

# 基于图神经网络的高光谱图像分类研究进展

万升,杨健,宫辰

(南京理工大学计算机科学与工程学院,江苏南京 210014)

**摘要:** 高光谱成像是遥感领域的一项先进技术,它能够收集和来自不同波段的电磁光谱信息,包括可见光、近红外和红外波段。由于高光谱成像技术能够检测到光谱信息的细微变化,因此,其在区分不同类型的地物方面取得了不错的成果。近年来,高光谱图像分类在城市规划和植被监测等应用中引起了许多研究者的关注,其主要目的是将图像中的每个像素分类到一个有意义的类别中。然而,高光谱图像数据量大、特征维数高的问题给像素的精确分类带来了一定挑战。如何有效提取高光谱图像的空谱特征已成为高光谱图像分类中最重要的问题之一。在过去的几年里,深度学习技术依靠强大的特征提取能力,在高光谱图像分类中具有不错的表现。其中,基于图神经网络(Graph Neural Network, GNN)的方法凭借其处理不规则数据的出色能力,为高光谱图像分类提供了新的研究方向。

图神经网络是一种能够直接处理图结构数据的深度学习模型。在图神经网络模型中,每个图节点表示一个样本,每条边表示一对样本之间的关系。图卷积操作通过在图节点之间传播信息,来学习图节点的表征,从而模型能够捕捉到图节点之间的复杂关系,并实施诸如节点分类和链接预测的任务。通过将高光谱图像转换为图结构,图神经网络能够在卷积过程中提取图像的空谱特征。其中,每个节点对应于一个像素或区域,像素或区域之间的关系被表示为边。本文从图神经网络的构图方式、图卷积类型、模型架构和优化策略4个角度,梳理了当前基于图神经网络的高光谱图像分类方法的研究内容和进展,并为该领域的技术研究提供了多层次的对比分析。

在基于图神经网络的高光谱图像分类方法中,图结构的构建是一项非常重要的任务。目前,主要存在两种基于高光谱数据的建图方法,即基于像素和基于区域的方法。在基于像素的建图方法中,每个像素都被视为一个图节点,这也是构建图结构最直接的方法。其中,每对图节点之间的权重可以由网络预先计算或学习。考虑到基于像素的建图方法复杂度较高,研究者开发了基于区域的建图方法。此类方法将图像的区域作为图节点,目前已被广泛应用于高光谱图像分类方法中。基于区域的建图方法可以有效减小图结构的尺寸,从而实现高效的图卷积运算。

此外,图卷积类型的选择也是基于图神经网络的高光谱图像分类中的一个重要问题。当前的图卷积操作主要包含两种类型,即基于谱域的图卷积和基于空间域的图卷积。基于谱域的图卷积从图信号处理的角度引入了滤波器,通常具备较为坚实的数学基础,并且在高光谱图像分类中得到了较为广泛的使用。与基于谱域的方法不同,基于空间域的图卷积利用加权平均函数直接对每个图节点的邻居进行卷积。因此,基于空间域的图卷积通常表现出更强的灵活性和泛化能力。

同时,模型架构的选择在基于图神经网络的高光谱图像分类中同样关键。目前主要存在两种类型的模型架构,即单一型和混合型。基于单一型架构的方法仅使用单一类型的深度模型(即图神经网络),早期的基于图神经网络的高光谱图像分类方法大多采用这一架构。然而,图神经网络模型本身存在一些固有的缺陷,这一定程度上限制了单一型架构方法在高光谱图像分类任务中的表现。为了缓解图神经网络模型的固有缺陷,进一步提高算法在高光谱图像分类任务中的性能,研究者开始探索将图神经网络与其他深度模型相融合的混合型模型架构,从而能够利用不同子模型来捕捉高光谱图像中多种类型的空谱特征。

模型优化策略的选择对于算法性能也有着显著的影响。目前主要存在两种模型优化策略,即全批量梯度下降和小批量梯度下降。全批量梯度下降法会遍历所有样本计算一次损失函数,然后根据各个参数对应的梯度来更新模型参数,这种优化策略通常用于基于谱域的图神经网络模型。然而,由于每一次的参数更新都会涉及所有样本,因此全批量梯度下降法的复杂度通常较高,尤其是像素或超像素数量较多时。为了提高训练效率,研究者提出使用小批量梯度下降进行模型优化。其中,损失可以根据每个子图计算得到。由于每个子图的规模比原始图结构小得多,因此小批量梯度下降策略通常具有很高的效率。

尽管图神经网络模型已经在高光谱图像分类任务中取得了一定成果,但现有方法仍存在一些有待改进的问题。例如自适应邻域构建,即邻域的大小和形状可以根据图像的不同区域变化。现有的基于图神经网络的方法通常假设邻域大小和形状是固定不变的,而这一假设对于图像的所有区域而言可能并非最优。此外,另一个问题是可伸缩性和准确性之间的权衡。图神经网络在获得可伸缩性的同时,无可避免地会对原始数据的完整性造成损伤。然而,保持数据的完整性对模型学习是至关重要的。因此,越来越多学者开始研究能够同时保证可扩展性和高分类精度的图神经网络。

络方法. 同时, 由于高光谱图像可能包含各种类型的噪声, 因此噪声的处理亦是一个值得关注的问题. 大部分现有的图神经网络方法对噪声不具有鲁棒性, 这更加凸显了开发噪声鲁棒图神经网络方法的必要性.

总的来讲, 由于基于图神经网络的方法能够有效提取高光谱图像中的空谱特征, 其在高光谱图像分类领域展现了巨大的潜能. 本文从不同角度回顾并总结了当前基于图神经网络的高光谱图像分类方法, 包括建图方式、图卷积类型、模型架构和优化策略. 同时, 还分析了高光谱图像分类所面临的挑战和图神经网络算法的特点, 并探讨了未来潜在的研究方向. 随着图神经网络方法的不断发展, 高光谱图像分类有望在各个领域取得更高的精度和更广泛的应用.

**关键词:** 高光谱图像分类; 图神经网络; 图机器学习; 半监督学习; 深度学习

**基金项目:** 国家自然科学基金(No.61973162); 江苏省自然科学基金(No.BZ2021013); 江苏省杰出青年基金(No.BK20220080); 中央高校基本科研业务费专项资金(No.30920032202, No.30921013114)

**中图分类号:** TP751      **文献标识码:** A      **文章编号:** 0372-2112(2023)06-1687-23

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20221295

## Advances of Hyperspectral Image Classification Based on Graph Neural Networks

WAN Sheng, YANG Jian, GONG Chen

(School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing, Jiangsu 210014, China)

**Abstract:** Hyperspectral imaging is an advanced imaging technique in the field of remote sensing that collects and processes information from a wide range of electromagnetic spectra, including visible, near-infrared, and infrared wavelengths. Owing to its capacity to detect subtle spectral information, hyperspectral imaging is highly effective at discriminating among different geographic objects. Therefore, hyperspectral image classification, which aims to categorize each image pixel into a certain meaningful class, has recently attracted increasing interest for real-world applications such as urban planning and vegetation monitoring. However, the very large amounts of data and high dimensionality of hyperspectral images make it challenging to classify the image pixels accurately. One of the most important issues in hyperspectral image classification is how to effectively extract the spectral—spatial features of the images. In recent years, deep learning techniques with strong feature extraction abilities have performed well in hyperspectral image classification. Among them, graph neural network (GNN)-based methods have become salient with their excellent ability to handle irregular data, providing a new research direction for hyperspectral image classification.

GNNs are a class of deep learning models that operate on graph-structured data. In GNN models, each node of the graph represents an example, and each edge represents a relationship between a pair of examples. The representations for each node can be learned by propagating information among nodes through graph convolution operations. This enables the model to capture the complex relationships between nodes and perform tasks such as node classification and link prediction. In hyperspectral image classification, GNNs can be used to learn spectral—spatial features by treating the image as a graph, where each pixel or region represents a node and the relationships between neighboring pixels or regions are represented as edges. This paper provides a multi-level comparative analysis of the research progress in GNN-based hyperspectral image classification from the perspectives of graph construction, graph convolution, model architecture, and optimization strategies.

Approaches to graph construction are an important aspect of GNN-based hyperspectral image classification. There are two main approaches to constructing a graph from a hyperspectral image, pixel-based and region-based. In pixel-based methods, each pixel is treated as a node, as this is the most straightforward way to construct a graph. The weight between each pair of nodes can be either precomputed or learned by the networks. Considering the high complexity of pixel-based methods, region-based methods have been developed, in which each region is considered a node and the size of the graph can be greatly reduced, resulting in efficient graph convolution operations. Region-based methods have recently been widely applied to hyperspectral image classification.

Additionally, the type of graph convolution is another important aspect of GNN-based hyperspectral image classification. There are two main types of graph convolution, spectral-based and spatial-based. In spectral-based methods, filters are introduced from the perspective of graph signal processing. Hence, this type of graph convolution typically has a solid

mathematical foundation and has been widely adopted in hyperspectral image classification. By contrast, in spatial-based methods, a weighted average function is utilized to perform convolution over the neighbors of each node. Compared with spectral-based models, spatial-based models typically exhibit better flexibility and generalization ability.

Furthermore, selection of model architecture is crucial in GNN-based hyperspectral image classification. There exist two main types of model architectures, monotypic and hybrid. In monotypic architecture, only a single type of deep model (i.e., graph neural network) is utilized, which was adopted by many early-stage GNN-based methods. However, performance is restricted by the inherent limitations of GNN models. To alleviate these limitations and further improve the performance of hyperspectral image classification tasks, researchers have begun exploring hybrid model architectures that combine GNN with other deep models. These hybrid models allow for the utilization of different sub-models to capture multiple types of spectral—spatial features contained in hyperspectral images.

Finally, the choice of optimization strategy also plays a critical role in the performance of GNN-based hyperspectral image classification. There are two main optimization strategies, full-batch gradient descent and mini-batch gradient descent. The full-batch gradient descent strategy, which is commonly used for spectral-based GNN models, involves computing the loss for all examples and updating model parameters based on the gradients corresponding to each parameter. However, since parameter updating involves all samples, the complexity of full-batch gradient descent can be very high, especially when dealing with a large number of pixels or superpixels. To improve training efficiency, mini-batch gradient descent can be used for model optimization. Here, the original graph structure is divided into subgraphs, and the loss of is computed for each subgraph. Since each subgraph is much smaller than the original graph, this strategy often exhibits greater efficiency.

Despite the promising results achieved by GNN-based hyperspectral image classification, some challenges remain that must be addressed. One of them is adaptive neighborhood construction, where the size and shape of the neighborhood may vary for different regions of the image. Existing GNN-based methods assume a fixed neighborhood size and shape, which may not be optimal for all regions of the image. Another challenge is the tradeoff between scalability and accuracy. GNN models inevitably compromise the integrity of the original data when achieving scalability, although preserving the integrity of the data is crucial for model learning. Therefore, there is a growing need to develop GNN-based methods that can achieve high accuracy while maintaining scalability. Noise processing is also a noteworthy issue, since hyperspectral images may contain various types of noise. Most existing GNN-based methods are not robust to noise, highlighting the need for development of noise-robust methods.

In summary, GNN-based methods have shown great potential for hyperspectral image classification by effectively extracting spectral—spatial features from hyperspectral images. In this paper, we have reviewed and summarized the existing methods from different perspectives, including graph construction, graph convolution, model architectures, and optimization strategies. We have also analyzed the challenges of hyperspectral image classification and the characteristics of GNN algorithms, providing insights into potential future research directions. With the continued development of GNN-based methods, hyperspectral image classification is expected to achieve higher accuracy and broader applicability in various fields.

**Key words:** hyperspectral image classification; graph neural network; graph machine learning; semi-supervised learning; deep learning

**Foundation Item(s):** National Natural Science Foundation of China (No.61973162); Natural Science Foundation of Jiangsu Province (No.BZ2021013); NSF for Distinguished Young Scholar of Jiangsu Province (No.BK20220080); Fundamental Research Funds for the Central Universities (No.30920032202, No.30921013114)

## 1 引言

高光谱成像是遥感领域中的一项重要技术。它能够收集从可见光到近红外波长范围内的电磁光谱。针对地表的同一区域,高光谱成像传感器通常可以采集到数百个狭窄的光谱条带,从而获取感兴趣目标的理化信息<sup>[1,2]</sup>。在高光谱图像中,每个像素可被看作一条高维向量,向量的每个元素对应于特定波长上的光谱反射率。由于高光谱图像有助于区分细微的光谱差异,其在众多领域都得到了广泛应用,例如环境科学、农

业、矿业等<sup>[3,4]</sup>。

高光谱图像分类是高光谱遥感对地观测技术中的一项重要内容,其目标是赋予图像像素唯一的地物类别标识<sup>[5]</sup>。然而,由于高光谱图像的高维特性、波段间的高相似性,以及混合像素的存在,高光谱图像分类始终面临着较大的挑战。具体来讲,在高光谱图像中,光谱波段范围广、数量多,且波段间的间距窄,直接处理图像中海量的光谱信息会耗费巨大的计算量。此外,图像中相邻波段间的高相关性可能会带来严重的信息冗余<sup>[6]</sup>。同时,高光谱图像中还存在异物同谱和同谱异物

的现象,这会导致高光谱数据呈高度非线性.一些基于统计学的模式识别方法难以直接处理这类数据,一定程度上增加了图像分类的难度<sup>[7]</sup>.不仅如此,由于高光谱图像的空间分辨率相对较低,图像中不可避免地存在部分混合像素(即一个像素中包含了多种地物类别特征),这同样给高光谱图像的准确分类带来了一定困扰<sup>[8-10]</sup>.最后,在有监督的高光谱图像分类中,由于像素标注工作费时费力,有标记的训练样本数量通常较少,这可能会影响分类器参数估计的准确性<sup>[11]</sup>.

在各国学者的努力下,近几十年来涌现出了多种类型的高光谱图像分类方法.其中,早期的方法主要在利用高光谱图像光谱信息的基础上,借助传统的模式识别技术进行像素分类.例如, $K$ -近邻分类器凭借其理论和操作的简易性被广泛用于高光谱图像分类<sup>[12,13]</sup>,而支持向量机理论在高光谱图像分类任务上同样取得了令人满意的效果<sup>[14-16]</sup>.此外,逻辑斯蒂回归<sup>[17,18]</sup>、基于稀疏表示的分类器<sup>[19,20]</sup>、最大似然分类器<sup>[21]</sup>等方法也被用于高光谱图像分类,并取得了不错的效果.然而,对于地物特征分布较为复杂的高光谱图像,仅使用光谱信息可能难以准确地辨别不同的地物类别<sup>[22]</sup>.研究发现,高光谱图像中空间位置相邻的像素通常会带有相关联的信息,因此许多研究者考虑将空间信息融入高光谱图像分类方法中.此类方法通常被称为基于空谱联合特征的高光谱图像分类方法<sup>[23-25]</sup>.例如,马尔可夫随机场模型常被用于提取高光谱图像中的空间信息,并已取得一定的成效<sup>[26]</sup>.除马尔可夫随机场外,研究者还提出了基于形态学的方法,从而对高光谱图像中的空间和光谱信息进行有效融合<sup>[27-29]</sup>.类似地,纹理特征描述子、Gabor滤波等技术<sup>[30,31]</sup>亦被用来提取高光谱图像中的空谱联合信息.

然而,上述方法大都需要手动提取空谱特征,因而特征的质量很大程度上依赖于专家经验.幸运的是,深度学习为高光谱图像特征提取提供了一种较为理想的解决方案<sup>[32]</sup>.具体来说,针对不同类型的高光谱数据,深度学习技术都可以通过逐步聚合低层特征来自动地获得抽象的高层表示,从而避免了繁杂的特征工程<sup>[33,34]</sup>.在早期的深度学习方法中,Chen等<sup>[35]</sup>首次通过建立堆叠式自动编码器来提取高光谱图像的高层特征.随后,Mou等<sup>[36]</sup>借助循环神经网络模型来解决高光谱图像分类问题.而在最近的数年中,卷积神经网络成为高光谱图像分类的有力工具之一<sup>[37,38]</sup>.基于卷积神经网络的方法在分类性能方面一度优于基于支持向量机的方法<sup>[39]</sup>.例如,Makantasis等<sup>[40]</sup>借助卷积神经网络模型同时编码高光谱图像的空间和光谱信息,并利用多层感知机进行像素分类.与之类似,Zhang等<sup>[41]</sup>提出了一种多维卷积神经网络来自动地提取多层级空谱特

征.此外, Lee等<sup>[42]</sup>设计了一种新颖的上下文深度卷积神经网络模型.该方法通过探索近邻像素间的空谱关系来得到最优的上下文信息.尽管基于卷积神经网络的方法在一定程度上取得了较为理想的分类表现,但这类方法仍存在一些不足.首先,在传统的卷积神经网络模型中,卷积核通常只能作用于形状规则的方形区域上.因此,这类模型往往无法自适应地捕捉高光谱图像中不同地物区块间的几何变化<sup>[43]</sup>.同时,当卷积神经网络在对不同图像区块进行卷积操作时,相应卷积核的权重参数固定不变.由于卷积核缺乏灵活性,使用这种卷积方式可能会导致类别边界区域信息的损失.不仅如此,传统的卷积神经网络模型无法直接对高光谱图像中的长距离空间关系进行建模,这一定程度上限制了模型的表征能力.

考虑到卷积神经网络在高光谱图像分类任务中的固有缺陷,研究者提出使用一种新型深度模型,即图神经网络(Graph Neural Network, GNN)<sup>[44]</sup>,用于高光谱图像分类.近年来,图神经网络凭借其强大的学习能力,在图数据分析和处理任务中取得了巨大的成功<sup>[45]</sup>.其中,图卷积神经网络(Graph Convolutional Neural Network, GCNN)<sup>[46]</sup>作为一种典型的图神经网络模型,在高光谱图像分类任务中发挥着越来越重要的作用<sup>[47-49]</sup>.图卷积神经网络主要通过聚合来自节点邻域的信息来不断更新节点表示,其中的图卷积操作可由图的邻域结构自适应地控制.因此,图卷积神经网络能够适用于非欧几里得结构的不规则数据,从而可以灵活地保留高光谱图像中不规则的类别边界信息.此外,借助合适的图结构,图卷积神经网络能够直接对远距离像素间的空间关系进行建模.利用图卷积神经网络的上述优势,Wan等<sup>[43]</sup>提出了一种多尺度动态图卷积网络,不仅可以从多种空间尺度下分别挖掘高光谱图像中的空谱信息,而且随着训练的进行,原始图信息能够被不断优化,最终产生更强的网络表示.基于上述工作,Wan等<sup>[22,50,51]</sup>还设计了多种改进的图卷积网络结构,并取得了令人满意的表现.同时,Hong等<sup>[52]</sup>提出的“小批次图卷积网络”在保证分类精度的前提下,一定程度上缓解了图卷积网络计算复杂度过高的问题.

本文主要对近年来应用于高光谱图像分类领域的图神经网络模型进行系统的归纳和整理,并对它们的主要思想和局限性做出详尽的分析.尽管目前已有高光谱图像分类的相关综述<sup>[1,5]</sup>,但是此类工作主要关注传统的深度学习(如卷积神经网络)和模式识别技术,而对近年来关注度较高的图神经网络模型相关方法鲜有涉及.因此,本文旨在全面概述基于图神经网络的高光谱图像分类方法,以帮助对该领域感兴趣的读者快速、全面地了解相关研究的最新进展.具体地,本文根

据图神经网络方法中图结构的构建方式、图卷积的类型,以及模型架构和模型优化策略4个方面,对现有的基于图神经网络的高光谱图像分类方法进行整理和归纳;同时,本文对常用的开源算法进行了广泛收集和性能对比及分析,使得本文能够作为理解、使用和开发各种实际应用的实践指南;最后,本文对当前方法进行总结,分析它们的缺陷,并探讨未来可能的研究方向。

## 2 符号与定义

本节主要介绍文中所使用的符号定义. 本文通常用  $\mathcal{G} = \langle \mathcal{V}, \mathcal{E} \rangle$  表示无向图. 其中,  $\mathcal{V}$  是节点集, 包含了图上的所有节点, 而  $\mathcal{E}$  表示边集, 包含了图上所有的边. 在此基础上可以构造图  $\mathcal{G}$  的邻接矩阵 (adjacency matrix)  $\mathbf{A}$ , 从而建立起节点之间的联系. 其中, 邻接矩阵  $\mathbf{A}$  中的元素  $A_{ij}$  刻画了图节点  $\mathbf{x}_i$  和  $\mathbf{x}_j$  的相似性. 这里, 图中第  $i$  个节点的“度”可以定义为  $D_{ii} = \sum_{j=1}^n A_{ij}$ , 其中,  $n$  代表图  $\mathcal{G}$  中节点的数量,  $\mathbf{D}$  是对角矩阵. 基于上述已定义的邻接矩阵  $\mathbf{A}$  和度矩阵  $\mathbf{D}$ , 可以得到未标准化的图拉普拉斯矩阵, 即  $\mathbf{L} = \mathbf{D} - \mathbf{A}$ . 通常情况下, 本文用  $\mathbf{X}$  表示图  $\mathcal{G}$  的节点特征矩阵, 其中,  $\mathbf{X}_{ij}$  表示第  $i$  个节点的第  $j$  个特征.

## 3 图神经网络的类型

受传统深度学习技术 (如卷积神经网络) 的启发, 研究者开始广泛研究以图结构为基础的深度学习模型, 而图神经网络凭借其优越的性能脱颖而出. 近年来, 在高光谱图像分类任务中, 图神经网络也正发挥着更加重要的作用. 图神经网络的相关理论可以追溯到 1997 年, Sperduti 等<sup>[53]</sup> 首次将神经网络应用到有向无环图上. 之后, 图神经网络的概念被正式提出<sup>[54]</sup>, 并被研究者进一步解释<sup>[55]</sup>. 总的来讲, 常见的图神经网络大致可以分为 4 类, 即图卷积神经网络、循环图神经网络、图自编码器和时空图神经网络. 值得注意的是, 目前用于高光谱图像分类任务的图神经网络大都属于图卷积神经网络. 因此, 本节主要回顾图卷积神经网络的主要类型, 包括基于谱域和基于空间域的方法.

### 3.1 基于谱域的图卷积神经网络

基于谱域的图卷积神经网络从图信号处理的角度引入了滤波器来定义图卷积操作, 因而具有坚实的数学基础. 这类方法通常假设图是无向的, 而一个无向图的鲁棒数学表示则为该图标准化的拉普拉斯矩阵, 即  $\mathbf{L} = \mathbf{I} - \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}}$ . 由于标准化的图拉普拉斯矩阵  $\mathbf{L}$  是对称半正定矩阵, 所以可以将其分解为  $\mathbf{U} \mathbf{A} \mathbf{U}^T$ . 其中,  $\mathbf{U}$  是由特征向量构成的矩阵,  $\mathbf{A}$  是由特征向量对应特征值组成的对角矩阵. 在图信号处理中, 一个图信号  $\mathbf{s} \in \mathbb{R}^n$

对应于一个包含了图  $\mathcal{G}$  中所有  $n$  个节点的特征向量, 该向量的第  $i$  个元素为第  $i$  个图节点的值. 基于信号  $\mathbf{s}$  的图傅里叶变换被定义为  $\mathcal{F}(\mathbf{s}) = \mathbf{U}^T \mathbf{s}$ . 借助图傅里叶变换, 可以将原始的输入图信号投影到正交空间中, 且该空间的基由标准化的图拉普拉斯矩阵  $\mathbf{L}$  的特征值构成. 接着, 使用滤波器  $\mathbf{g}$  对输入信号  $\mathbf{s}$  施加的图卷积操作被定义为

$$\begin{aligned} \mathbf{g} * \mathbf{s} &= \mathcal{F}^{-1}(\mathcal{F}(\mathbf{s}) \odot \mathcal{F}(\mathbf{g})) \\ &= \mathbf{U}(\mathbf{U}^T \mathbf{s} \odot \mathbf{U}^T \mathbf{g}) \end{aligned} \quad (1)$$

其中,  $\odot$  表示 Hadamard 积,  $\mathcal{F}^{-1}$  代表逆图傅里叶变换. 在定义了滤波器  $\mathbf{g}_\theta = \text{diag}(\mathbf{U}^T \mathbf{g})$  后, 基于谱域的图卷积操作能够被简化为

$$\mathbf{g}_\theta * \mathbf{s} = \mathbf{U} \mathbf{g}_\theta \mathbf{U}^T \mathbf{s} \quad (2)$$

其中,  $\text{diag}(\cdot)$  代表对角矩阵. 目前, 基于谱域的图卷积神经网络大都遵循此定义, 它们的差异主要在于滤波器  $\mathbf{g}_\theta$  的选择.

2014 年, Bruna 等<sup>[56]</sup> 基于谱图理论提出了谱域图卷积神经网络的前驱工作——谱卷积神经网络. 该方法首次提出在图上构建卷积神经网络, 其中, 第  $k$  层图卷积层的输出定义如下

$$\mathbf{H}_{:,j}^{(k)} = \sigma \left( \sum_{i=1}^{d_{in}} \mathbf{U} \boldsymbol{\Theta}_{i,j}^{(k)} \mathbf{U}^T \mathbf{H}_{:,i}^{(k-1)} \right) \quad (3)$$

其中,  $j = 1, 2, \dots, d_{out}$ ,  $\mathbf{H}^{(0)} = \mathbf{X}$ ,  $d_{in}$  和  $d_{out}$  分别为输入和输出信号的通道数,  $\boldsymbol{\Theta}^{(k)}$  是由可学习参数组成的对角矩阵,  $\sigma$  是激活函数. 然而, 谱卷积神经网络中卷积核的参数数量取决于图节点的数量  $n$ , 同时卷积操作的时间复杂度也较高 ( $\mathcal{O}(n^3)$ ).

为了解决谱卷积神经网络卷积核过大的缺陷, Deferrard 等<sup>[57]</sup> 提出了 ChebNet. 由于 ChebNet 无须计算拉普拉斯矩阵的特征向量, 其卷积操作的时间复杂度可以降低至  $\mathcal{O}(m)$  ( $m$  为边的数量). 具体地, ChebNet 通过特征值对角矩阵对应的 Chebyshev 多项式来对滤波器  $\mathbf{g}_\theta$  进行参数化, 即

$$\sigma_\theta = \sum_{i=0}^K \theta_i T_i(\tilde{\Lambda}) \quad (4)$$

其中,  $\theta$  为可学习的参数,  $K$  为多项式的阶数,  $\tilde{\Lambda} = \frac{2\mathbf{A}}{\lambda_{\max}} - \mathbf{I}$ ,  $\mathbf{A}$  是由标准化拉普拉斯矩阵特征值组成的对角阵,  $\lambda_{\max}$  是最大的特征值,  $\mathbf{I}$  是单位矩阵. 式 (4) 中的 Chebyshev 多项式可以被递归地定义为

$$T_i(\mathbf{s}) = 2\mathbf{s}T_{i-1}(\mathbf{s}) - T_{i-2}(\mathbf{s}) \quad (5)$$

且  $T_0(\mathbf{s}) = 1$ ,  $T_1(\mathbf{s}) = \mathbf{s}$ . 令  $\hat{\mathbf{L}} = 2\mathbf{L}/\lambda_{\max} - \mathbf{I}$ , 则 ChebNet 的网络层定义如下

$$\mathbf{g}_\theta * \mathbf{s} = \sum_{i=0}^K \theta_i T_i(\hat{\mathbf{L}}) \mathbf{s} \quad (6)$$

在此基础上, Kipf等<sup>[46]</sup>利用一阶近似对ChebNet中的卷积操作进行了进一步简化, 并提出了广为人知的图卷积网络. 通过假设 $K=1, \lambda_{\max}=2$ , Kipf等<sup>[46]</sup>将式(6)简化为

$$\mathbf{g}_\theta^* \mathbf{s} = \theta_0 \mathbf{s} - \theta_1 \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \mathbf{s} \quad (7)$$

为了限制参数规模以避免网络过拟合, Kipf等<sup>[46]</sup>进一步假设 $\theta = \theta_0 = -\theta_1$ , 从而得到了如下的图卷积操作

$$\mathbf{g}_\theta^* \mathbf{s} = \theta \left( \mathbf{I} + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \right) \mathbf{s} \quad (8)$$

由于 $\mathbf{I} + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}}$ 的特征值范围在 $[0, 2]$ 之间, 如果在深度模型中多次使用式(8)中的卷积操作可能会导致梯度爆炸或弥散. 因此, 图卷积网络采用了一种重标准化技巧. 具体地, 将 $\mathbf{I} + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}}$ 转换为 $\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}}$ , 其中 $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ ,  $\tilde{\mathbf{D}} = \sum_j \tilde{\mathbf{A}}_{ij}$ . 接着, 在将式(8)扩展至多通道输入和输出的形式后, 可以给出图卷积网络第 $k$ 层卷积层的输出

$$\mathbf{H}^{(k)} = \sigma \left( \tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{H}^{(k-1)} \mathbf{W} \right) \quad (9)$$

其中,  $\mathbf{W}$ 为可学习的参数矩阵. 需要说明的是, 图卷积神经网络亦可作为基于空间域的图卷积神经网络算法, 这是因为它的卷积过程能够被看作基于邻域结构的节点特征聚合. 由于图卷积网络在各类任务中表现优秀, 国内外研究者基于图卷积网络提出了一系列改进工作. 例如, Li等<sup>[58]</sup>考虑到图卷积网络仅能借助固定的图结构来描述节点间的关联信息, 提出了一种自适应图卷积网络, 以灵活地提取图节点间潜在的关联信息, 其在多组图数据集中都取得了令人满意的结果. 同时, Zhuang等<sup>[59]</sup>设计了一种对偶图卷积网络. 该算法可以同时提取图中的局部和全局结构信息, 克服了传统图卷积网络无法有效刻画全局一致性的不足. 此外, Xu等<sup>[60]</sup>通过将图傅里叶变换替换为图小波变换, 提出了图小波神经网络, 该算法在便捷性和可解释性方面具备明显优势.

### 3.2 基于空间域的图卷积神经网络

与传统卷积神经网络在图像中的卷积操作类似, 基于空间域的图卷积神经网络利用节点间的空间关系来定义图卷积操作<sup>[44]</sup>. 图1分别对传统卷积神经网络中的二维卷积操作和图神经网络中的空间域图卷积操作进行了可视化, 图1(a)中的圆圈对应于图像像素, 中心像素(即橙色圆圈)与周围8个邻居像素以网格的形式相连, 并借助一个 $3 \times 3$ 的卷积核对所有9个像素的特征进行加权平均操作, 其中的权值由卷积核定义. 而在图1(b)中, 圆圈对应于图节点, 其中, 中心节点(橙色圆圈)可能与任意距离内的其他节点相连, 基于空间域的

图卷积网络通过聚合中心节点和其邻居的信息来更新中心节点的表征. 与基于谱域的图卷积神经网络模型相比, 基于空间域的模型凭借其便捷性、灵活性以及优秀的泛化能力, 近年来得到了更广泛的应用.




图1 不同类型的卷积操作

作为空间域图卷积神经网络的前驱工作, Micheli<sup>[61]</sup>提出的NN4G通过直接聚合节点邻域信息来进行图卷积操作. 同时, 该方法还使用残差连接和跳跃连接来记忆每一层中的信息, 其节点表征更新方式如下

$$\mathbf{H}^{(k)} = \sigma \left( \mathbf{X} \mathbf{W}^{(k)} + \sum_{i=1}^{k-1} \mathbf{A} \mathbf{H}^{(i-1)} \tilde{\mathbf{W}}^{(k)} \right) \quad (10)$$

其中,  $\tilde{\mathbf{W}}^{(k)}$ 为可学习的参数矩阵. 受NN4G方法的启发, Bacciu等<sup>[62]</sup>提出了上下文图马尔可夫模型. 该模型除继续保持NN4G算法的空间局部性外, 还具备概率可解释性的优点. 此外, Atwood等<sup>[63]</sup>将图卷积视为一种扩散过程, 并提出了扩散卷积神经网络. 该算法借助一个特定的转移矩阵来定义节点的邻域, 以此为基础进行如下的扩散图卷积操作:

$$\mathbf{H}^{(k)} = \sigma \left( \mathbf{W}^{(k)} \odot \mathbf{P}^{(k)} \mathbf{X} \right) \quad (11)$$

其中, 概率转移矩阵 $\mathbf{P} = \mathbf{D}^{-1} \mathbf{A}$ . 最后, 模型将所有 $K$ 个表征矩阵 $\mathbf{H}^{(1)}, \mathbf{H}^{(2)}, \dots, \mathbf{H}^{(K)}$ 拼接起来作为模型的输出. 然而, 在扩散卷积神经网络中, 距离较远的邻居节点对中心节点的贡献非常有限. 为了缓解这一问题, PGD-GCNN算法<sup>[64]</sup>基于最短路径策略构建了一个最短路径邻接矩阵, 从而有效增强了远距离邻居节点在特征聚合中的重要性.

由于早期的图卷积神经网络无法处理归纳式半监督学习问题<sup>[65]</sup>, Hamilton等<sup>[66]</sup>提出了GraphSAGE算法. GraphSAGE算法从邻居节点中随机采样, 并仅需通过

对采样得到的邻居节点进行聚合即可更新节点表征。在 GraphSAGE 等算法的图卷积操作中,所有邻居节点对中心节点的贡献是相同或预先确定的,这种做法可能无法准确刻画节点之间的内在联系。因此,研究者提出了一系列基于注意力机制<sup>[67]</sup>的空间域图神经网络。此类算法的图卷积操作能够自适应地为每个邻居节点赋予不同权重。作为具有代表性的基于注意力机制的图卷积神经网络,图注意力网络<sup>[68]</sup>算法在节点特征的基础上,借助注意力机制来学习节点间的权重,具体的图卷积操作定义如下

$$\mathbf{h}_i^{(k)} = \sigma \left( \sum_{j \in \mathcal{N}(i) \cup i} \alpha_{ij}^{(k)} \mathbf{W}^{(k)} \mathbf{h}_j^{(k-1)} \right) \quad (12)$$

其中,  $\mathbf{h}_i^{(k)}$  代表节点  $\mathbf{x}_i$  在第  $k$  层的表征,  $\alpha_{ij}^{(k)}$  为第  $k$  层中节点  $\mathbf{x}_i$  和  $\mathbf{x}_j$  间的注意力系数。在图注意力网络中,注意力系数通常基于节点对的特征计算得到。值得注意的是,图注意力网络还引入了多头注意力机制来增强学习的稳定性。图注意力网络凭借可并行化、易扩展到归纳式

半监督学习的优势,在众多领域都取得了优秀的表现。此外,门控注意力网络<sup>[68]</sup>亦为一种基于多头注意力机制的图卷积神经网络,不同于图注意力网络借助平均化操作来处理多头信息,该算法通过自注意力机制聚合来自不同头部的信息。

近年来,由于涌现出了众多基于空间域的图卷积神经网络理论和模型,一些研究者试图利用特定的框架来对不同类型的网络进行整合。例如, Monti 等<sup>[69]</sup>提出了一种定义在图或流形上的空间域框架——MoNet,而前文介绍的扩散卷积神经网络则可以被视作 MoNet 的特例。同时, Gilmer 等<sup>[70]</sup>提出了消息传递神经网络。该网络能够借助消息传递函数来统一多种空间域图卷积神经网络。总的来讲,这类模型都包含两步操作,即消息传递和读出操作。此外, Wang 等<sup>[71]</sup>设计了非局部神经网络来整合多种基于自注意力机制的图神经网络。表 1 展示了几种具有代表性的图卷积神经网络算法,同时总结了算法的主要贡献和局限性。

表 1 图卷积神经网络代表性算法汇总

算法名称	发表时间	图卷积类型	主要贡献	局限性
Spectral CNN <sup>[56]</sup>	2014 年	谱域图卷积	首个基于谱域方法的图卷积神经网络模型,将卷积神经网络推广到图数据中	时间复杂度过高,无法直接扩展至未观测的数据
ChebNet <sup>[57]</sup>	2016 年	谱域图卷积	利用 Chebyshev 多项式近似计算图卷积,有效降低了图卷积的时间复杂度	无法直接扩展至未观测的数据
GCN <sup>[46]</sup>	2017 年	谱域图卷积	利用一阶近似进一步简化 ChebNet 中的卷积操作	无法直接扩展至未观测的数据
NN4G <sup>[61]</sup>	2009 年	空间域图卷积	首个基于空间域方法的图卷积神经网络模型,直接从节点的邻域聚合特征	节点表征可能会有较大的尺度差异
GraphSAGE <sup>[66]</sup>	2017 年	空间域图卷积	优化了图卷积过程中的节点采样方式,将图卷积神经网络模型推广到归纳式半监督学习场景中	丢失部分局部信息,节点表征不稳定
GAT <sup>[68]</sup>	2017 年	空间域图卷积	利用自注意力机制自适应地聚合邻居特征	网络参数较多,易过拟合

#### 4 图神经网络在高光谱图像分类领域的研究现状

高光谱图像分类通常指像素级别的分类任务,即确认图像中每一个像素的地物类别。在过去的数年中,以卷积神经网络为代表的深度学习方法凭借出色的空谱特征提取能力,在高光谱图像分类领域取得了令人欣慰的成果。近年来,一种新型深度学习方法——图神经网络开始出现在高光谱图像分类领域中。与卷积神经网络模型不同,图神经网络能够直接处理不规则的非欧几里得数据,其卷积操作不再被限制于方形的局部区域中。因此,在捕捉像素间关联信息方面具有更强的灵活性。图神经网络主要包括图卷积神经网络、循环图神经网络、图自编码器和时空图神经网络 4 类模型。其中,图卷积神经网络通常较为高效,且易与其他深度模型组合。因此,当前用于高光谱图像分类的图神经网络

模型主要为图卷积神经网络。

本节首先从图神经网络中的两个重要模块(即建图和图卷积模块)出发,对当前的高光谱图像分类方法进行整理和归纳。具体地,如图 2 所示,基于图神经网络的高光谱图像分类方法首先需要建立图结构,这是图神经网络方法的基础步骤,图结构的准确与否很大程度上影响着模型的性能。其中,根据图节点的类型可以将当前方法大致分为两种,即以原始像素为节点建图和以超像素为节点建图的方法。接着,可以在上述图结构的基础上进行图卷积操作,以提取高光谱图像中的空谱特征。这里,根据图卷积操作的类型可以将当前方法分为两类,分别为基于空间域图卷积和基于谱域图卷积的方法。最后,可利用上述学到的空谱特征来预测图像分类的结果。

除此之外,图神经网络方法中的模型架构和优化

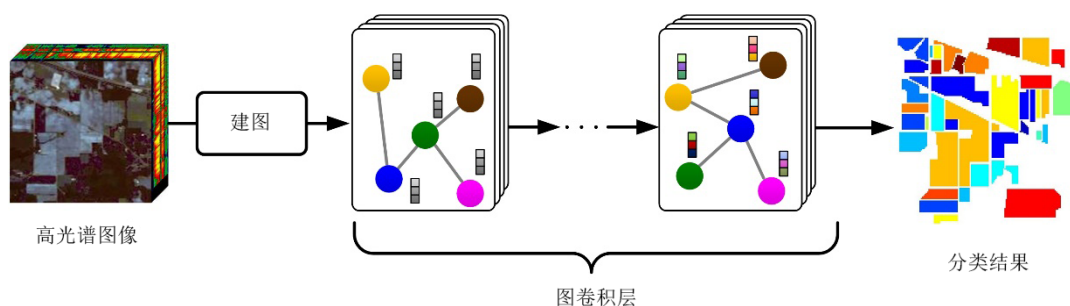


图2 基于图神经网络的高光谱图像分类常用流程示意图

策略也值得关注. 本节从这两方面对当前基于图神经网络的高光谱图像分类方法进行整理和归纳. 具体来讲, 根据图神经网络是否与卷积神经网络等其他深度模型协同运作, 可以将当前的高光谱图像分类方法大致分为混合型型和单一型两种类型. 而在模型优化策略

的选择方面, 目前的图神经网络方法往往通过两种不同的方式来更新网络模型的参数, 即全批量梯度下降法和小批量梯度下降法. 表2对基于图神经网络的代表性高光谱图像分类算法进行了汇总, 并简要介绍了算法的主要贡献和局限性.

表2 基于图神经网络的代表性高光谱图像分类算法汇总

算法名	主要贡献	局限性
S <sup>2</sup> GCN <sup>[47]</sup>	首次将光谱信息和空间信息同时引入图卷积过程	图卷积操作的复杂度较高
MDGCN <sup>[43]</sup>	提出动态图卷积, 在图卷积的过程中迭代优化图信息	无法优化图拓扑结构
CAD-GCN <sup>[22]</sup>	首次提出可学习的超像素级建图技术, 实现了像素-超像素转换过程的自动化	训练难度大, 对超像素的特征初始化要求较高
miniGCN <sup>[52]</sup>	使用小批量梯度下降策略优化模型, 并探索了图神经网络和卷积神经网络的不同融合方式	需要手动选择最优的融合方式
non-local GCN <sup>[48]</sup>	提出非局部图卷积来挖掘像素间的长距离关联信息	非局部图卷积依赖像素级图学习, 复杂度较高
CEGCN <sup>[72]</sup>	解决了卷积神经网络和图卷积网络表征结构不兼容的问题	子模型较多, 训练存在一定难度
SAGE-A <sup>[73]</sup>	利用自注意力机制捕捉图像的多尺度和全局空谱信息	全局空谱关联信息易受噪声影响
DAGCN <sup>[74]</sup>	基于信息熵理论设计像素间相似性度量方法, 缓解了光谱特征冗余的问题	网络结构庞大, 无法用于大规模高光谱数据
MGLN <sup>[51]</sup>	在不同层级上重建图结构, 捕捉超像素间的潜在关联信息	图结构重建模块的超参数调整存在一定难度
GCGCN <sup>[75]</sup>	从拓扑结构的角度构建全局一致性图结构用于图卷积, 增强了表征的全局平滑性	图的构建和表征学习被分为两步, 算法训练难度较大

#### 4.1 建图方式

在图卷积神经网络中, 图结构是卷积操作的基础, 图结构的准确与否直接影响着表征学习的效果. 因此, 针对特定任务构建一个合适的图结构对图神经网络模型至关重要, 而图节点的选择是建图的关键环节. 在基于图神经网络的高光谱图像分类方法中, 通常以像素或超像素为节点来构建图结构.

##### 4.1.1 以像素为节点建图

与许多其他基于图的高光谱图像分类方法类似, 在基于图神经网络的方法中, 将图像像素作为图节点是最直接而简易的建图方式. 由于高光谱图像无法直接提供具有图结构的数据, 因此研究者往往需要根据节点间的邻接关系, 建立相应邻接矩阵, 用于图卷积操作<sup>[23, 76-79]</sup>. 其中, 构建邻接矩阵的关键步骤之一是确定节点间的权重, 根据权重是否可学习可以将当前方法

大致分为两类. 第一类方法通常会预先计算图节点间的权重, 且该权重在模型学习的过程中始终保持固定. 例如, 早期的S<sup>2</sup>GCN算法<sup>[47]</sup>以高光谱图像中的像素为图节点, 通过融合像素间的光谱特征差异和空间距离, 建立了一个基于空谱信息的邻接矩阵用于后续图卷积. 受S<sup>2</sup>GCN算法启发, DGU-HSI算法<sup>[80]</sup>基于像素之间的空间位置关系和光谱特征差异分别建立了两个邻接矩阵用于图卷积, 并对卷积的结果进行融合. 与S<sup>2</sup>GCN算法相比, DGU-HSI算法需要基于两个邻接矩阵分别进行图卷积操作, 其复杂度相对较高. 然而, DGU-HSI算法一定程度上避免了不同种信息的相互干扰, 在图卷积的过程中能够更好地保留图像原始的空间和光谱信息. 此外, 考虑到高光谱图像中的地物形态多变, Xi等<sup>[81]</sup>在不同空间尺度下分别构建了多个邻接矩阵用于图卷积操作, 充分挖掘了图像的多尺度空谱信息. 在上述这些方法中, 邻接矩阵 $A$ 中元素 $A_{ij}$ 的一般计算形

式为

$$A_{ij} = \mathcal{D}(\mathbf{x}_i, \mathbf{x}_j, \mathbf{p}_i, \mathbf{p}_j) \quad (13)$$

其中,  $\mathbf{x}_i$  和  $\mathbf{x}_j$  分别为第  $i$  和  $j$  个像素的光谱特征,  $\mathbf{p}_i$  和  $\mathbf{p}_j$  分别为  $\mathbf{x}_i$  和  $\mathbf{x}_j$  对应的空间特征(如在图像网格中的位置),  $\mathcal{D}$  为以空间特征(可选)和光谱特征为输入的非参数化相似性度量函数.

在式(13)中,邻接矩阵的计算依赖于固定的相似性或距离度量函数(如余弦相似性或欧氏距离).因此,当像素的光谱特征中包含噪声等干扰因素时,得到的邻接矩阵可能无法准确刻画像素间的内在联系,进而影响后续表征学习的效果.针对这一问题,研究者提出构建像素级邻接矩阵的另一种思路,即利用网络模型来自适应地学习像素间权重,从而能够在训练过程中不断优化邻接矩阵<sup>[82,83]</sup>.其中,最直接的做法是利用参数矩阵编码像素特征,再基于编码后的特征来计算邻接矩阵,如 non-local GCN 算法<sup>[48]</sup>.然而,仅使用随机初始化的参数矩阵编码像素特征无法捕捉图像的空谱信息.为了解决这一问题,FDGC<sup>[82]</sup>和 DGCN-M 算法<sup>[84]</sup>借助卷积神经网络来提取图像的空谱特征,并基于生成的表征计算邻接矩阵.为了避免引入规模庞大的卷积神经网络,Bai 等<sup>[74]</sup>使用自注意力机制<sup>[67]</sup>对像素间的相似性关系进行编码,不仅控制了参数规模,而且能够驱使模型关注最重要的邻域特征信息.总的来讲,在可学习的邻接矩阵  $A$  中,元素  $A_{ij}$  的计算过程可以表示为

$$A_{ij} = \tilde{\mathcal{D}}(\mathbf{x}_i, \mathbf{x}_j, \mathbf{p}_i, \mathbf{p}_j) \quad (14)$$

式(13)与式(14)最显著的差异在于相似性度量函数的选择,前者一般采用固定的、非参数化的度量函数  $\mathcal{D}$ ,后者通常使用参数化的度量函数  $\tilde{\mathcal{D}}$ .

#### 4.1.2 以超像素为节点建图

尽管直接以像素为节点进行构图简单易行,但这种做法仍存在一定缺陷.具体来讲,当高光谱图像中的像素数目较多时,以像素为节点建图可能导致图的尺寸过大,进而使得后续图卷积操作的时间和空间复杂度升高,这一缺陷严重制约了图神经网络模型在大规模高光谱数据集上的应用<sup>[43]</sup>.为了解决这一问题,研究者提出以超像素为节点来构建图结构.超像素通常指由纹理、颜色、亮度等特征相似的相邻像素构成的不规则像素块,高光谱图像中的超像素往往可以借助图像分割算法得到.在高光谱图像中,超像素数量通常远远小于像素数量.因此,以超像素为节点建图能够合理地限制图的尺寸,有效提高了图卷积的效率.同时,利用超像素来构建图结构的另一个优势在于,分割得到的超像素能够很好地保留高光谱图像的局部结构信息.由于具备上述优势,以超像素为节点建图的方式迅速得到了广泛应用.

目前,以超像素为节点建图的图神经网络方法大

致可以分为两类.第一类方法基于固定的超像素划分,即原始图像中的每个像素被固定地划入对应的超像素中,同时超像素的特征也始终保持固定.Wan 等<sup>[43]</sup>于 2019 年提出的 MDGCN 是最早利用超像素建图的图神经网络方法.MDGCN 算法首先借助一种名为 SLIC (Simple Linear Iterative Clustering)<sup>[85]</sup>的图像分割算法将高光谱图像分割为一系列紧凑的超像素,并将超像素中所有像素点的光谱特征均值作为对应超像素的特征.接着,基于局部空间邻域来构建图结构以用于后续图卷积.自 MDGCN 算法被提出后,以超像素为单位构建图结构成为一种较为常见的操作<sup>[86,87]</sup>,同时也衍生出了一系列改进的算法.例如,为了提取高光谱图像中的多尺度空谱信息,MSSGU 算法<sup>[88]</sup>利用区域融合技术生成多等级的超像素划分结果,并分别构建相应的图结构用于图卷积操作.同时,为了保留像素级的细粒度空谱信息,GiGCN 算法<sup>[89]</sup>分别构建了像素级和超像素级的图结构,并通过融合不同层级图卷积的结果来获得多尺度空谱特征.此外,为了进一步改善图卷积操作的效率,Auto-GCN 算法<sup>[90]</sup>将原始图像分割为尺寸较大的网格形超像素,再利用超像素构建图结构,有效减少了图节点的数量.然而,在上述算法中,图网络模型性能的优劣依赖于超像素分割的准确性.当分割结果存在较多错误时,以超像素为单位构建的图结构可能无法准确刻画高光谱图像中地物之间的关联信息.尤其在图像类别边界附近,由于像素的光谱特征波动较大,超像素分割的结果往往存在较多错误,这一定程度上限制了高光谱图像分类准确率的提高.

考虑到传统图像分割算法的局限性,研究者开始探索基于“软分割”技术的超像素建图方法.在这类方法中,超像素的划分及其对应的特征都是可调整的,从而模型能够在学习的过程中逐渐改进图像分割的结果.目前,大多数基于“软分割”技术的超像素建图方法都采用了端到端策略,即图像分割和图的构建两个模块需要被共同优化.例如,Wan 等<sup>[22]</sup>提出的 CAD-GCN 算法首先基于像素与超像素间的相似性关系学习一个“软分配”矩阵.随后,基于该矩阵将原始图像中的像素自适应地分配到其对应的近邻超像素中,这也是首个基于端到端策略进行超像素建图的算法.由于分割结果能够在训练的过程中被逐步优化,这种建图方式也被后续的 DIGCN<sup>[50]</sup>等众多算法沿用.图 3 展示了 CAD-GCN 算法中“软分割”技术的大致过程.其中,蓝色线条的宽度对应着像素特征  $\mathbf{x}_i$  被分配到特定超像素的比例.可以发现,特征  $\mathbf{x}_i$  被同时分配到了近邻的 7 个超像素中,且该分配过程能根据像素与超像素间的相似度自适应地调整.与之不同的是,Ding 等<sup>[75]</sup>提出了一种两阶段建图策略.该算法会预先学习一个像素分配矩

阵,接着固定该矩阵,并进行超像素分割.与基于固定分割的超像素建图方法相比,基于“软分割”的方法可以得到更合理的超像素划分和更准确的图节点特征,进而能够有效改善高光谱图像分类的表现.然而,分割模块训练难度较大是此类方法急需解决的问题.

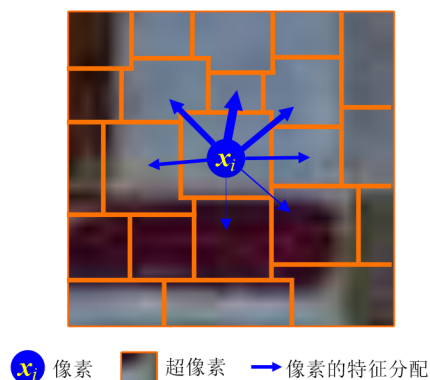




图3 CAD-GCN算法<sup>[22]</sup>中“软分割”技术示意图

图4为不同建图方式的示意图,同时,表3对上述建图方式进行了具体的分类.总的来讲,当前基于图神经网络的高光谱图像分类方法大都以像素或超像素为节点建立图结构.像素级的建图方法无须对图像进行特殊预处理,操作流程简单,因而早期的方法大多采用这一建图方式.尽管超像素级的建图方法需要对原始图像进行预分割,但由于图像分割后的超像素数目远小于原始的像素数目,因此这种建图方法在时间和空间复杂度方面一般具有较大优势.此外,将超像素作为图节点能够保留高光谱图像的局部结构信息,从而有效强化模型的代表能力.尽管如此,当超像素分割的结果存在错误时,最终的分类准确率也会受到一定影响,而借助“软分割”技术一定程度上能够减少误分割带来

的负面影响.



(a) 以像素为节点建图



(b) 以超像素为节点建图




图4 两种不同的建图方式示意图

表3 高光谱图像分类任务中,神经网络的建图方式

建图方式	具体类型	文献	优点	局限性
以像素为节点	节点间权重固定	文献[23], [47], [52], [76], [77], [78], [79], [80], [81], [91], [92], [93], [94]	操作方便,无须特殊处理	邻接矩阵的准确性易受噪声等因素影响
	节点间权重可学习	文献[48], [74], [82], [83], [84], [95], [96], [97], [98]	邻接矩阵可迭代优化,能减少噪声等因素的干扰	算法时间和空间复杂度很高,且模型训练存在一定难度
以超像素为节点	超像素划分固定	文献[43], [51], [72], [73], [86], [87], [88], [89], [90], [99], [100], [101], [102], [103], [104]	操作便捷,可以预先计算,节省计算资源	需要手动选择超像素分割算法及其对应的超参数,分割的准确性难以保证
	超像素划分可学习	文献[22], [50], [75], [105]	分割结果可由模型自动优化,超像素划分更精确	算法时间和空间复杂度相对较高,且分割模块的训练存在较大难度

## 4.2 图卷积类型

由于当前高光谱图像分类领域中的图神经网络模型通常为图卷积神经网络,因此本节将以两种不同类型的图卷积操作(即基于空间域和基于谱域的图卷积)为基础,对现有的基于图神经网络的高光谱图像分类方法进行整理和归纳.

### 4.2.1 基于空间域的图卷积

与卷积神经网络在图像中的卷积操作类似,空间域图卷积神经网络直接基于节点的空间关系定义图卷积操作.因此,这类图卷积操作较为直观,定义也相对灵活.由于具备上述优点,基于空间域的图卷积神经网络近年来开始逐渐被用于高光谱图像分类任务.其中,

以自注意力机制为基础发展而来的图注意力网络等模型<sup>[68]</sup>受到了广泛关注<sup>[91,97]</sup>,这类模型通过学习一组注意力系数来自适应地聚合邻居特征.例如,Ding等<sup>[73]</sup>提出的SAGE-A算法利用注意力系数 $e_{ij}$ 来编码节点(超像素)间的潜在关联信息

$$e_{ij} = \mathbf{a}^T [\mathbf{W}\mathbf{z}_i || \mathbf{W}\mathbf{z}_j] \quad (15)$$

其中, $\mathbf{a}$ 为参数向量, $\mathbf{W}$ 为参数矩阵, $\mathbf{z}_i$ 和 $\mathbf{z}_j$ 分别代表超像素的特征.在对 $e_{ij}$ 进行标准化操作得到 $\alpha_{ij}$ 后,SAGE-A算法通过如下的方式进行特征聚合

$$\mathbf{h}_i^l = \sigma \left( \sum_{j \in \mathcal{N}(i)} \alpha_{ij} \mathbf{W} \mathbf{h}_j^{(l-1)} \right) \quad (16)$$

其中, $\sigma$ 代表激活函数, $\mathbf{h}_j^{(l-1)}$ 为第 $l-1$ 层网络生成的超像素 $\mathbf{z}_j$ 的表征.借助式(16)中的特征聚合操作,SAGE-A算法能够基于超像素间的潜在联系自适应地挖掘空谱信息,从而有效抑制图像特征中噪声等干扰因素对模型学习的影响.

除自注意力机制外,Hu等<sup>[102]</sup>还提出使用边卷积操作<sup>[106]</sup>来捕捉高光谱图像区域间的潜在关联信息,从而能够自适应地提取图像中最重要的空谱特征.为了更准确地挖掘高光谱图像的空谱信息,在Zuo等<sup>[78]</sup>提出的EGNN算法中,边特征还被用来刻画像素类间和类内的相似度.然而,由于需要计算像素或区域之间的关联信息,上述算法的计算复杂度相对较高,为了提高算法的运行效率,Yang等<sup>[92]</sup>基于GraphSAGE模型<sup>[66]</sup>提出了S<sup>2</sup>GraphSAGE算法.由于该算法借助随机采样策略仅聚合部分邻居像素的特征,因而其时间和空间复杂度相对较低.

#### 4.2.2 基于谱域的图卷积

基于谱域的图卷积神经网络从图信号处理的角度引入滤波器,以此来定义图卷积操作,因而具有坚实的数学基础.作为最经典的谱域图卷积神经网络,图卷积神经网络<sup>[46]</sup>在众多领域都得到了广泛应用,并收获了一定的成功.而在高光谱图像分类任务中,图卷积网络同样是最常见的谱域图神经网络模型<sup>[75,90]</sup>.Shahraki等<sup>[91]</sup>于2018年首次提出利用图卷积神经网络模型来进行高光谱图像分类.该算法直接利用式(9)中的图卷积操作提取图像的空谱特征.随后,在S<sup>2</sup>GCN算法<sup>[47]</sup>中,Qin等通过将图信号卷积中的多项式阶数设为2(即式(6)中的

$K$ ),得到了如下的卷积操作

$$\mathbf{g}_\theta * \mathbf{s} = \theta \left( \mathbf{I} + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} + \left( \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \right)^2 \right) \mathbf{s} \quad (17)$$

从而能够为每个像素额外地引入二阶邻居信息.此后,Wan等提出了一系列基于图卷积网络模型的高光谱图像分类方法,如MDGCN<sup>[43]</sup>、CAD-GCN<sup>[22]</sup>等.同时,miniGCN<sup>[52]</sup>、non-local GCN<sup>[48]</sup>等方法同样借助图卷积网络模型来提取高光谱图像的空谱特征.不同于上述基于图卷积网络模型的高光谱图像分类方法,Ma等<sup>[76]</sup>在F<sup>2</sup>HNN算法中设计了一种新颖的超图卷积操作.具体来讲,在常规的图结构中,边仅能表示节点间的关系,无法描述数据中潜在的复杂结构.而在超图中,超边能够涵盖任意数量的节点,这一特性为超图卷积操作赋予了更强大的表征能力.同时,由于F<sup>2</sup>HNN算法基于超边权重矩阵进行卷积操作,因此原始邻接矩阵中的噪声不会对算法造成较大影响.

表4根据图卷积的类型,对基于图神经网络的高光谱图像分类方法进行了归纳.总体来讲,基于谱域的图神经网络理论基础坚实,其在高光谱图像分类任务中也取得了较为理想的效果.然而,此类方法仍存在一些不足.具体来讲,基于谱域的图神经网络模型在处理规模较大的图结构时,计算量会急剧增加.因此,无法直接适用于大尺寸高光谱图像;同时,这类模型无法处理分布外的高光谱数据.相对地,使用基于空间域的图神经网络模型一定程度上能够缓解上述问题.具体地,空间域模型的卷积操作不依赖整个图结构,因而计算量相对较低;同时,由于卷积操作具有局部化特性,空间域模型能够轻松地泛化到分布外的高光谱数据上.不仅如此,空间域模型定义直观、灵活性强,研究者能够根据不同风格的高光谱图像,较为方便地调整信息聚合的方式,以获取更具鉴别能力的空谱特征.近年来,基于空间域的图注意力网络凭借其对本样本间关系的准确刻画以及优秀的泛化能力,逐渐受到了研究者的关注.不仅如此,图注意力网络的多头机制有利于刻画高光谱图像中的多尺度空谱信息,但空间和时间复杂度较高的问题始终制约着图注意力网络相关方法的进一步发展.因此,如何基于图注意力网络设计更高效、便捷的高光谱图像分类方法可能是未来潜在的研究发现之一.

表4 高光谱图像分类任务中,神经网络的图卷积类型

图神经网络类型	文献	优点	局限性
空间域	文献[51], [73], [74], [78], [84], [86], [92], [95], [96], [97], [98], [99], [102], [103]	时间和空间复杂度相对较低,泛化能力、鲁棒性和可解释性强	训练难度较高
谱域	文献[22], [23], [43], [47], [48], [50], [52], [72], [75], [76], [77], [79], [80], [81], [82], [83], [87], [88], [89], [90], [91], [93], [94], [100], [101], [104], [105]	理论基础坚实,训练难度低	时间和空间复杂度较高,泛化能力差

### 4.3 模型架构

目前,基于图神经网络的高光谱图像分类方法通常包含两种模型架构,分别是单一型和混合型. 基于单一型架构的方法仅使用单一类型的深度模型(即图神经网络),而在基于混合型架构的方法中,图神经网络通常会与其他类型的深度模型(如卷积神经网络)协同运作. 本节将以这两类架构为基础,对当前基于图神经网络的高光谱图像分类方法进行归纳和分析.

#### 4.3.1 单一型

早期基于图神经网络的高光谱图像分类方法大都使用单一的图卷积神经网络模型架构,如 $S^2GCN^{[47]}$ 等算法. 如前文所述,由于图卷积操作可以有效处理非欧几里得结构数据,基于图卷积的空谱特征提取方法能够保留高光谱图像中不规则的类别边界信息. 同时,图卷积操作能够方便地捕捉图像中的长距离空间关联信息. 因此,仅使用图神经网络的单一型架构方法,在高光谱图像分类任务中往往也能够取得不错的表现. 然而,图神经网络模型本身也存在一些固有的缺陷,在一定程度上限制了单一型架构方法在高光谱图像分类任务中的表现. 例如,传统图神经网络方法无法直接对高光谱图像中的多尺度空间信息建模,尽管 $MDGCN$ 等算法<sup>[43]</sup>可以利用多个图卷积神经网络子模型间接地实现多尺度特征提取,但这会大大增加算法的时间和空间复杂度.

#### 4.3.2 混合型

为了缓解图神经网络模型的固有缺陷,并进一步提高算法在高光谱图像分类任务中的性能,研究者开始探索将图神经网络与其他深度模型相融合的混合型模型架构,从而能够利用不同子模型来捕捉高光谱图像中多种类型的空谱特征. 近年来,基于混合型模型架构的方法在高光谱图像分类任务中得到了广泛的应用. 此类方法主要包含两种模型融合范式. 其中,第一种为“并行式”,其结构如图5所示. 不同类型的子模型同时运作来生成最终的预测结果. 例如,在 $WFCG$ 算法<sup>[99]</sup>中,考虑到图神经网络的卷积操作复杂度较高,同时,卷积神经网络无法灵活地刻画不同类型地物区块间的潜在联系, $Dong$ 等<sup>[99]</sup>提出了一种带权融合架构. 该架构巧妙地融合了卷积神经网络和图神经网络,不仅弥补了两种模型各自的缺陷,而且能够同时捕捉图像中的长距离和高阶空谱特征,有效地增强了模型的代表能力. 类似地, $Liu$ 等<sup>[82]</sup>为了缓解单独使用卷积神经网络或图神经网络的局限性,提出了同时使用这两种模型的混合型架构算法—— $FDGC$ . 与 $WFCG$ 算法不同,在 $FDGC$ 算法中,图神经网络被用来挖掘高光谱图像中的结构信息,而卷积神经网络被用来提取高光谱图像中不同层次的空谱信息. 此外,使用“并行式”模型融合范式的算法还包括 $miniGCN^{[52]}$ 、 $CEGCN^{[72]}$ 等,它们同样采样了图5所示的模型结构.

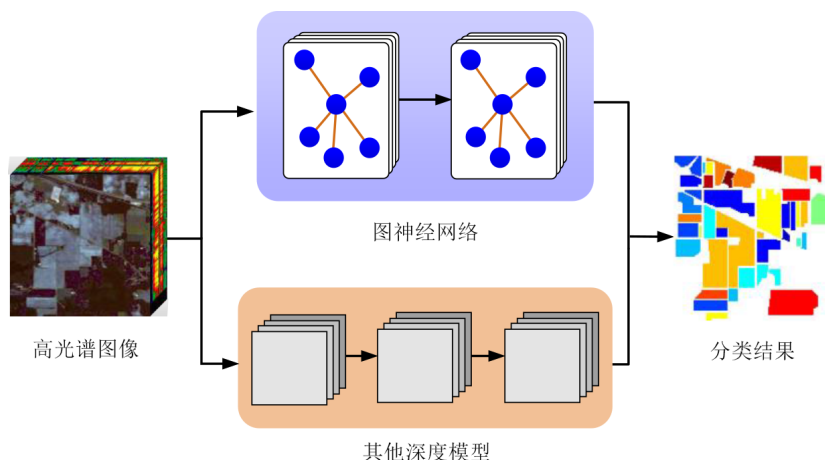


图5 “并行式”模型融合范式的结构示意图

尽管借助“并行式”模型融合范式能够引入不同类型的空谱信息,但如何确定不同子模型在融合中的权重仍是此类方法的主要难点之一. 为了避免费力地寻找最优的模型融合权重,研究者提出了“串行式”模型融合范式,即不同子模型通过前后相连的方式进行组合. 根据图神经网络位置的不同,此类算法目前可以大致被分为如图6所示的3种类型. 基于图6(a)的结构,

$Li$ 等<sup>[83]</sup>设计了 $GSANet$ 算法. 该算法首先利用卷积神经网络提取图像的局部空谱特征,随后借助图卷积网络来进一步捕捉高光谱图像的空间结构信息. 在 $GSANet$ 算法中,卷积神经网络生成的局部空谱特征能为图神经网络提供更准确的像素间关联信息. 同时,图神经网络有利于缓解卷积神经网络在类别边界区域表现不佳的问题,两种模型协同运作,有效提高了算法在高光谱

图像分类任务中的性能. 类似地,“串行式”模型融合范式也被S<sup>2</sup>RGANet算法<sup>[95]</sup>所采用. 与GSANet身份不同,在S<sup>2</sup>RGANet算法中,卷积神经网络仅被用于提取图像中的光谱信息,而空间结构信息主要由图神经网络刻画,这一做法有效缓解了固定卷积核在类别边界区域中的局限性. 由于引入了卷积神经网络模型,GSANet和S<sup>2</sup>RGANet算法往往需要大量的有标签样本指导模型训练. 考虑到标签信息在高光谱图像中的稀缺性,Sellami等<sup>[93]</sup>提出了MV-DNNet算法. 该算法将卷积神经网络替换为自编码器,从而仅利用图像的原始信息即可自动地提取空谱特征,极大地降低了模型对标签的依赖. 不同于图6(a)的结构,Hu等<sup>[102]</sup>在EGNN算法中基于图6(b)的结构提出了另一种“串行式”模型. 其中,图神经网络和卷积神经网络先后被用于提取粗粒度的区域级特征和细粒度的像素级特征,有效保留了高光谱图像不同层级的光谱信息. 此外,基于图6(c)的结构,Liu等<sup>[88]</sup>将卷积神经网络同时被用于算法的前处

理和后处理步骤,以进行像素级的特征融合操作,从而避免了复杂度较高的像素级图卷积操作,一定程度上提高了算法的运行效率. 图6展示了“串行式”模型融合范式常用的几种结构,总的来讲,当高光谱图像中的地物分布较为复杂时,直接使用卷积神经网络可能会导致部分类别边界信息的缺失. 因此,可以借助图6(a)的结构,即首先使用图神经网络模型来捕捉复杂多变的类别边界信息,再利用卷积神经网络等模型提取图像的高阶空谱特征;而当图像中的地物区域较为平整时,使用图6(b)的结构有利于构建一个更准确的图结构,从而能够有效增强图神经网络的表征能力;与上述两种结构相比,图6(c)的结构虽然较为复杂,但它不仅可以更细致地刻画像素的局部空谱信息,而且能够避免复杂度较高的像素级图卷积操作. 需要说明的是,图6仅展示了当前高光谱图像分类方法中最常被使用的3种网络结构. 理论上,不同的深度模型可以通过多次交叉组合的方式得到更多类型的网络结构.




图6 3种“串行式”模型融合范式的结构示意图

表5对高光谱图像分类任务中图神经网络算法的架构类型进行了具体的分类. 可以发现,在混合型架构中,“串行式”模型融合范式的使用频率相对较高. 这主

要是因为并行化的模型结构需要同时计算多种深度模型的运算结果,所以空间复杂度往往较高;同时,在“并行式”模型融合范式中,不同模型的组合形式相对单

一,一定程度上限制了算法的灵活性;此外,往往需要手动确定每个子模型在“并行式”融合中的权重,这在实际使用中是一项较为困难的工作.而在“串行式”模

型融合范式中,图神经网络能够与其他深度模型以多种顺序灵活地组合,保证了算法在不同类型高光谱图像中的有效性.

表5 高光谱图像分类任务中,图神经网络的模型架构

图神经网络架构类型		文献	优点	局限性
单一型		文献[22], [43], [47], [48], [50], [73], [74], [75], [79], [80], [81], [86], [87], [89], [92], [94], [96], [97], [98], [100], [101], [51], [103], [104], [105]	结构简单,训练难度低	无法直接提取多尺度和高阶空谱信息,灵活性较差
混合型	串行式	文献[72], [76], [78], [83], [84], [88], [90], [91], [93], [95], [102],	灵活性强,可针对目标图像调整模型结构	复杂度较高,模型训练难度较大
	并行式	文献[23], [52], [77], [82], [99]	能够直接融合不同类型的空谱特征	复杂度高,模型训练难度大,需要手动调节子模型的权重

#### 4.4 模型优化策略

与卷积神经网络等其他深度模型类似,图神经网络的模型优化方式主要分为两种.第一种方式为全批量梯度下降,这种优化方法会遍历所有样本计算一次损失函数,然后根据各个参数对应的梯度来更新模型参数.基于谱域的图卷积神经网络一般采用此类优化方法,如S<sup>2</sup>GCN<sup>[47]</sup>、MDGCN<sup>[43]</sup>、CAD-GCN<sup>[22]</sup>等.由于每一次的参数更新都会涉及所有样本,因此,全批量梯度下降法的时间和空间复杂度通常较高.尤其当高光谱图像的像素/超像素数量较多时,图神经网络模型训练的效率往往非常低.

为了改善图神经网络模型训练的效率,Hong等<sup>[52]</sup>在miniGCN算法中首次提出利用小批量梯度下降法来优化图神经网络的参数.具体来讲,在模型训练的每个循环中,miniGCN从原始图数据中随机采样多个子图,

并分别计算相应的损失,再根据梯度更新模型参数.因为每个子图的规模相比于原始图结构小了很多,所以miniGCN的训练效率明显高于全批量梯度下降法.受miniGCN启发,S<sup>2</sup>RGANet<sup>[95]</sup>、DGCN<sup>[84]</sup>等算法也采用了类似的优化方式,有效提高了高光谱图像分类任务中图神经网络的训练效率.

表6根据优化策略对当前基于图神经网络的高光谱图像分类方法进行了归纳.可以发现,使用全批量梯度下降策略的方法占据了主流.本文推测.这可能是因为高光谱图像分类任务中的图神经网络模型主要是谱域图卷积神经网络,而这类模型通常只能使用全批量梯度下降策略进行参数优化.同时,当前方法大多基于超像素建立图结构,因而图的尺寸相对较小,这大大降低了全批量梯度下降策略对显存的消耗.因此,全批量梯度下降策略目前被大多数研究者所采用.

表6 高光谱图像分类任务中,图神经网络的优化策略

优化策略	文献	优点	局限性
全批量梯度下降	文献[22], [43], [47], [48], [50], [51], [72], [73], [74], [75], [76], [78], [79], [81], [83], [86], [87], [88], [89], [90], [91], [94], [98], [99], [100], [101], [102], [103], [104], [105]	训练速度快,模型优化稳定	显存需求高,无法用于大规模高光谱数据,可能影响模型的泛化能力
小批量梯度下降	文献[23], [52], [77], [80], [82], [84], [92], [93], [95], [96], [97]	显存需求低,可用于大规模高光谱数据	训练速度慢,模型可能难以收敛

## 5 常用开源方法对比

本节首先介绍几种基于图神经网络的开源高光谱图像分类方法.随后,为了更直观地展示不同方法的分类效果,本节对比并分析了使用不同方法得到的实验结果.

### 5.1 常用开源方法简介

近年来,深度学习理论和应用的发展非常迅速,各

种功能强大的开发工具也层出不穷,例如Caffe<sup>[107]</sup>、TensorFlow<sup>[108]</sup>、PyTorch<sup>[109]</sup>等.基于这些工具,研究者可以相对轻松地设计用于高光谱图像分类的图神经网络模型.表7总结了当前用于高光谱图像分类任务的几种主流的图神经网络开源代码,包括MDGCN<sup>[43]</sup>、miniGCN<sup>[52]</sup>等.

### 5.2 常用分类方法的对比

为了进一步分析不同算法的特点,本节在Indian

表 7 用于高光谱图像分类任务的图神经网络开源工具

算法	发表时间	框架	链接
MDGCN <sup>[43]</sup>	2019 年	TensorFlow	<a href="https://github.com/LEAP-WS/MDGCN">https://github.com/LEAP-WS/MDGCN</a>
miniGCN <sup>[52]</sup>	2020 年	TensorFlow	<a href="https://github.com/danfenghong/IEEE_TGRS_GCIN">https://github.com/danfenghong/IEEE_TGRS_GCIN</a>
SSGPN <sup>[110]</sup>	2021 年	TensorFlow	<a href="https://github.com/B-Xi/IGARSS_2021_SSGPN">https://github.com/B-Xi/IGARSS_2021_SSGPN</a>
CEGCN <sup>[72]</sup>	2020 年	PyTorch	<a href="https://github.com/qichaoliu/CNN_Enhanced_GCIN">https://github.com/qichaoliu/CNN_Enhanced_GCIN</a>
WFCC <sup>[99]</sup>	2022 年	PyTorch	<a href="https://github.com/raglandman/WFCG">https://github.com/raglandman/WFCG</a>
X-GPN <sup>[81]</sup>	2022 年	TensorFlow	<a href="https://github.com/B-Xi/TNNLS_2022_X-GPN">https://github.com/B-Xi/TNNLS_2022_X-GPN</a>
MGLN <sup>[51]</sup>	2022 年	TensorFlow	<a href="https://github.com/LEAP-WS/MGLN">https://github.com/LEAP-WS/MGLN</a>

Pines, University of Pavia 和 Salinas 数据集上进行了充分的实验。其中, Indian Pines 数据集由机载可见/红外成像光谱仪传感器于 1992 年在印度西北部采集得到。该数据集包含 145×145 像素, 空间分辨率为 20 m, 涵盖了波长为 0.4~2.5 μm 的光谱通道; University of Pavia 数据集是由 ROSIS 传感器于 2001 年在意大利帕维亚大学拍摄获得, 该数据集有 610×340 个像素, 空间分辨率为 1.3 m, 包含了波长为 0.43~0.86 μm 的光谱通道; Salinas 数据集由 AVIRIS 传感器在加利福尼亚州 Salinas 山谷收集得到, 其包含 512×217 个像素, 空间分辨率为 3.7 m, 该数据集含有 204 维光谱通道。同时, 本节使用了 3 种常用的定量评价指标来比较不同算法的性能, 包括总体准确率 (Overall Accuracy, OA)、每类平均准确率 (Average Accuracy, AA) 和 Kappa 系数<sup>[5]</sup>。为了确保对比实验的公平性, 本节从每个类别中随机挑选 30 个有标签像素用作模型训练 (若数量不足 30, 则随机挑选 15 个像素), 而剩余像素被用来评估算法性能。

表 8~10 分别展示了不同算法在 Indian Pines, University of Pavia 和 Salinas 数据集上的定量结果。其中, 最优结果被加粗显示。图 7 展示了不同算法在 Indian

Pines 数据集上的分类图。观察表中结果可以发现, WFCC 算法在 Indian Pines 和 University of Pavia 数据集上都取得了最佳的分类结果, 这可能是因为该算法能够借助卷积神经网络和图注意力网络准确地捕捉图像的局部和全局空谱信息。不仅如此, 同样使用卷积神经网络和图神经网络两类模型的 CEGCN 算法在三组数据集中也取得了较为理想的分类结果, 一定程度上验证了“混合型”模型架构在高光谱图像分类任务中的优越性。同时, 尽管 MDGCN 算法仅使用图神经网络模型, 但其在 Indian Pines 和 Salinas 数据集上的分类精度与 CEGCN 算法十分接近, 这主要得益于多尺度图卷积机制的引入, 这有效强化了图神经网络在复杂地块中的表征能力。此外, 由于超像素级别的图卷积操作有利于保留高光谱图像的局部结构信息, 因此以超像素为节点建图的 MDGCN、CEGCN、WFCC 和 MGLN 算法通常能够取得相对更高的分类准确率, 并且此类算法的分类图也相对较为平整, 而 miniGCN、SSGPN 和 X-GPN 算法的分类图则含有较多的椒盐状错误。值得一提的是, 虽然 miniGCN 算法在分类准确率方面表现一般, 但得益于小批量梯度下降法的使用, 该算法在训练速度方面往往具备较大优势。

表 8 不同算法在 Indian Pines 数据集上的实验结果

指标	算法						
	MDGCN <sup>[43]</sup>	miniGCN <sup>[52]</sup>	SSGPN <sup>[110]</sup>	CEGCN <sup>[99]</sup>	WFCC <sup>[99]</sup>	X-GPN <sup>[81]</sup>	MGLN <sup>[51]</sup>
OA	93.47±0.38	73.45±1.34	89.31±2.03	93.62±1.65	<b>95.58±0.99</b>	92.83±3.17	94.27±0.92
AA	96.24±0.21	84.10±0.90	94.14±1.03	97.00±1.02	<b>97.64±0.39</b>	96.79±1.41	95.58±1.18
Kappa	92.55±0.43	69.92±1.51	87.83±2.30	92.71±1.89	<b>94.97±1.12</b>	91.88±3.57	93.46±1.04

表 9 不同算法在 University of Pavia 数据集上的实验结果

指标	算法						
	MDGCN <sup>[43]</sup>	miniGCN <sup>[52]</sup>	SSGPN <sup>[110]</sup>	CEGCN <sup>[99]</sup>	WFCC <sup>[99]</sup>	X-GPN <sup>[81]</sup>	MGLN <sup>[51]</sup>
OA	95.68±0.22	87.17±1.05	89.33±2.27	98.73±1.27	<b>99.20±0.34</b>	96.50±0.71	93.29±1.80
AA	93.15±0.28	88.26±0.57	90.87±1.20	99.16±0.38	<b>99.33±0.27</b>	97.06±0.61	92.33±0.67
Kappa	94.25±0.29	83.21±1.33	85.85±2.83	98.33±1.66	<b>99.09±0.39</b>	96.03±0.80	91.21±2.27

表 10 不同算法在 Salinas 数据集上的实验结果

指标	算法						
	MDGCN <sup>[43]</sup>	miniGCN <sup>[52]</sup>	SSGPN <sup>[110]</sup>	CEGCN <sup>[99]</sup>	WFCC <sup>[99]</sup>	X-GPN <sup>[81]</sup>	MGLN <sup>[51]</sup>
OA	97.25±0.87	87.38±1.34	91.08±1.67	97.80±0.65	97.78±1.02	95.96±1.15	<b>98.39±0.63</b>
AA	98.21±0.30	94.36±0.58	95.41±0.77	99.03±0.31	<b>99.04±0.37</b>	98.43±0.54	98.60±0.24
Kappa	96.94±0.96	85.99±1.48	90.06±1.86	97.55±0.73	97.53±1.13	95.51±1.28	<b>98.21±0.70</b>

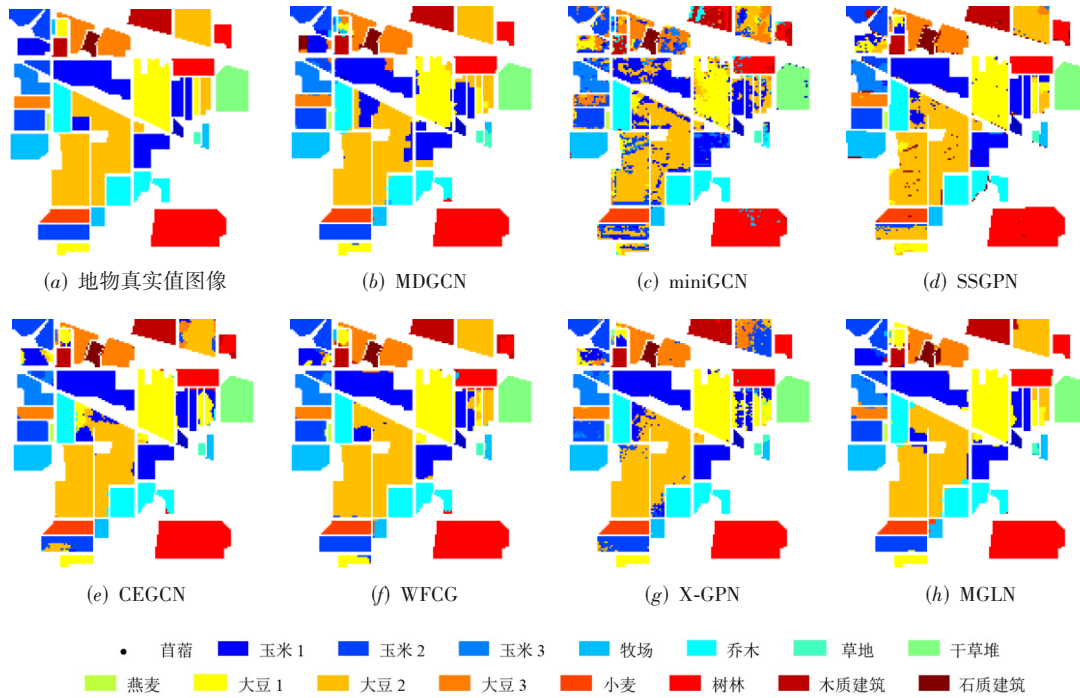


图 7 不同算法在 Indian Pines 数据集上的分类图

## 6 未来研究发现

尽管图神经网络模型已经在高光谱图像分类任务中取得了一定成果,但现有方法仍存在改进的空间。

### 6.1 邻域的构建

在图神经网络模型中,图的邻域结构对图卷积操作起着至关重要的作用.使用合适的邻域结构有利于准确捕捉节点间的关联信息,从而帮助模型学习到具备强大表征能力的节点特征.而在目前的图神经网络方法中,节点邻居往往通过手动的方式确定,这样可能会在图卷积的过程中引入一些无关信息或忽略部分有价值的信息,最终影响模型的表现.因此,如何让图神经网络根据高光谱图像不同区域的地物特性来自适应地确定邻域结构可能是未来值得研究的方向之一。

### 6.2 监督信息的挖掘

高光谱图像的标注工作依赖专家经验.因此,有标签像素的获取成本较高.当图像中有标签像素的数量较少时,有限的监督信息可能导致图神经网络模型无

法进行有效的学习,这制约着图神经网络方法分类性能的提高.近年来,以对比学习为代表的自监督学习方法在自然语言处理、计算机视觉等领域被广泛应用,这类方法旨在从大量的无标签样本中挖掘监督信息来辅助模型学习.因此,在未来的高光谱图像分类方法中,可以利用自监督理论来挖掘图像中丰富的监督信息,从而进一步改善图神经网络的分类表现,缓解因标签信息不足而造成的性能下降。

### 6.3 可伸缩性的权衡

当前,图神经网络模型在具备可伸缩性(scalability)的同时,无可避免地会破坏原始图数据的完整性.例如,在信息聚合的过程中使用随机采样可能会忽略包含重要信息的邻居节点.在高光谱图像中,无论长距离还是短距离像素间的关联信息都有助于改善分类结果.因此,保留图数据的完整性对模型学习至关重要.如何在增强模型可伸缩性与维持图数据完整性之间进行合理的权衡可能是未来值得研究的方向之一。

## 6.4 图像噪声的处理

在高光谱图像中,由于采集设备等因素的影响,不可避免地会存在多种类型的噪声.其中,包括光谱特征中的噪声和标签噪声.然而,当前的图神经网络模型大都无法有效抵御噪声的干扰,这可能会导致噪声信息逐渐传播至整个图中.解决此问题的一种思路是:在图卷积的过程中,利用拓扑结构来识别噪声,并抑制噪声信息在图中的传播.

## 6.5 模型深度

当前用于高光谱图像分类任务的图神经网络模型大都使用了浅层模型.当网络层数过大时,图神经网络由于过拟合现象,分类性能会明显下降.然而,多次的信息聚合操作有助于捕捉高光谱图像中的全局结构信息.因此,如何在维持图神经网络深度的同时,避免过平滑问题的影响,可能是一个潜在的研究方向.

## 7 结论

本文回顾了高光谱图像分类的研究背景和意义,简要介绍了基于图神经网络(主要为图卷积神经网络)的高光谱图像分类方法.同时,从图神经网络的不同模块等方面出发,对当前方法进行了归纳和总结,分析并对比了不同方法的特性.此外,本文还总结、对比并分析了当前经常被使用的开源方法.随着高光谱图像分类技术和图神经网络理论的发展,基于图神经网络的高光谱图像分类方法不断演变.但总体而言,这类方法大多存在如下共性特点.

(1)网络结构多分支化.在早期的基于图神经网络的高光谱图像分类方法中,网络模型较为简单,大都是单分支结构.然而,由于结构的单一化,单分支图神经网络模型往往无法满足性能进一步提升的需求,例如无法直接捕捉多尺度空谱信息.针对这种情况,多分支的图神经网络结构开始逐渐被用于高光谱图像分类任务,极大地增强了模型的灵活性,并使得模型能够从多种角度刻画高光谱图像中的多尺度空谱信息.不仅如此,模型中的不同分支可以被赋予不同的功能.例如,可以借助不同的网络分支分别进行图学习和节点表征的更新.总的来讲,尽管多分支结构可能会增加算法复杂度,但同时也为算法设计带来了更多的选择,并赋予图神经网络更大的潜力.

(2)图动态化.由于外界环境、采集设备等因素的干扰,高光谱图像数据可能包含一定的噪声.因此,直接基于原始高光谱图像数据建立的图结构可能无法准确反映像素/超像素间的关系.为缓解这一问题,近年来,动态图技术开始被用于图神经网络模型中,以改善

高光谱图像分类的效果.通过在模型训练过程中不断优化节点间的关联信息,原始高光谱数据中的噪声等干扰因素可以在一定程度上得到抑制.然而,如何进一步更新节点间的邻接关系是此类方法需要突破的难点之一.

(3)模型组合多元化.为了进一步改善基于图神经网络的高光谱图像分类方法的表现,越来越多的研究者开始使用多种网络模型组合的策略.例如,借助卷积神经网络对局部空谱特征进行预提取,再利用图神经网络捕捉高光谱图像中的长距离关联信息.值得注意的是,基于这种模型组合策略的方法正变得越来越多元化,不仅包括模型选择的多元化(如卷积神经网络、自编码器等),还包含组合方式的多元化(如串行式组合和并行式组合等).

## 参考文献

- [1] 黄鸿,王丽华,石光耀.面向高光谱遥感影像分类的监督多流形鉴别嵌入方法[J].电子学报,2020,48(6):1099-1107.  
HUANG H, WANG L H, SHI G Y. Supervised multi-manifold discriminant embedding method for hyperspectral remote sensing image classification[J]. Acta Electronica Sinica, 2020, 48(6): 1099-1107. (in Chinese)
- [2] 杜培军,夏俊士,薛朝辉,等.高光谱遥感影像分类研究进展[J].遥感学报,2016,20(2):236-256.  
DU P J, XIA J S, XUE Z H, et al. Review of hyperspectral remote sensing image classification[J]. Journal of Remote Sensing, 2016, 20(2): 236-256. (in Chinese)
- [3] KRUSE F A. Identification and mapping of minerals in drill core using hyperspectral image analysis of infrared reflectance spectra[J]. International Journal of Remote Sensing, 1996, 17(9): 1623-1632.
- [4] LOBO A, GARCIA E, BARROSO G, et al. Machine learning for mineral identification and ore estimation from hyperspectral imagery in tin-tungsten deposits: Simulation under indoor conditions[J]. Remote Sensing, 2021, 13(16): 3258.
- [5] 张号逵,李映,姜晔楠.深度学习在高光谱图像分类领域的研究现状与展望[J].自动化学报,2018,44(6):961-977.  
ZHANG H K, LI Y, JIANG Y N. Deep learning for hyperspectral imagery classification: The state of the art and prospects[J]. Acta Automatica Sinica, 2018, 44(6): 961-977. (in Chinese)
- [6] SUN W W, DU Q. Hyperspectral band selection: A review [J]. IEEE Geoscience and Remote Sensing Magazine,

- 2019, 7(2): 118-139.
- [7] DENG B, JIA S, SHI D M. Deep metric learning-based feature embedding for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(2): 1422-1435.
- [8] HARSANYI J C, CHANG C I. Hyperspectral image classification and dimensionality reduction: An orthogonal subspace projection approach[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1994, 32(4): 779-785.
- [9] MA K Y, CHANG C I. Kernel-based constrained energy minimization for hyperspectral mixed pixel classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-23.
- [10] 张绍泉, 黄志浩, 邓承志, 等. 光谱加权协同稀疏和全变差正则化高光谱图像解混[J]. *电子学报*, 2020, 48(12): 2453-2461.  
ZHANG S Q, HUANG Z H, DENG C Z, et al. Spectral reweighted collaborative sparsity and total variation based hyperspectral unmixing method[J]. *Acta Electronica Sinica*, 2020, 48(12): 2453-2461. (in Chinese)
- [11] HE Z, HU J, WANG Y W. Low-rank tensor learning for classification of hyperspectral image with limited labeled samples[J]. *Signal Processing*, 2018, 145: 12-25.
- [12] MA L, CRAWFORD M M, TIAN J W. Local manifold learning-based k-nearest-neighbor for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(11): 4099-4109.
- [13] 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.
- [14] OKWUASHI O, NDEHEDEHE C E. Deep support vector machine for hyperspectral image classification[J]. *Pattern Recognition*, 2020, 103: 107298.
- [15] 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.
- [16] 王国胜, 钟义信. 支持向量机的若干新进展[J]. *电子学报*, 2001, 29(10): 1397-1400.  
WANG G S, ZHONG Y X. Some new developments on support vector machine[J]. *Acta Electronica Sinica*, 2001, 29(10): 1397-1400. (in Chinese)
- [17] 刘建伟, 孙正康, 刘泽宇, 等. 核典型关联性分析相关特征提取与核逻辑斯蒂回归域自适应学习[J]. *电子学报*, 2016, 44(12): 2908-2915.  
LIU J W, SUN Z K, LIU Z Y, et al. Domain adaptation learning with kernel logistic regression and kernel canonical correlation analysis[J]. *Acta Electronica Sinica*, 2016, 44(12): 2908-2915. (in Chinese)
- [18] LI J, BIOUCAS-DIAS J M, PLAZA A. Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(11): 4085-4098.
- [19] GHAMISI P, MAGGIORI E, LI S T, et al. New frontiers in spectral-spatial hyperspectral image classification: The latest advances based on mathematical morphology, Markov random fields, segmentation, sparse representation, and deep learning[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2018, 6(3): 10-43.
- [20] 周浦城, 张杰, 薛模根, 等. 基于卷积分析稀疏表示和相位一致性的低照度图像增强[J]. *电子学报*, 2020, 48(1): 180-188.  
ZHOU P C, ZHANG J, XUE M G, et al. Low-light image enhancement based on convolutional analysis sparse representation and phase congruency[J]. *Acta Electronica Sinica*, 2020, 48(1): 180-188. (in Chinese)
- [21] 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*, 2019, 30(6): 1790-1802.
- [22] 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.
- [23] PU C Y, HUANG H, LUO L Y. Classification of hyperspectral image with attention mechanism-based dual-path convolutional network[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [24] TU B, ZHOU C L, LIAO X L, et al. Spectral-spatial hyperspectral classification via structural-kernel collaborative representation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(5): 861-865.
- [25] HE L, LI J, LIU C Y, et al. Recent advances on spectral-spatial hyperspectral image classification: An overview and new guidelines[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(3): 1579-1597.

- [26] 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.
- [27] 王宇, 陈殿仁, 沈美丽, 等. 基于形态学梯度重构和标记提取的分水岭图像分割[J]. *中国图象图形学报*, 2008, 13(11): 2176-2180.  
WANG Y, CHEN D R, SHEN M L, et al. Watershed segmentation based on morphological gradient reconstruction and marker extraction[J]. *Journal of Image and Graphics*, 2008, 13(11): 2176-2180. (in Chinese)
- [28] GU Y F, LIU T Z, JIA X P, et al. Nonlinear multiple kernel learning with multiple-structure-element extended morphological profiles for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(6): 3235-3247.
- [29] BENEDIKTSSON J A, PALMASON J A, SVEINSSON J R. Classification of hyperspectral data from urban areas based on extended morphological profiles[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(3): 480-491.
- [30] LI J J, XI B B, LI Y S, et al. Hyperspectral classification based on texture feature enhancement and deep belief networks[J]. *Remote Sensing*, 2018, 10(3): 396.
- [31] BHATTI U A, YU Z Y, CHANUSSOT J, et al. Local similarity-based spatial-spectral fusion hyperspectral image classification with deep CNN and Gabor filtering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-15.
- [32] 刘小波, 刘鹏, 蔡之华, 等. 基于深度学习的光学遥感图像目标检测研究进展[J]. *自动化学报*, 2021, 47(9): 2078-2089.  
LIU X B, LIU P, CAI Z H, et al. Research progress of optical remote sensing image object detection based on deep learning[J]. *Acta Automatica Sinica*, 2021, 47(9): 2078-2089. (in Chinese)
- [33] 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.
- [34] FANG L Y, LIU Z L, SONG W W. Deep hashing neural networks for hyperspectral image feature extraction[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(9): 1412-1416.
- [35] CHEN Y S, LIN Z H, ZHAO X, et al. Deep learning-based classification of hyperspectral data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2094-2107.
- [36] MOU L C, GHAMISI P, ZHU X X. Deep recurrent neural networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(7): 3639-3655.
- [37] 魏钰轩, 陈莹. 基于自适应层信息熵的卷积神经网络压缩[J]. *电子学报*, 2022, 50(10): 2398-2408.  
WEI Y X, CHEN Y. Convolutional neural network compression based on adaptive layer entropy[J]. *Acta Electronica Sinica*, 2022, 50(10): 2398-2408. (in Chinese)
- [38] YU S Q, JIA S, XU C Y. Convolutional neural networks for hyperspectral image classification[J]. *Neurocomputing*, 2017, 219: 88-98.
- [39] JIA P Y, ZHANG M, YU W B, et al. Convolutional neural network based classification for hyperspectral data[C]// 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Piscataway: IEEE, 2016: 5075-5078.
- [40] MAKANTASIS K, KARANTZALOS K, DOULAMIS A, et al. Deep supervised learning for hyperspectral data classification through convolutional neural networks[C]// 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Piscataway: IEEE, 2015: 4959-4962.
- [41] ZHANG H K, LI Y, ZHANG Y Z, et al. Spectral-spatial classification of hyperspectral imagery using a dual-channel convolutional neural network[J]. *Remote Sensing Letters*, 2017, 8(5): 438-447.
- [42] LEE H, KWON H. Going deeper with contextual CNN for hyperspectral image classification[J]. *IEEE Transactions on Image Processing*, 2017, 26(10): 4843-4855.
- [43] WAN S, GONG C, ZHONG P, et al. Multiscale dynamic graph convolutional network for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(5): 3162-3177.
- [44] WU Z H, PAN S R, CHEN F W, et al. A comprehensive survey on graph neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(1): 4-24.
- [45] 刘启超, 肖亮, 刘芳, 等. SSCDenseNet: 一种空-谱卷积稠密网络的高光谱图像分类算法[J]. *电子学报*, 2020, 48(4): 751-762.  
LIU Q C, XIAO L, LIU F, et al. SSCDenseNet: A spec-

- tral-spatial convolutional dense network for hyperspectral image classification[J]. *Acta Electronica Sinica*, 2020, 48(4): 751-762. (in Chinese)
- [46] KIPF T N, WELLING M. Semi-supervised classification with graph convolutional networks[C]//Proceedings of the International Conference on Learning Representations. Toulon: ICLR, 2017: 1-14.
- [47] QIN A Y, SHANG Z W, TIAN J Y, et al. Spectral-spatial graph convolutional networks for semisupervised hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(2): 241-245.
- [48] 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.
- [49] ZHANG S, TONG H H, XU J J, et al. Graph convolutional networks: A comprehensive review[J]. *Computational Social Networks*, 2019, 6(1): 1-23.
- [50] WAN S, PAN S R, ZHONG P, et al. Dual interactive graph convolutional networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-14.
- [51] WAN S, PAN S R, ZHONG S W, et al. Multi-level graph learning network for hyperspectral image classification[J]. *Pattern Recognition*, 2022, 129: 108705.
- [52] 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*, 2021, 59(7): 5966-5978.
- [53] SPERDUTI A, STARITA A. Supervised neural networks for the classification of structures[J]. *IEEE Transactions on Neural Networks*, 1997, 8(3): 714-735.
- [54] GORI M, MONFARDINI G, SCARSELLI F. A new model for learning in graph domains[C]//Proceedings of 2005 IEEE International Joint Conference on Neural Networks. Piscataway: IEEE, 2005: 729-734.
- [55] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. *IEEE Transactions on Neural Networks*, 2009, 20(1): 61-80.
- [56] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and locally connected networks on graphs[C]//Proceedings of the 2nd International Conference on Learning Representations. Banff: ICLR, 2014: 1-14.
- [57] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. New York: ACM, 2016: 3844-3852.
- [58] LI R Y, WANG S, ZHU F Y, et al. Adaptive graph convolutional neural networks[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2018, 32(1): 3546-3553.
- [59] ZHUANG C Y, MA Q. Dual graph convolutional networks for graph-based semi-supervised classification[C]//Proceedings of the 2018 World Wide Web Conference. New York: ACM, 2018: 499-508.
- [60] XU B B, SHEN H W, CAO Q, et al. Graph wavelet neural network[C]//Proceedings of the International Conference on Learning Representations. Vancouver: ICLR, 2019: 1-13.
- [61] MICHELI A. Neural network for graphs: A contextual constructive approach[J]. *IEEE Transactions on Neural Networks*, 2009, 20(3): 498-511.
- [62] BACCIU D, ERRICA F, MICHELI A. Contextual graph Markov model: A deep and generative approach to graph processing[C]//Proceedings of the 35th International Conference on Machine Learning. Stockholm: IMLS, 2018: 294-303.
- [63] ATWOOD J, TOWSLEY D. Diffusion-convolutional neural networks[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. New York: Curran Associates Inc., 2016: 2001-2009.
- [64] TRAN D V, NAVARIN N, SPERDUTI A. On filter size in graph convolutional networks[C]//2018 IEEE Symposium Series on Computational Intelligence (SSCI). Piscataway: IEEE, 2019: 1534-1541.
- [65] ZHU X J. Semi-Supervised Learning Literature Survey [R]. Madison: University of Wisconsin-Madison, 2005.
- [66] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: Curran Associates Inc., 2017: 1025-1035.
- [67] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: Curran Associates Inc., 2017: 6000-6010.
- [68] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al.

- Graph attention networks[C]//Proceedings of the International Conference on Learning Representations. Vancouver: ICLR, 2018: 1-12.
- [69] MONTI F, BOSCAINI D, MASCI J, et al. Geometric deep learning on graphs and manifolds using mixture model CNNs[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2017: 5425-5434.
- [70] GILMER J, SCHOENHOLZ S S, RILEY P F, et al. Neural message passing for Quantum chemistry[C]//Proceedings of the 34th International Conference on Machine Learning. Sydney: JMLR.org, 2017: 1263-1272.
- [71] WANG X L, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 7794-7803.
- [72] 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.
- [73] DING Y, ZHAO X F, ZHANG Z L, et al. Graph sample and aggregate-attention network for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [74] BAI J, DING B X, XIAO Z, et al. Hyperspectral image classification based on deep attention graph convolutional network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-16.
- [75] DING Y, GUO Y Y, CHONG Y W, et al. Global consistent graph convolutional network for hyperspectral image classification[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-16.
- [76] MA Z T, JIANG Z G, ZHANG H P. Hyperspectral image classification using feature fusion hypergraph convolution neural network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-14.
- [77] LIU S Y, CAO Y, WANG Y B, et al. DFL-LC: Deep feature learning with label consistencies for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 3669-3681.
- [78] ZUO X B, YU X C, LIU B, et al. FSL-EGNN: Edge-labeling graph neural network for hyperspectral image few-shot classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-18.
- [79] DING Y, CHONG Y W, PAN S M, et al. Spatial-spectral unified adaptive probability graph convolutional networks for hyperspectral image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(7): 3650-3664.
- [80] GUO F M, LI Z W, XIN Z Q, et al. Dual graph U-nets for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 8160-8170.
- [81] XI B B, LI J J, LI Y S, et al. Semisupervised cross-scale graph prototypical network for hyperspectral image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, DOI: 10.1109/TNNLS.2022.3158280.
- [82] LIU Q W, DONG Y N, ZHANG Y X, et al. A fast dynamic graph convolutional network and CNN parallel network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-15.
- [83] LI W, WANG J J, GAO Y H, et al. Graph-feature-enhanced selective assignment network for hyperspectral and multispectral data classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-14.
- [84] HE X, CHEN Y S, GHAMISI P. Dual graph convolutional network for hyperspectral image classification with limited training samples[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-18.
- [85] ACHANTA R, SHAJI A, SMITH K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274-2282.
- [86] DING Y, ZHAO X F, ZHANG Z L, et al. Multiscale graph sample and aggregate network with context-aware learning for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 4561-4572.
- [87] DING Y, ZHAO X F, ZHANG Z L, et al. Semi-supervised locality preserving dense graph neural network with ARMA filters and context-aware learning for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-12.
- [88] LIU Q C, XIAO L, YANG J X, et al. Multilevel superpixel structured graph U-nets for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-15.

- [89] JIA S, JIANG S G, ZHANG S Y, et al. Graph-in-graph convolutional network for hyperspectral image classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, DOI: 10.1109/TNNLS.2022.3182715.
- [90] CHEN J, JIAO L C, LIU X, et al. Automatic graph learning convolutional networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-16.
- [91] SHAHRAKI F F, PRASAD S. Graph convolutional neural networks for hyperspectral data classification[C]//2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Piscataway: IEEE, 2019: 968-972.
- [92] YANG P, TONG L, QIAN B, et al. Hyperspectral image classification with spectral and spatial graph using inductive representation learning network[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 14: 791-800.
- [93] SELLAMI A, TABBONE S. Deep neural networks-based relevant latent representation learning for hyperspectral image classification[J]. *Pattern Recognition*, 2022, 121: 108224.
- [94] WANG H Y, CHENG Y H, PHILIP CHEN C L, et al. Semisupervised classification of hyperspectral image based on graph convolutional broad network[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 2995-3005.
- [95] XU K J, ZHAO Y, ZHANG L M, et al. Spectral-spatial residual graph attention network for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [96] PU S, SONG Y, CHEN Y, et al. Hyperspectral image classification with localized spectral filtering-based graph attention network[J]. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2022, 3: 155-161.
- [97] CAI W W, WEI Z G. Remote sensing image classification based on a cross-attention mechanism and graph convolution[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [98] SHA A S, WANG B, WU X F, et al. Semisupervised classification for hyperspectral images using graph attention networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(1): 157-161.
- [99] 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.
- [100] YANG B, CAO F L, YE H L. A novel method for hyperspectral image classification: Deep network with adaptive graph structure integration[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-12.
- [101] QU J H, XU Y S, DONG W Q, et al. Dual-branch difference amplification graph convolutional network for hyperspectral image change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-12.
- [102] HU H J, YAO M L, HE F, et al. Graph neural network via edge convolution for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [103] ZHAO X F, NIU J H, LIU C T, et al. Hyperspectral image classification based on graph transformer network and graph attention mechanism[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [104] CHEN R, LI G H, DAI C L. DRGCN: Dual residual graph convolutional network for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [105] ZHANG H Y, ZOU J Q, ZHANG L P. EMS-GCN: An end-to-end mixhop superpixel-based graph convolutional network for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-16.
- [106] WANG Y, SUN Y B, LIU Z W, et al. Dynamic graph CNN for learning on point clouds[J]. *ACM Transactions on Graphics*, 38(5): 146.
- [107] JIA Y Q, SHELHAMER E, DONAHUE J, et al. Caffe: Convolutional architecture for fast feature embedding [C]//Proceedings of the 22nd ACM international conference on Multimedia. New York: ACM, 2014: 675-678.
- [108] ABADI M, BARHAM P, CHEN J M, et al. TensorFlow: A system for large-scale machine learning[C]//Proceedings of the 12th USENIX conference on Operating Systems Design and Implementation. Berkeley: USENIX Association, 2016: 265-283.
- [109] PASZKE A, GROSS S, MASSA F, et al. PyTorch: An imperative style, high-performance deep learning library [C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. New York: Curran Associates Inc., 2019: 8026-8037.

- [110] XI B B, LI J J, LI Y S, et al. Semi-supervised graph prototypical networks for hyperspectral image classification [C]//2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS. Piscataway: IEEE, 2021: 2851-2854.

#### 作者简介



万 升 男,1993年生,江苏扬州人.南京理工大学计算机科学与工程学院博士研究生.主要研究方向为图机器学习和高光谱遥感图像分类.



杨 健 男,1973年生,江苏徐州人.南京理工大学教授、博士生导师.主要研究方向为模式识别、计算机视觉、机器学习.



宫 辰(通讯作者) 男,1988年生,安徽淮南人.南京理工大学教授、博士生导师.主要研究方向为机器学习、计算机视觉.