 6.09	50.96 ± 11.02	41.24 ± 5.09	53.98 ± 9.80	72.85 ± 19.43	78.34 ± 15.75	90.52 ± 10.74	
7	0.00 ± 0.00	80.52 ± 10.06	82.48 ± 13.90	79.32 ± 17.32	88.77 ± 7.03	93.10 ± 6.81	93.39 ± 6.57	93.25 ± 8.26	
8	0.00 ± 0.00	62.30 ± 13.69	58.76 ± 28.65	36.16 ± 26.26	47.32 ± 19.61	89.12 ± 12.93	84.05 ± 13.31	85.05 ± 19.14	
9	31.28 ± 8.63	44.76 ± 3.07	69.42 ± 10.53	99.67 ± 0.65	99.87 ± 0.26	100 ± 0.00	98.95 ± 2.10	100 ± 0.00	
10	0.00 ± 0.00	36.30 ± 18.64	57.58 ± 12.29	68.38 ± 26.36	42.36 ± 33.7	86.53 ± 16.63	76.92 ± 18.84	99.75 ± 0.50	
11	53.84 ± 2.23	71.84 ± 4.19	85.72 ± 6.61	88.25 ± 11.13	91.25 ± 8.02	98.25 ± 1.40	96.57 ± 4.36	99.60 ± 0.65	
12	0.00 ± 0.00	51.94 ± 16.17	73.34 ± 5.42	74.19 ± 38.52	99.66 ± 0.67	100 ± 0.00	93.26 ± 12.37	99.89 ± 0.23	
13	43.78 ± 1.23	45.72 ± 8.01	49.48 ± 28.47	80.00 ± 40.00	98.32 ± 3.36	100 ± 0.00	100 ± 0.00	100 ± 0.00	
14	10.62 ± 23.75	48.48 ± 29.22	89.80 ± 7.37	66.31 ± 33.15	59.53 ± 31.13	66.50 ± 27.64	71.08 ± 21.45	58.25 ± 25.16	
OA	39.26 ± 0.90	61.79 ± 4.81	72.31 ± 4.97	65.23 ± 10.57	67.78 ± 6.56	90.33 ± 2.04	89.19 ± 4.46	93.05 ± 2.01	
AA	23.72 ± 2.13	56.57 ± 6.47	69.03 ± 6.68	64.08 ± 10.79	65.06 ± 8.73	89.46 ± 3.06	87.90 ± 5.65	91.24 ± 2.10	
Kappa 系数	33.36 ± 1.01	58.56 ± 5.25	70.00 ± 5.39	62.33 ± 11.48	65.01 ± 7.18	89.52 ± 2.21	88.28 ± 4.85	92.47 ± 2.18	

(2)BS 数据集下不同训练样本的分类结果如图 7b 所示,由于样本丰富度较为均衡,从图中的分类结果来看 SVM 算法取得的分类结果是所有对比算法中最差的。HybridSN 算法在学习样本从 1% 增加至 5% 的过程中,起初与 IP 数据集一致,分类结果低于 GCN 算法,随着样本数量的增加,学习到的特征越来越多,分类结果也越来越好。

(3)WHC 数据集下不同训练样本的分类结果如图 7c 所示,与其他 2 个数据集相比,WHC 数据集更为庞大。为了体现出对少样本学习的公正性,进一步削减训练数据,仅用 0.1% 的样本作为各个对比算法初始训练样本,以此进一步增加至 0.9% 来验证各个算法在不同样本下的分类预测能力。在混合图神经网络与图卷积方法中,本文所提出的 HAMGCN 算法在各个分类阶段依旧表现出较优的效果。

2.3 消融实验

本文所提 HAMGCN 算法以多注意力机制的权值学习与编译图神经网络的超像素不规则学习的特点来提高模型的识别能力。为了充分证明本算法各个子模块的有效性,本文以编译图神经网络、卷积神经网络与注意力机制和 HAMGCN 在 3 个数据集下的分类结果来展示每个子部分的分类作用。

表 7 给出 3 个数据集下总体分类精度的分类结果。在 IP 数据集上,CGNN 子网络总体分类精度仅为 64.74%,这是由于在该类样本学习条件下,当将 HSI 转换为图节点特征时,CGNN 模型频繁错误识别重要的光谱节点信息。然而,在没有 GNN 的成分下本研究设计的网络模块 CCNN + MCNN 对地物的分类效果明显提升。这是因为卷积网络对空间的线性非特征映射具有良好的拟合性,再加上多注意力机制的权值分配使得模型的识别性能有了较大幅度




图 6 WHC 数据集分类图

Fig.6 WHC data set classification results

表 6 使用 0.5 % 训练样本的 WHC 数据集分类结果

Tab.6 Classification results of WHC dataset using 0.5 % training samples									%
类别	SVM 算法	HybridSN 算法	HuEtAl 算法	GCN 算法	GAT 算法	CEGCN 算法	WFCG 算法	HAMGCN 算法	
1	48.44 ± 0.92	87.04 ± 0.43	57.68 ± 2.03	97.66 ± 0.46	98.39 ± 0.68	99.27 ± 0.23	99.06 ± 0.21	99.54 ± 0.16	
2	5.38 ± 5.58	80.64 ± 2.56	73.08 ± 9.27	87.23 ± 3.17	88.26 ± 1.84	96.99 ± 1.47	95.64 ± 0.63	97.29 ± 1.31	
3	0.00 ± 0.00	91.52 ± 1.81	86.12 ± 9.62	93.57 ± 2.69	68.27 ± 5.25	98.04 ± 1.28	98.40 ± 1.14	99.13 ± 0.21	
4	0.00 ± 0.00	60.08 ± 4.90	21.56 ± 37.46	93.32 ± 3.48	92.68 ± 5.95	97.14 ± 1.28	97.00 ± 1.47	98.14 ± 1.03	
5	0.00 ± 0.00	46.72 ± 12.53	2.40 ± 2.84	68.06 ± 17.58	26.95 ± 18.67	81.59 ± 5.22	1.74 ± 2.60	92.49 ± 10.15	
6	21.52 ± 11.22	85.50 ± 1.99	58.10 ± 29.56	72.07 ± 12.01	31.81 ± 5.30	81.96 ± 4.67	63.48 ± 6.64	85.66 ± 1.74	
7	51.04 ± 4.56	83.08 ± 2.70	64.14 ± 4.81	82.79 ± 5.42	61.03 ± 12.04	93.52 ± 4.08	91.67 ± 4.34	94.70 ± 2.63	
8	1.12 ± 2.50	80.82 ± 3.63	53.74 ± 5.16	87.23 ± 2.76	65.72 ± 3.26	94.90 ± 1.92	94.13 ± 1.24	95.85 ± 1.75	
9	17.24 ± 4.52	91.00 ± 1.32	85.06 ± 17.84	66.76 ± 6.09	49.25 ± 2.56	95.64 ± 2.07	95.73 ± 0.81	93.07 ± 2.95	
10	5.50 ± 4.31	93.08 ± 1.22	89.26 ± 2.93	82.31 ± 7.35	70.39 ± 4.48	98.69 ± 0.54	97.84 ± 0.81	99.10 ± 0.43	
11	0.00 ± 0.00	65.48 ± 6.57	30.48 ± 33.89	95.18 ± 3.19	91.12 ± 1.68	99.25 ± 0.16	98.72 ± 0.78	99.38 ± 0.20	
12	0.26 ± 0.48	68.46 ± 2.91	43.70 ± 15.80	86.49 ± 4.85	65.90 ± 33.17	88.43 ± 6.61	68.38 ± 14.48	97.14 ± 1.20	
13	70.14 ± 0.99	86.38 ± 1.13	74.14 ± 12.01	64.39 ± 7.90	15.76 ± 2.15	84.53 ± 3.63	76.80 ± 4.30	90.06 ± 2.37	
14	33.78 ± 6.92	74.58 ± 2.57	69.28 ± 6.19	87.45 ± 3.41	83.27 ± 3.50	96.06 ± 1.13	95.59 ± 1.79	97.71 ± 0.94	
15	79.82 ± 0.66	97.84 ± 0.15	91.74 ± 15.17	55.47 ± 9.95	26.00 ± 16.73	53.29 ± 12.92	19.83 ± 17.88	64.98 ± 13.95	
16	69.90 ± 1.45	92.42 ± 0.29	91.56 ± 3.97	98.48 ± 0.33	98.65 ± 0.64	99.81 ± 0.03	99.63 ± 0.23	99.76 ± 0.06	
OA	59.09 ± 0.59	76.97 ± 1.58	82.57 ± 3.90	90.88 ± 0.62	83.38 ± 1.21	97.04 ± 0.34	95.24 ± 0.59	97.79 ± 0.34	
AA	25.26 ± 1.27	80.29 ± 2.02	62.00 ± 1.57	82.40 ± 2.51	64.59 ± 4.02	91.19 ± 1.51	80.85 ± 2.39	94.00 ± 1.13	
Kappa 系数	49.24 ± 0.75	85.72 ± 1.04	77.44 ± 0.57	89.32 ± 0.73	80.43 ± 1.45	96.54 ± 0.40	94.42 ± 0.69	97.42 ± 0.39	




图 7 不同训练样本的分类结果

Fig. 7 Classification of different training samples

表 7 3 个数据集下不同模块消融实验结果

Tab. 7 Ablation experiments of different modules in three data sets

数据集	算法			%
	CGNN	CCNN + MCNN	HAMGCN	
IP	64. 74	94. 25	95. 89	
BS	72. 46	90. 38	91. 78	
WHC	86. 83	96. 24	97. 60	

提升。在 BS 数据集上,CCNN 与 MCNN 子模块下分类效果与 IP 数据集下分类效果类似。这表明尽管不同数据集有不一样的数据特征,但相对于卷积网络,该模型在适当的学习样本下仍可以获得较为良好的分类结果。同样,在丰富度最好的 WHC 数据集上,CCNN 与 MCNN 相较于 CGNN,对 HSI 数据的识别能力仍然有较大差异。这也证明了本研究设计的卷积网络子模块比单一图卷积模型对 HSI 数据识别更有效。当学习数据样本不足时,HSI 三维数据特征在光谱维度的特征进一步减少,卷积网络对三维空间光谱信息感知能力进一步下降,使得卷积网

络模型识别能力受限。3 个数据集上的消融实验表明,本研究所提方法 (HAMGCN) 在有限的学习样本条件下,利用卷积网络与图卷积网络在空间与光谱维度上能实现优势互补。同时引入多注意力机制模块灵活分类权值系数,进一步提升了模型分类性能。

2. 4 算法效率实验

为了比较算法之间的运行效率,在 3 个数据集下统计了每种算法的运行时间,实验设置与对比实验相同。具体实验结果如表 8 所示,从表 8 中可以看出,经典 SVM 方法在 IP 数据集下时间开销最小,而基于三维与二维卷积的 HybridSN 算法时间消耗最高。基于图神经网络的方法在丰富度最高的 WHC 数据下有着明显的速度优势。这是因为在数据量丰富的情况下,基于超像素的特征提取方式收敛更加快速。而本文方法虽然在 3 个数据集下的计算时间消耗并不占优势,但是结合对比方法的模型泛化性来看,HAMGCN 算法的综合性能最好。

表 8 3 个数据集下不同算法的运行时间

Tab. 8 Running time of different algorithms in three data sets

数据集	算法							
	SVM	HybridSN	HuEtAl	GCN	GAT	CEGCN	WFCG	HAMGCN
IP	3. 21	62. 50	32. 97	3. 87	4. 21	3. 29	5. 04	5. 03
BS	5. 41	22. 71	11. 07	36. 43	37. 96	36. 27	64. 69	52. 37
WHC	52. 12	914. 27	799. 27	45. 37	47. 01	41. 55	120. 16	58. 17

3 结论

(1)提出了一种高光谱图像分类的 HAMGCN 算法。该算法所设计的 CCNN 对原始 HSI 进行频谱通道压缩,多注意力机制卷积神经网络根据不同的光谱波段分配权值系数,以及编译图神经网络根据不规则的HSI 地物块灵活卷积来提取超像

素空间特征。
(2)设计的新型编译图神经网络在图编码器与图解器相互协同的作用下能有效捕捉高维度 HSI 中光谱与空间语义信息,多注意力机制模块的灵活分配权值也一定程度上提高了模型空间感知能力,同时在算法效率方面,HAMGCN 算法也很好地平衡了耗时与分类精度的关系。

参考文献

- [1] 赵茂程,吴泽本,汪希伟,等. 基于光谱成像的猪肉新鲜度空间分布预测评价方法[J]. 农业机械学报, 2022, 53(3): 412–422.
ZHAO Maocheng, WU Zeben, WANG Xiwei, et al. Evaluation of spectral imaging-based spatial predictions of freshness spatial distribution over pork[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 412–422. (in Chinese)
- [2] 鲁向晖,王倩,张海娜,等. 基于无人机多光谱遥感的芳樟矮林 SPAD 反演[J]. 农业机械学报, 2023, 54(5): 201–209.
LU Xianghui, WANG Qian, ZHANG Haina, et al. Inversion of SPAD of *Cinnamomum camphora* dwarf forest based on UAV multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 201–209. (in Chinese)
- [3] 袁翠霞,任艳敏,韩志强,等. 高分辨率遥感影像的田间道路识别方法[J]. 测绘通报, 2023(1): 145–148.
YUAN Cuixia, REN Yanmin, HAN Zhiqiang, et al. Field road recognition method based on high-resolution remote sensing images[J]. Bulletin of Surveying and Mapping, 2023(1): 145–148. (in Chinese)
- [4] 冯权泷,牛博文,朱德海,等. 土地利用/覆被深度学习遥感分类研究综述[J]. 农业机械学报, 2022, 53(3): 1–17.
FENG Quanlong, NIU Bowen, ZHU Dehai, et al. Review for deep learning in land use and land cover remote sensing classification[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 1–17. (in Chinese)
- [5] 朱俊清,赵学儒,马涛,等. 基于卫星遥感的陆域地质灾害监测方法[J]. 吉林大学学报(工学版), 2023, 53(6): 1861–1872.
ZHU Junqing, ZHAO Xueru, MA Tao, et al. Monitoring road geological disaster based on satellite remote sensing[J]. Journal of Jilin University(Engineering and Technology Edition), 2023, 53(6): 1861–1872. (in Chinese)
- [6] WANG Xiaolei, HE Xiufeng, SHI Jian, et al. Estimating sea level, wind direction, significant wave height, and wave peak period using a geodetic GNSS receiver[J]. Remote Sensing of Environment: an Interdisciplinary Journal, 2022, 279(6): 113–135.
- [7] LI Yanmeng, SUN Huaijiang, YAN Wenzhu, et al. R-CTSVM+: robust capped L1-norm twin support vector machine with privileged information[J]. Information Sciences, 2021, 574(9): 12–32.
- [8] 杨洋,李轶鲲,杨树文,等. 基于空间模糊 C 均值聚类 and 贝叶斯网络的高分一号遥感影像变化检测[J]. 测绘与空间地理信息, 2023, 46(4): 34–37, 42.
YANG Yang, LI Yikun, YANG Shuwen, et al. Change detection of GF-1 remote sensing image based on spatial fuzzy C-means clustering and bayesian network[J]. Geomatics & Spatial Information Technology, 2023, 46(4): 34–37, 42. (in Chinese)
- [9] 王爱丽,刘美红,薛冬,等. 结合动态卷积和三重注意力机制的高光谱图像分类[J]. 激光与光电子学进展, 2022, 59(10): 1015011.
WANG Aili, LIU Meihong, XUE Dong, et al. Hyperspectral image classification combined dynamic convolution with triplet attention mechanism[J]. Laser & Optoelectronics Progress, 2022, 59(10): 1015011. (in Chinese)
- [10] 陈文豪,何敬,刘刚. 引入注意力机制的卷积神经网络高光谱图像分类[J]. 激光与光电子学进展, 2022, 59(18): 1811001.
CHEN Wenhao, HE Jing, LIU Gang. Hyperspectral image classification based on convolution neural network with attention mechanism[J]. Laser & Optoelectronics Progress, 2022, 59(18): 1811001. (in Chinese)
- [11] ROY S, KRISHNA G, DUBEY S, et al. HybridSN: exploring 3D–2D CNN feature hierarchy for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(2): 277–281.
- [12] WANG Jinwei, SONG Xiangbo, SUN Le, et al. A novel cubic convolutional neural network for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13(7): 4133–4148.
- [13] 廖建尚,王立国. 两类空间信息融合的高光谱图像分类方法[J]. 激光与光电子学进展, 2017, 54(8): 81001–81002.
LIAO Jianshang, WANG Ligu. Hyperspectral image classification based on fusion with two kinds of spatial information[J]. Laser & Optoelectronics Progress, 2017, 54(8): 81001–81002. (in Chinese)
- [14] 徐沁,梁玉莲,王冬越,等. 基于 SE-Res2Net 与多尺度空谱融合注意力机制的高光谱图像分类[J]. 计算机辅助设计与图形学学报, 2021, 33(11): 1726–1734.
XU Qin, LIANG Yulian, WANG Dongyue, et al. Hyperspectral image classification based on SE-Res2Net and multi-scale spatial spectral fusion attention mechanism[J]. Journal of Computer-Aided Design & Computer Graphics, 2021, 33(11): 1726–1734. (in Chinese)
- [15] 唐婷,潘新,罗小玲,等. 融合 ConvLSTM 和多注意力机制网络的高光谱图像分类[J]. 光谱学与光谱分析, 2023, 43(8): 2608–2616.
TANG Ting, PAN Xin, LUO Xiaoling, et al. Fusion of ConvLSTM and multi-attention mechanism network for hyperspectral image classification[J]. Spectroscopy and Spectral Analysis, 2023, 43(8): 2608–2616. (in Chinese)
- [16] 杨国亮,龚家仁,刁浩,等. 基于快速双分支密集连接网络和双注意力机制的高光谱图像分类[J]. 激光与光电子学进展, 2022, 59(8): 12.
YANG Guoliang, GONG Jiaren, XI Hao, et al. Hyperspectral image classification based on fast double branch dense connection network and double attention mechanism[J]. Laser & Optoelectronics Progress, 2022, 59(8): 12. (in Chinese)
- [17] 陈宏达,普哈晔,王斌,等. 基于图像欧氏距离的高光谱图像流形降维算法[J]. 红外与毫米波学报, 2013, 32(5): 450–455.
CHEN Hongda, PU Hanye, WANG Bin, et al. Image Euclidean distance-based manifold dimensionality reduction algorithm for hyperspectral imagery[J]. J. Infrared Millim. Waves, 2013, 32(5): 450–455. (in Chinese)
- [18] 孙艳丽,张霞,帅通,等. 光谱角—欧氏距离的高光谱图像辐射归一化[J]. 遥感学报, 2015, 19(4): 618–626.
SUN Yanli, ZHANG Xia, SHUAI Tong, et al. Radiometric normalization of hyperspectral satellite images with spectral angle distance and Euclidean distance[J]. Journal of Remote Sensing, 2015, 19(4): 618–626. (in Chinese)
- [19] DONG Yanni, LIU Quanwei, DU Bo, 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.