

基于图扩散卷积的高光谱图像分类算法研究

魏智豪¹

WEI Zhihao

摘要

传统的高光谱图像(HSI)分类方法在处理高维数据时往往面临效率低下的问题。尽管卷积神经网络(CNN)和图卷积网络(GCN)在高光谱分类任务中取得了较好的效果,但在同时建模局部与全局特征方面仍存在局限。为解决这一挑战,文章提出一种融合CNN与图扩散卷积(GDC)的混合模型。具体而言,首先通过谱域变换模块对输入数据进行非线性降维,随后构建两个并行分支:像素级CNN分支用于提取局部空间—光谱特征,基于超像素的GDC分支通过图扩散捕获全局结构信息。最终将两类特征融合后输入分类器以获得预测结果。在Indian Pines、Pavia University和Salinas三个基准数据集上的实验表明,所提方法在分类精度上优于当前多种先进技术。

关键词

图扩散卷积; 卷积神经网络; 高光谱图像分类; 卷积神经网络

doi: 10.3969/j.issn.1672-9528.2026.02.007

0 引言

高光谱图像能够提供比传统彩色图像更丰富的光谱信息,每个像素不仅仅包含空间上的信息,还包括多维光谱数据,这使得高光谱图像在地球观测、农业监测和环境保护等领域中展现出了巨大的潜力^[1]。高光谱图像分类在遥感图像分析中占据了重要地位,它通过分析每个像素的光谱特征,能够有效地识别不同的物质或地物类型。应用领域包括土地覆盖分类、作物监测、矿产勘探等。

在过去十年,基于模型驱动的高光谱图像分类方法得到了成熟的发展。K-邻近分类算法^[2]凭借其理论和操作的简易性被广泛用于高光谱图像分类。但是K-邻近算法在处理高维数据时表现差强人意,而基于支持向量机(SVMs)^[3]的方法通过引入核函数(Kernel function)将数据从原始空间映射到高维特征空间,这类方法在处理高维数据时能够得到令人满意的结果。此外,最大似然分类(MLC)^[4]、逻辑(logistic)回归^[5]等方法通过对数据的统计特征进行建模并分类,在数据标注稀缺的情况下具有一定优势。然而,随着高光谱数据维度的增加,传统方法在高维数据处理上面临着过拟合和计算效率低下的问题。

与模型驱动的分类方法不同,数据驱动的理论从大量数据中自动学习规律,从而构建、优化模型,最后做出预测。卷积神经网络(CNN)^[6]凭借其强大的特征提取能力和对空间结构的刻画能力,已被广泛应用于HSI分类任务中。有效

缓解了由高维数据带来的过拟合和计算效率低下等问题。二维卷积神经网络(2D-CNN)只在空间维度上进行卷积,无法捕获光谱间的相关性,从而影响分类精度。三维卷积神经网络(3D-CNN)能够同时学习光谱-空间特征,但其计算开销大且结构复杂。HybridSN^[7]通过采用浅层3D-CNN和轻量级2D-CNN,将2D-CNN与3D-CNN的优点结合起来,以降低计算成本并提升整体分类精度。此外,一些将卷积神经网络与模型驱动理论相结合的混合模型^[8-10]也表现出良好的性能。

随着图信号理论的发展,图卷积网络(GCNs)已被广泛用于图数据分析,尤其是在图像分类任务中。对于高光谱图像,各像素不仅在光谱上具有相似性,还存在局部空间相关性。GCN通过图结构来建模数据点之间的关系,从而能够有效刻画像素间的空间依赖性,使其在HSI分类中展现出良好的应用前景。基于GCN的分类方法,如mini-GCN^[11]和contrastive GCN^[12],已经在HSI分类任务中取得了令人满意的结果。更为先进的方法,例如CEGCN^[13]和NCGLF²^[14],融合了多种深度学习技术,兼顾局部与非局部特征,同样获得了较好的分类性能。尽管基于GCN的方法具有一定优势,但它们在刻画HSI中远距离依赖关系方面仍然存在不足。

为了解决这些挑战,本文提出了一种基于图扩散卷积的高光谱图像分类方法。该方法将图扩散卷积网络(GDCN)与CNN相结合以完成最终分类。本文的主要贡献概括如下:

一是在标准的GCN上引入了扩散过程,使得网络能够更加精准地建模邻域之间的关系。并且对生成的扩散矩阵进

1. 西安石油大学理学院 陕西西安 710065

行稀疏化处理，降低了计算复杂度；

二是将 CNN 与 GDCN 联合起来进行特征融合，分别提取了高光谱图像的局部特征和全局特征，提高分类精度和鲁棒性；

三是在多个数据集上开展实验，并与已有方法进行比较，验证了所提算法的优越性。

1 方法

1.1 网络的结构

每个高光谱数据集可以表示为 $X \in \mathbb{R}^{H \times W \times B}$ ，其中 H 、 W 和 B 分别表示图像的高度、宽度以及光谱波段数。HSI 分类的目标是利用由有限标注样本训练得到的分类器，为图像中的每个像素分配类别标签。本研究提出了一种 HSI 分类模型，如图 1 所示。该模型采用多分支融合策略，以联合表征 HSI 的光谱信息与空间结构信息。整体网络结构主要包括三个模块：光谱变换模块、CNN 模块、超像素级 GDCN 模块。




图 1 所提方法的架构

原始 HSI 首先输入到由多个 1×1 卷积层构成的光谱变换模块。该模块对每个像素的光谱向量进行非线性降维处理，从而获得具有更强判别力的光谱特征表示，为后续的空间-光谱卷积和图结构的构建打下基础。降维后的图像分别输入到两个并行的特征提取分支中。像素级卷积分支使用多个空间-光谱卷积模块，从局部窗口中提取像素级的空间上下文信息，增强局部结构的感知能力。超像素级图扩散卷积分支借助 LDA-SLIC 算法对图像进行超像素分割，构建超像素图结构，并通过多层图卷积网络（GCN）在超像素图中传播低频全局结构特征，再映射回像素层面。上述两个分支输出的特征在像素层级拼接后，输入至全连接层与 Softmax 分类器，输出最终的类别概率图。网络整体实现了局部细粒度特征与超像素级结构信息的有效互补融合。

1.2 CNN 层

高光谱图像（HSI）同时包含丰富的光谱信息和有限的空间信息，直接使用传统的卷积处理难以捕捉局部空间相关性。该模块通过空间-光谱联合卷积在增强光谱的特征表达能力的情况下提取了各通道的空间特征，这就同时利用了光谱相关性和局部空间结构。具体而言，输入的高光谱图像通

过第一个空间光谱卷积层，该卷积层由一个用于提取光谱特征的 1-D 卷积核以及一个用于提取光谱特征的 2-D 卷积核构成。对于该模块中由第 L 层 1-D 卷积核提取的光谱特征所输出的特征图 G^l ，用公式表示为：

$$G^l = K_j^l \cdot \hat{H}^{l-1} \quad (1)$$

式中： K_j^l 表示第 L 层第 j 个特征图的 1-D 卷积核； $\hat{H}^{l-1}$ 表示输入数据经批归一化（batchnorm, BN）处理。将光谱卷积的结果与空间卷积核 B_j^l 在空间卷积的采样网格 R 上逐位置加权求和，通过激活函数得到：

$$H_j^l = \text{LeakyReLU}(\sum B_j^l \cdot G^l + b_j^l) \quad (2)$$

式中： b_j^l 是偏置项。此设计极大减少了参数数量，大幅提升了计算效率。

1.3 GDCN 层

为快速构建包含空间-光谱信息的图结构，使用主成分分析对输入的高光谱图像数据进行降维处理，减少冗余光谱。随后使用简单线性迭代聚类方法将降维后的 HIS 图像划分为多个空间相连且光谱相似的超像素，初步揭示了高光谱图像的空间结构。并对生成的超像素图像建立图模型，建立超像素块之间的邻接关系，将 HSI 图像转换为无向图 $G=(V, \epsilon)$ ，其中 V 、 ϵ 分别表示图结构的节点集和边集。将原始图转换为新图，然后在新图上运行模型。

传统图卷积（如 GCN）仅通过消息传递聚合直接邻居的信息，无法建模长距离依赖。图扩散卷积（GDC）^[15] 是一种通过广义图扩散增强图结构数据特征的传播方法，其核心目标是扩展传统图卷积的感受野，使其不仅关注直接邻居（一阶邻域），还能捕获多跳邻居（高阶邻域）的全局关系。如图 2 所示，首先把所有的注意力放在考虑的节点上。然后，将一些注意力传递给节点的邻居，并从开始节点上分散开。一段时间后停止，在其点上的注意力分布定义了从开始节点到其他节点的边。




图 2 扩散过程的示意图，采用图扩散和稀疏化技术

通过对每个节点的操作，得到一个矩阵，呈现一个新的连续加权图。准确来说，定义图扩散用公式表示为：

$$S = \sum_{k=0}^{\infty} \theta_k T^k \quad (3)$$

式中： θ_k 为第 k 阶扩散项路径传播权重； T 为对称归一化的拉普拉斯矩阵，定义为 $T = I - \hat{A}$ ，其中 I 为单位矩阵， $\hat{A}$ 用公式表示为：

$$\hat{A} = D^{-\frac{1}{2}} A D^{-\frac{1}{2}} \quad (4)$$

式中： A 是邻接矩阵； D 是度矩阵（degree matrix）对角线元素，表示为 $d_{ii} = \sum_{j=1}^N a_{ij}$ ，此外，不同的扩散方式对应不同的 T 和 θ_k 。

本文使用热核（Heat kernel）扩散，热核图扩散定义为：

$$S = \sum_{k=0}^{\infty} \frac{(-t)^k}{k!} L^k = \sum_{k=0}^{\infty} \frac{(-t)^k}{k!} (I - \hat{A})^k \quad (5)$$

后对生成的扩散图进行图卷积，其传播公式为：

$$H^{(l+1)} = \sigma \left(\left(\sum_{k=0}^{\infty} \frac{(-t)^k}{k!} (I - \hat{A})^k \right) H^{(l)} W^{(l)} \right) \quad (6)$$

式中： $H^{(l)}$ 和 $H^{(l+1)}$ 表示第 l 层和第 $l+1$ 层的特征矩阵； $W^{(l)}$ 表示可训练的权重矩阵； $\sigma(\cdot)$ 表示激活函数。该模块用于在图上建模土地覆盖的大尺度空间结构，并生成超像素级别的特征。在训练过程中，对所有有标注像素采用交叉熵损失函数，其形式用公式表示为：

$$\mathcal{L} = - \sum_{i=1}^N \sum_{c=1}^C L_c(P_i) \log(Y_c(P_i)) \quad (7)$$

式中： $L_c(P_i)$ 表示真实标签 $L(P_i)$ 的第 c 个元素； $Y_c(P_i)$ 表示模型预测的像素 $X(P_i)$ 属于类别 c 的概率。

2 实验

2.1 实验设置


在 3 个基准高光谱图像（HSI）数据集上对所提出的 GDCN 进行评估，分别是 Indian Pines (IP)、Pavia University (PU) 和 Salinas(SA)。上述数据集涵盖了具有不同空间分辨率和光谱维度的多种农业、城市与湿地场景。所有高光谱数据立方均归一化到 [0,1] 区间，并采用主成分分析（PCA）保留前 30 个主成分。在每个有标签像素周围提取大小为 15×15 的空谱块。对于 PU 和 SA 数据集，从有标签样本中随机选取 1% 用于训练；为缓解类别不均衡问题，IP 数据集的训练比例设为 5%，其余样本全部用于测试。基于超像素的图结构通过 SLIC 算法构建，其中每个节点表示一个超像素的平均光谱 - 空间特征，边权由特征相似度确定。模型在一块显存为 16 GB 的 NVIDIA GPU 上训练，采用 Adam 优化器（学习率 0.001，训练 200 个 epoch，batch size 为 64）。为确保结果的统计可靠性，本研究采用三折交叉验证，并报告平均总体精度（OA）、平均精度（AA）以及 Kappa 系数来评估分类性能。

为得到最佳的实验结果，本研究也在 CNN 分支和 GDCN 分支进行了实验。CNN 分支和 GCN 分支的最终输出通道均为 64。表 1 为不同的 CNN 和 GCN 层数得到的 OA 值。在 3 个数据集的比率均设置为 0.005。实验结果显示，CNN 层数为 2、GCN 层数为 2 时，在 3 个数据集集中的 OA 值最优。

表 1 CNN 层数与 GDCN 层数对高光谱图像分类结果 OA 值的影响

Conv-Layers		IP	PU	SA
CNN-Layers	1	76.62	97.31	95.46
	2	79.30	99.08	98.44
	3	70.21	99.05	98.24
	4	61.23	98.66	97.79
GDCN-Layers	1	61.28	69.87	86.99
	2	67.37	77.09	90.02
	3	53.75	73.42	87.36
	4	48.41	72.91	86.01

除对数据进行预处理，在模型训练中设置了其他参数。在训练过程中，学习率和训练次数分别设置为 0.000 1 和 500。对于 IP 数据集，将每个类别的 1%、1%、98% 分别作为训练的训练集、验证集和测试集。对于 PU 和 SA 数据集，将每个类别的 0.1%、0.1%、99.8% 分别作为训练的训练集、验证集和测试集。为验证所提方法的有效性，选择了 7 种方法进行比较，包括 2D-CNN^[16]，SSRN^[17]，Hybrid-SN^[7]，CEGCN^[13]，SSFTT^[18]，CVSSN^[19]，NSR-Net^[20]。为对不同方法的性能进行定量评估，本实验采用总体精度（OA）、平均精度（AA）、Kappa 系数来定量评价不同方法的性能。



(a) False color image (b) Ground truth (c) 2D-CNN (d) SSRN (e)

Hybrid-SN (f) CEGCN (g) SSFTT (h) CVSSN (i) NSR-Net (j) GDCN

图 3 IP 数据集的可视化分类结果

2.2 结果与分析

表 2 展示了不同方法在 3 个公开数据集上的结果，由于篇幅限制，这里仅对 IP 结果进行分析，其可视化分类图也相应地展示在图 3 中。从表 2 的结果中看出，本研究所提出的方法表现优于其他同类方法。具体来说，与 CEGCN 相比，本文所提出的方法在 3 个指标上分别提高了 6.69%、17.76%、7.78%。证明了图扩散卷积确实有利于 HSI 分类。同样的，从图 3 看出，SSFT 比本文所提方法的预测误差面积最小，这也意味着图扩散卷积的结构可以捕捉到更深层次的特征。此外所提方法在 3 个指标上比 SSRN 分别提高了 8.81%、4.85%、8.77%，表明图扩散卷积对于特征提取非常具有价值。表 2 可以看出，CEGCN 在 OA 方面的性能优于

表 2 不同方法在 3 个数据集上的分类结果

Method		2D-CNN	SSRN	Hybrid-SN	CEGCN	SSFTT	CVSSN	NSR-Net	GDCN
IP	OA	60.42	73.52	66.23	75.64	81.61	69.46	74.30	82.33
	AA	57.51	76.99	64.37	64.08	67.29	61.65	78.58	81.84
	Kappa	54.07	70.89	63.22	71.88	78.90	65.40	70.79	79.66
PU	OA	73.54	75.73	71.42	90.45	74.53	74.62	85.26	92.55
	AA	70.53	73.63	59.20	83.78	50.56	75.83	78.66	91.44
	Kappa	64.55	69.64	62.06	87.43	64.71	71.47	80.23	92.07
SA	OA	80.92	82.81	87.99	93.15	86.57	90.56	92.16	99.45
	AA	78.67	89.88	88.58	95.00	86.44	88.87	92.89	99.49
	Kappa	78.68	80.61	86.69	92.34	85.00	87.48	91.25	99.39

2D-CNN，并且所提算法优于 Hybrid-SN，这些结果验证了全局信息对于 HIS 分类是合理的。因此，所提出的算法通过使用 CNN 和 GDC 分别提取局部和全局的空间光谱特征对于高光谱图像分类问题具有一定的价值。

此外，图 4 显示了不同方法在 IP 数据集上不同训练集比例的准确率。显然，无论训练比例高或低，所提算法都可以取得更好的效果。特别是当训练集比率为 0.01 时，所提算法在 OA、AA、Kappa 方面均表现出良好的分类性能，反映了所提方法可以在较少训练样本的情况下得到更好的分类结果。




图 4 Indina Pines 数据集不同训练集比率下不同方法的分类结果

3 消融实验

在进行消融实验后，可以更好地找到所提算法背后原因，如表 3 中第一行和第二行分别为 CNN 和 GCN 独立进行分类任务后的结果，与第二行相比，第三行 OA、AA、Kappa 值分别提升了 16.43%、12.42%、20.19%，证明将扩散模块应用于图卷积网络有助于图卷积网络捕获更多的鉴别信息。从第四行中 OA、AA、Kappa 值相较于第一行分别提升了 2.91%、1.77%、3.61%，相较于第二行分别提升了 24.87%、41.24%、30.12%，证明了将 CNN 分支与 GCN 分支结合对分类结果是有提升的。第五行中的 OA、AA、Kappa 值相较于第四行分别提升了 5.77%、4.58%、6.88%，证明了扩散模块在混合网络中的价值。综上所述，本文所采用的局部与全局相结合的特征提取结构以及扩散模块是合理有效的。

表 3 消融研究 IP 数据集上不同成分组合的 OA、AA 和 Kappa

CNN model	GCN model	Diffusion model	OA	AA	Kappa
√	×	×	73.29	74.38	68.80
×	√	×	51.33	34.91	42.29
×	√	√	67.76	47.33	62.48
√	√	×	76.20	76.15	72.41
√	√	√	81.97	80.73	79.29

4 结论

本实验提出了一种名为新型网络用于 HIS 分类，该网络由像素级的卷积神经网络和超像素级的图卷积网络组成。首先将整幅图像分割成许多空间相连的超像素，以揭示 HIS 的强空间—光谱结构。通过将每个超像素视为图节点，并建立超像素之间的邻接关系，引入扩散过程来提取更多的非局部特征，构建了一个无向图来建模 HSI 不同区域之间的关系，并进一步将其输入一种新的端到端的网络架构，将卷积神经网络和图扩散卷积分别得到的像素级和超像素级的特征进行融合。在图扩散卷积中，扩散模块重构了整个图结构，获得了更丰富的特征信息，这在高光谱图像分类任务中显示了其相对于传统 GCN 的优点。实验结果表明，与多种竞争方法相比，本文方法取得了更优的分类性能。未来工作将致力于设计更为轻量化的模型，以进一步提升其在 HSI 分类中的应用灵活性。

参考文献：

[1]LI L, BAO S, JING M L,et al.Hyperspectral image denoising using superpixel segmentation and graph laplacian regularization[J/OL].IEEE geoscience and remote sensing letters,2024[2025-12-25].<https://ieeexplore.ieee.org/abstract/document/10606536>.DOI:10.1109/LGRS.2024.3432669.

[2]GE H M, PAN H Z, WANG L G ,et al.Self-training algorithm for hyperspectral imagery classification based

- on mixed measurement k-nearest neighbor and support vector machine[J]. Journal of applied remote sensing, 2021,15(4):042604.
- [3] OKWUASHI O, NDEHEDEHE C E. Deep support vector machine for hyperspectral image classification[J]. Pattern recognition, 2020,103:107298.
- [4] PENG J T, LI L Q, TANG Y Y. Maximum likelihood estimation-based joint sparse representation for the classification of hyperspectral remote sensing images[J]. IEEE transactions on neural networks and learning systems, 2018, 30(6): 1790-1802.
- [5] KHODADADZADEH M, GHAMISI P, CONTRERAS C, et al. Subspace multinomial logistic regression ensemble for classification of hyperspectral images[C]//IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE, 2018: 5740-5743.
- [6] YU S Q, JIA S, XU C Y. Convolutional neural networks for hyperspectral image classification[J]. Neurocomputing, 2017, 29: 88-98.
- [7] ROY S K, KRISHNA G, DUBEY S R, et al. HybridSN: exploring 3D-2D CNN feature hierarchy for hyperspectral image classification[J]. IEEE geoscience and remote sensing letters, 2019,17(2):277-281.
- [8] CAO X Y, XU L, MENG D Y, et al. Integration of 3-dimensional discrete wavelet transform and markov random field for hyperspectral image classification[J]. Neurocomputing, 2017, 226: 90-100.
- [9] CAO X Y, ZHOU F, XU L, et al. Hyperspectral image classification with markov random fields and a convolutional neural network[J]. IEEE transactions on image processing, 2018, 27(5): 2354-2367.
- [10] CAO X Y, YAO J, XU Z B, et al. Hyperspectral image classification with convolutional neural network and active learning[J]. IEEE transactions on geoscience and remote sensing, 2020,58(7):4604-4616.
- [11] HONG D F, GAO L R, YAO J, et al. Graph convolutional networks for hyperspectral image classification[J]. IEEE transactions on geoscience and remote sensing, 2020, 58(7): 5966-5978.
- [12] YU W T, WAN S, LI G Y, et al. Hyperspectral image classification with contrastive graph convolutional network[J]. IEEE transactions on geoscience and remote sensing, 2023, 61: 1-15.
- [13] 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, 2020, 59(10): 8657-8671.
- [14] TU B, REN Q, LI J, et al. NCGLF²: network combining global and local features for fusion of multisource remote sensing data[J]. Information fusion, 2024,104: 102192.
- [15] GASTEIGER J, WEIßENBERGER S, GÜNNEMANN S, et al. Diffusion improves graph learning[C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. Brussels: ACL, 2019: 13366 - 13378.
- [16] YANG X F, YE Y M, LI X T, et al. Hyperspectral image classification with deep learning models[J]. IEEE transactions on geoscience and remote sensing, 2018,56(9):5408-5423.
- [17] ZHONG Z L, LI J, LUO Z M, et al. Spectral-spatial residual network for hyperspectral image classification: a 3D deep learning framework[J]. IEEE transactions on geoscience and remote sensing, 2017,56(2):847-858.
- [18] SUN L, ZHAO G R, ZHENG Y H, et al. Spectral-spatial feature tokenization transformer for hyperspectral image classification[J/OL]. IEEE transactions on geoscience and remote sensing, 2022[2025-12-31]. <https://ieeexplore.ieee.org/document/9684381>. DOI: 10.1109/TGRS.2022.3144158.
- [19] LI M S, LIU Y K, XUE G K, et al. Exploring the relationship between center and neighborhoods: central vector oriented self-similarity network for hyperspectral image classification[J]. IEEE transactions on circuits and systems for video technology, 2023,33(4):1979-1993.
- [20] NIE X Y, XUE Z H, SU H J, et al. NSR-Net: representation model-inspired interpretable deep unfolding network for hyperspectral image classification[J/OL]. IEEE transactions on geoscience and remote sensing, 2025[2025-12-30]. <https://ieeexplore.ieee.org/document/10810502>. DOI: 10.1109/TGRS.2024.3520639.

【作者简介】

魏智豪（2000—），男，陕西西安人，硕士研究生，研究方向：信号、图像处理。

（收稿日期：2025-12-09 修回日期：2026-02-09）