

高光谱遥感影像半监督分类研究进展

杨星^{1,2}, 方乐缘^{1,2}, 岳俊³

1. 湖南大学 电气与信息工程学院, 长沙 410080;
2. 鹏城实验室, 深圳 518055;
3. 中南大学 自动化学院, 长沙 410083

摘要: 随着高光谱遥感技术的迅猛发展和应用需求的不断增加, 高光谱遥感影像分类成为领域的研究热点。尽管监督学习已在高光谱遥感影像分类中取得了不错的效果, 但在许多情况下, 获取大规模标记样本来训练监督分类算法是困难和昂贵的。因此, 利用半监督分类技术对高光谱遥感影像精准分类是一项重要的研究内容。本文首先简要介绍了高光谱遥感影像发展现状和部分应用场景。其次, 本文对近年来高光谱遥感影像半监督分类研究的进展进行了综述, 着重讨论了低密度分割法、生成式模型、基于分歧(差异)的方法和基于图的方法四种典型半监督分类方法的关键技术和优劣。最后, 进一步讨论了半监督分类技术的潜力, 为今后研究工作的优化提供思路。

关键词: 高光谱遥感影像, 半监督分类, 低密度分割法, 生成式模型, 图神经网络

中图分类号: TP701/P2

引用格式: 杨星, 方乐缘, 岳俊. 2024. 高光谱遥感影像半监督分类研究进展. 遥感学报, 28(1): 20-41

Yang X, Fang L Y and Yue J. 2024. Advances in semi-supervised classification of hyperspectral remote sensing images. National Remote Sensing Bulletin, 28(1):20-41[DOI:10.11834/jrs.20243404]

1 引言

高光谱遥感(Hyperspectral Remote Sensing)及其应用已有数十年的历史, 随着不断发现光谱内的地物特性, 极大地增加了该技术的重要性, 使得高光谱遥感成为21世纪最重要的研究方向之一(童庆禧等, 2006)。高光谱遥感影像HSI(Hyperspectral Image)是成像光谱仪在电磁波谱的紫外、可见光、近红外和中红外区域, 获得大量光谱连续且光谱分辨率较高的图像数据(杜培军等, 2016)。HSI包含了丰富的空间、辐射和光谱三重信息, 其中每个像素可以被视为包含特定波长下材料光谱反射率的向量(张良培和张立福, 2005)。该光谱反射率为HSI中每个像素创建了唯一的光谱特征, 该光谱特征可用于识别地球表面上的各种材料(Rasti等, 2020)。高光谱遥感影像分类是高光谱遥感影像处理和应用中至关重要的一个环节(张达和郑玉权, 2013; Bioucas-Dias等,

2013), 然而其物理材料的多样性、光谱相似性和类内变异性使得图像复杂度增大, 其分类任务仍存在诸多挑战(张良培等, 2014)。

近年来, 许多监督学习的机器学习、深度学习算法被引入高光谱遥感影像分类任务中, 并取得了良好的分类效果(Sabale和Jadhav, 2015; Hong等, 2022)。但这些监督学习算法需要大量有标签样本对网络进行训练, 而且随着网络深度加深, 其需要训练的参数越多, 训练过程中需要的有标签样本也就更多。当有标签样本数量较少时, 这些监督学习的HSI分类算法很容易发生过拟合, 即其在训练数据集上表现较好, 但在测试数据集上表现却较差(Li等, 2019)。但是在许多实际高光谱遥感影像分类场景下, 获取足够的标记数据是非常困难的。其主要原因是高光谱图像的样本标记往往需要专家知识和经验, 因此样本标记的成本较高。其次, 随着科技、遥感设备的发展,

收稿日期: 2023-09-19; 预印本: 2023-11-19

基金项目: 国家自然科学基金(编号:U22B2014,62101072);湖南省自然科学基金(编号:2021JJ40570)

第一作者简介: 杨星, 研究方向为高光谱遥感图像分析。E-mail: hnuyangx@hnu.edu.cn

通信作者简介: 岳俊, 研究方向为遥感图像处理。E-mail:junyue@csu.edu.cn

高光谱图像的空间分辨率随之变高, 对一幅高光谱图像中所有像元进行标注较为困难, 往往需要实地考察才能确定像元对应类别。因此如何能在大量的高光谱像元中仅仅标注少量的高光谱像元的情况下训练一个深度模型是非常值得研究的一件事情。

无监督学习使用聚类或最大似然方法, 根据数据的相似性对数据进行聚类。这种方法的主要缺点是不能准确地聚类未知数据, 不能有效地确定其聚类类别与真实类别之间的关系。近年来, 预训练-微调的框架在得到了广泛的关注。预训练过程首先通过自监督学习从无标签数据中创建“虚拟”标签, 然后使用这些“虚拟”标签预训练一个特征提取网络, 比如自编码网络, 堆栈式自编码网络等 (Zhao 等, 2021), 训练过程通过优化重建损失来优化网络参数。微调过程则是在预训练好的特征提取网络后加上一个分类器, 在有标签数据上训练分类器网络。这种自监督学习的优势在于不需要人为标注的数据, 可以利用大量未标记数据进行自主训练, 提高模型性能。然而, 预训练任务和下游任务往往存在差异 (语义、任务难度等), 由此带来两者学习之间的竞争, 甚至预训练结果更差。其次, 这些方法将无监督训练与有监督训练分离, 仅在预训练中使用无标签样本来初始化, 并不能在分类训练过程中去促进整个网络得到更好的分类结果, 所以不是严格意义上的半监督分类。

半监督分类同时使用有标签数据和无标签数据来构建分类算法模型, 其中包含较小数量的有标签样本和大量的无标签样本作为训练数据 (Zhou 等, 2018)。半监督分类方法是基于相同类别的标记样本和无标记样本在特征空间上更为接近的假设, 由于大量的无标记样本能更加完整的描述数据整体特征, 所以使用全部数据训练的模型具有更好的泛化能力 (Padmanabha Reddy 等, 2018)。按照统计学习理论差异, 半监督分类可以分为: 归纳式学习和转导学习 (也称为直推学习) (transductive learning) (Wechsler 等, 2004)。转导学习处理整个样本空间中所有给定和未知的数据, 不仅预测训练数据中无标签样本的类标签, 更主要的是预测未知测试样本的类标签 (典型如标签传播算法)。归纳学习则只处理样本空间内给定的训练数据, 利用训练数据中有类标签的样本和无

类标签的样例进行训练, 仅预测训练数据中无类标签样例的类标签。半监督分类广泛应用于工业 (Cao 等, 2022; Long 等, 2023; Yang 等, 2021a)、文本处理 (Gao 等, 2021; Zhao 等, 2022a; Zhou 等, 2022a)、医学分析 (Lopes 等, 2022; Zhou 等, 2022b; Flores 等, 2022)、农业等多种领域。近年来, 高光谱遥感影像半监督分类研究取得了令人瞩目的进展。研究者们提出了许多创新的算法和技术, 以应对数据标注不足的问题。本文对近年来高光谱遥感影像半监督分类研究的进展进行了综述, 着重讨论了关键技术和方法。

2 高光谱遥感影像现状

2.1 高光谱遥感国内外发展

自 20 世纪 80 年代初, 美国宇航局喷气推进实验室提出光谱成像仪新概念后, 率先研制出第一代航空光谱成像仪 (AIS-1) (Goetz 等, 1985)。其后, 又成功研制第二代高光谱成像仪: 航空可见光/红外光成像仪 (AVIRIS) (Green 等, 1998), 是最常用的航空光谱仪之一 (刘银年, 2021)。

第三代为克里斯特里尔傅里叶变换高光谱成像仪 (FTHSI), 其重量仅为 35 kg (袁迎辉和林子瑜, 2007), 光谱分辨率为 2—10 nm, 可适用于轻型飞机 (唐绍凡 等, 2019)。在 1982 年到 2000 年期间, 许多国家相继开始研究成像光谱仪, 如: 加拿大的荧光成像光谱仪 FLI (Fluorescence Line Imager) (Gower 等, 1988)、小型机载光谱成像仪 CASI (Compact Airborne Spectrographic Imager) (McFee 等, 1997), 德国的机载反射光学光谱成像仪 ROSIS (Reflective Optics Spectrographic Imaging System) (Kunkel 等, 1991)。目前, 高光谱成像技术得到了广泛的商用化, 如: 澳大利亚 HyVista 公司研制的机载高光谱扫描仪 HyMap (Lucas 等, (2008)), 美国 HaedWall 公司研发的 Nano-Hyperspec、Micro-Hyperspec Ext-VNIR 等系列产品 (Yuen 和 Richardson, 2010), 芬兰的 Specim 公司研发的 Specim ImSpector 光谱仪 (Jan 等, 2008)。

国内于 20 世纪 80 年代中后期开始成像光谱仪的研制工作, 目前已跻身国际先进行列 (童庆禧 等, 2016)。主要成果包括稳态大视场偏振干涉成像光谱仪 (SLPIIS) (杜娟 等, 2008), 推扫式成像光谱仪 (PHI) 系列 (徐力智, 2020)、实用

模块化成像光谱仪（OMIS）系列（刘银年等，2002），高分辨率成像光谱仪（C-HRIS）（禹秉熙，2000）等多种类型。2002年“神州”三号飞船携带中分辨率成像光谱仪发射升空，这使中国成为世界上第二个拥有航天成像光谱仪的国家（黄意玢等，2006）。此外，高分五号卫星（GF-5）于2018年成功发射，是世界首颗实现对大气和陆地综合观测的全谱段高光谱卫星（龚燃，2018）。国内商业遥感卫星较有名的包括欧比特“珠海一号”高光谱卫星（李先怡等，2019），目前已完成8颗高光谱卫星组网。此外，由未来宇航联合高校院所、国有企业及商业航天企业共同发起的“未来碳星计划”预期于2023年完成研制并发射，该计划是全球首个基于高光谱碳监测的商业卫星星座。

2.2 高光谱遥感应用研究

自20世纪80年代初以来，利用光谱成像仪进行地质遥感一直是一个活跃的研究领域，迄今为止，国际上已有许多光谱成像仪广泛应用于各种高光谱遥感场景，如国土资源调查、农林遥感、城市环境检测等多个领域。

通过遥感的方式获取土地利用、矿产资源勘查等国土资源信息，可以大大减少所需要的人力物力和时间。在土地利用监测方面，文献（Chaudhri等，2019）基于HSI对农业和城市亚类进行分类；Chen等（2022c）通过高分五号采集高光谱数据集，并应用于复杂土地覆盖分类；研究者们还将高光谱图像用于土地覆盖制图和变化检测（Crowson等，2019；Xu等，2019）；Li等（2022a）使用高光谱描述城市管理的建成区，并用所提出的深度学习模型检测其变化。此外，高光谱遥感相比普通遥感有更高的光谱分辨率，因此可以实现对不同矿物元素的精细化探测（Rajesh，2004）。数个研究均证明了高光谱遥感在识别矿物资源的潜力，Tripathi和Garg（2023）通过研究印度地质区域，为矿物识别提供了多种有效方法。除此之外，HSI还被广泛应用于自然灾害（Modzelewska等，2020）、湖泊海洋检测（Grotte等，2022）等。

在农林遥感方面，高光谱遥感可以提供土壤属性、农作物生长情况以及其他收获和决策的有用和可操作的信息（Meng等，2020）。土壤有机质

是评价农田管理的关键变量，Zhang等（2013）利用高光谱遥感影像预测了美国和西班牙部分地区的土壤有机质、总磷、总氮、总碳和粘土含量；Meng等（2021）和刘雯等（2023）利用GF-5卫星分别预测了黑龙江省土壤有机质含量和矿区周边突然类型。Laban等（2018）从Sentinel-2卫星采集了埃及同一农业季节的高光谱遥感图像，并用深度卷积神经网络研究季节性土地覆盖和作物分类。Li等（2020b）提出一种混合CNN和transformer的架构，用于加州中部地区的作物分类。Bharathi等（2022）将HSI用于土壤和作物测绘制图。Pryzant等（2017）中提出了一个利用高光谱卫星图像和深度特征学习来预测埃塞俄比亚小麦真菌爆发的框架。Mu等（2019）中提出了一种利用CNN从多时间远程图像中估计冬小麦产量的方法。除此之外，研究者们还将高光谱遥感用于作物植被分类（Laliberte等，2011）、生长情况监测（Sandino等，2018）、疾病检测（Abdulridha等，2020）、森林生物量分析和树种鉴定（Modzelewska等，2020）等。

在城市环境检测方面，高光谱遥感连续的光谱曲线为识别光谱特征和检索不同的水质、大气参数提供了机会。Cai等（2022a）使用高光谱遥感采集珠江三角洲中山市河流区域数据，并用机器学习算法来评价城市河流综合水质。Zhang等（2022b）提出一种采用高光谱仪器无人机获取实时高分辨率遥感图像数据，从而动态监测城市水质。Cai等（2023）则利用高光谱数据对城市水污染源类型进行分类识别。而在大气成分监测方面，Elcoroaristizabal等（2021）结合HSI建立了定量分析大气颗粒物的方法，Zhou等（2023）通过HSI分析大气中甲烷浓度变化，其结果与实际测量结果一致。这些发现可以为城市环境治理、监管和监测等多方面提供真实可靠的数据。

3 高光谱影像半监督分类方法概述

高光谱遥感影像分类任务是高光谱遥感影像处理的一个重要分支，其目的是确定高光谱遥感影像中每一个像素对应的地物类别，在遥感影像分析中有着广泛的应用，包括精准农业（Khan等，2022），环境分析（Liu等，2022），城市调查（Cavalli，2021）等。在实际应用中，由于高光谱遥感影像样本的标记难以获取，而获得大量的未

标记样本十分简单 (Camps-Valls 等, 2007)。因此, 如何使用半监督分类方法提高高光谱遥感影像分类任务的准确度成为当前的研究热点 (Wang 等, 2014)。

自训练算法是最早利用半监督分类思想的算法, 到了 20 世纪 90 年代, Merz 等 (1992) 最早提出半监督学习的概念。随后, Joachims 等 (1999) 提出半监督支持向量机; Dempster 等 (1997) 将高斯混合模型和期望最大算法结合, 提出了生成式半监督分类方法。随着机器学习方法的发展,

Blum 等 (2004) 提出了最小割法 (Mincut), 首次将图论应用于解决 SSL 问题。此外, 研究者们提出标签传播算法 (Zhu 和 Ghahramani, 2002)、图神经网络 (Scarselli 等, 2005)、Tri-training (Zhou 和 Li, 2005)、Co-Forest (Li 和 Zhou, 2007) 等方法。近年来, 图卷积网络 (Kipf 和 Welling, 2017) 和半监督生成对抗网络 (Odena, 2016) 等方法均取得了良好的效果。图 1 展示了半监督分类算法的发展。

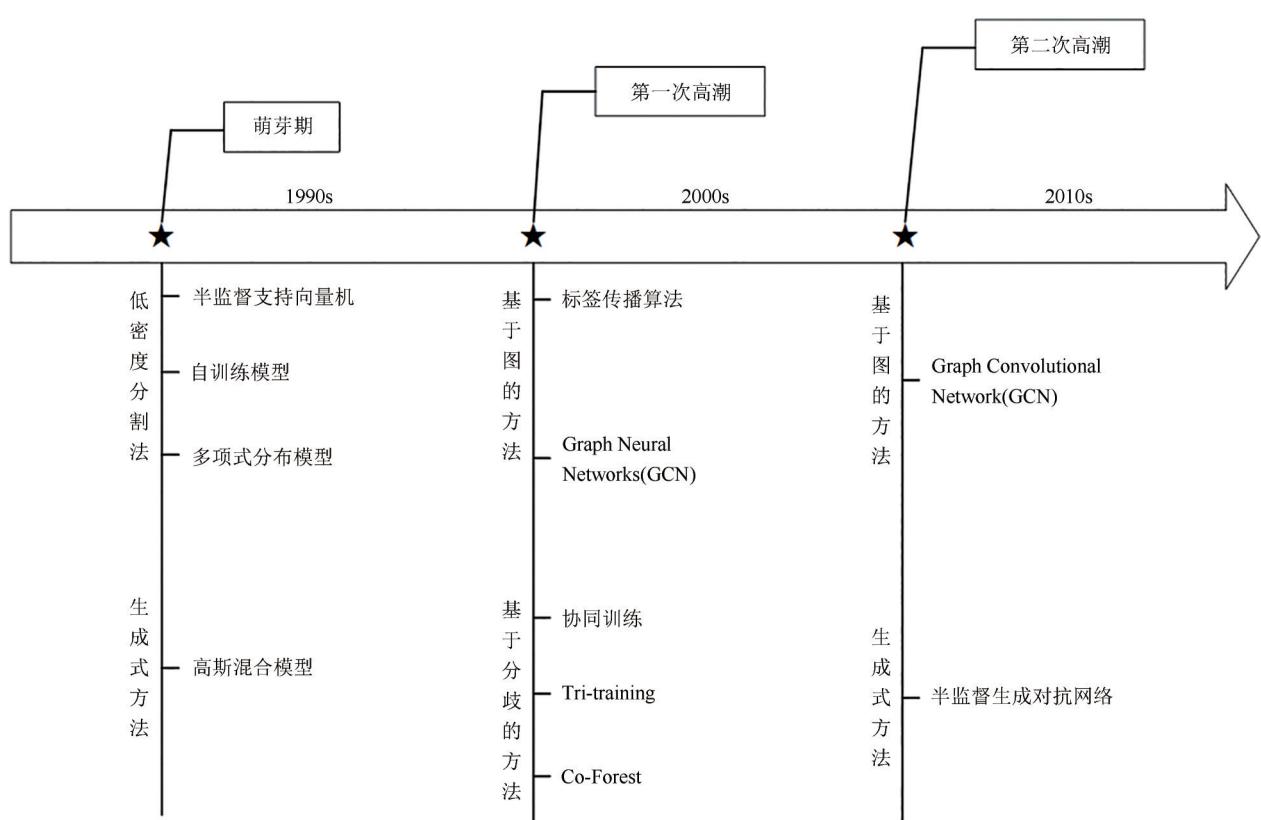


图 1 半监督分类算法发展脉络图

Fig. 1 Development of semi-supervised classification algorithm

半监督分类方法是基于相同类别的标记样本和未标记样本在特征空间上更为接近的假设 (Pise 和 Kulkarni, 2008), 在半监督分类中有 3 个常用的基本假设来建立预测样例和学习目标之间的关系 (梁吉业 等, 2009): 平滑假设 (Smoothness Assumption)、聚类假设 (Cluster Assumption) 和流形假设 (Manifold Assumption) (Zhu, 2008)。在高光谱遥感影像分类领域, 半监督分类方法主要包括低密度分割法、生成式方法、基于分歧 (差异) 的方法和基于图的方法, 其典型算法如图 2 所示。

3.1 低密度分割法

低密度分割法基于低密度分割假设, 其核心思想是: 尝试为无标签样本找到合适的标签, 使得超平面划分后的间隔最大化 (陶新民 等, 2020)。如图 3 所示, 红色和蓝色的点分别表示正负样本, 绿色的点表示无标签样本, 橘红色区域中即为低密度区域, 低密度分割法的决策边界应位于该区域中。典型的低密度分割法就是自训练算法和转导学习方法, 如表 1 所示。

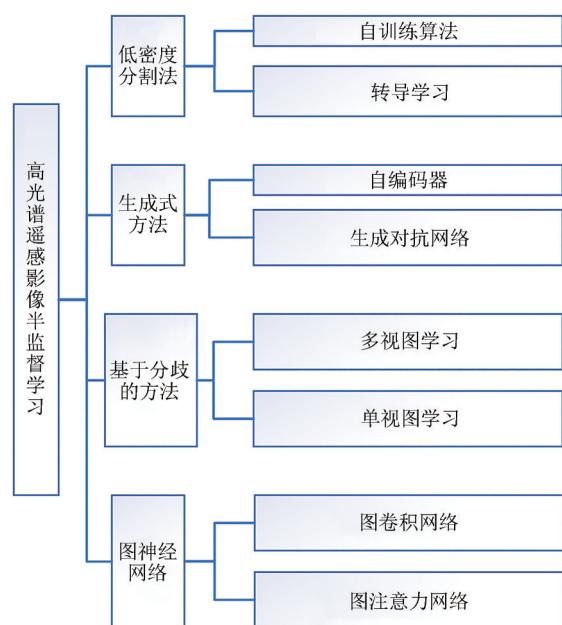


图2 半监督分类算法

Fig. 2 Semi-supervised classification algorithm

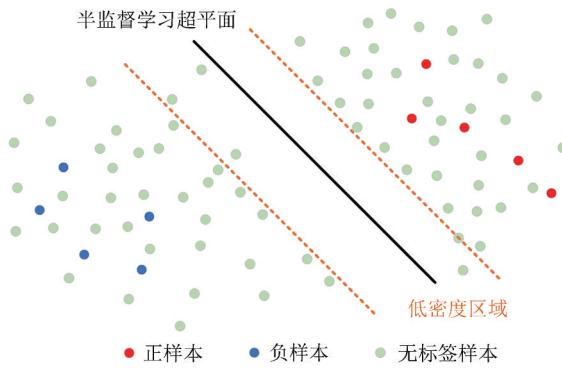


图3 低密度分割算法

Fig. 3 Low density segmentation algorithm

表1 低密度分割法

Table 1 Low density segmentation method

方法	文献	优势	劣势
自训练算法	文献(Wu等,2018; Zhang等,2020b; Fang等,2020; Singh等,2020; Wu等,2020; Wang等,2022,2023)	操作简单方便,易于实现	训练迭代过程中分类器产生错误累积,不适用于噪声、分布不平衡等数据
	文献(Dopido等,2013; Li等,2018a,b; Ding等,2022b)		
转导学习	文献(Bruzzone等,2006; Astorino等,2015; Huang等,2021)	鲁棒性强,有更好的可解释性	训练成本高,对超参数和数据标签信息的依赖度高
	文献(Liu等,2021,2022a; Dong等,2022)	有效地处理高维、稀疏、噪声数据	较难收敛

自训练算法的主要思想是找到某种数据标记方法,用未标记的数据集来扩充已标记的数据集。其伪代码为

输入: 有标签样本集 $L = (x_1, y_1), (x_2, y_2), \dots, (x_L, y_L)$; 无标签样本集 $U = (x'_1, x'_2, \dots, x'_u)$

输出: 无标签样本集的类别标签 y'_1, y'_2, \dots, y'_u ;

repeat:

 用有标签样本 L 训练模型 m ;

 for $x'_1 \in U$

 模型 m 计算无标签样本 x' 的置信度 $m(x')$;

 if $m(x') > \theta$ then

 将 (x', y') 加入有标签样本集 L ;

 end if

 end for

 Until U 中所有样本置信度大于 θ 。

在自训练算法步骤中,如果分类器对未标记样本预测错误,那么错误伪标签会在每次训练迭代过程中造成分类器错误累积,使得分类器性能下降。因此自训练算法中存在的一个问题,是如何在每次迭代中,从未标记样本中生成可靠的伪标签。

针对训练过程中如何选取未标记数据中进行伪标记,典型的解决方案是更可靠的伪标签标记策略。Wang 等 (2014) 在自训练算法中引入了朴素贝叶斯,将模型预测概率改为取平均后验概率与朴素贝叶斯后验概率之和;此外,Zou 等 (2018) 不设置固定阈值,在初次迭代中选择最有信心的样本添加伪标签,而后不断增加伪标签样本比例,直到数据的选择阈值达到 0.5。随着这个思想,Zhang 等 (2022a) 提出课程学习对伪标签的动态适应,将训练过程设计成难易程度循序渐进的课程,使得训练过程更平稳,收敛得更快,且有更好得泛化能力。在高光谱遥感影像分类中,Zhang 等 (2020b) 提出了一种基于简单线性迭代聚类分割的方法;Wu 等 (2018) 提出了使用非参数聚类算法来生成伪标签;Fang 等 (2020) 提出近似秩序聚类算法,这些方法都通过对高光谱遥感影像深度特征进行聚类,增加了伪标签标记的有效性。Wu 等 (2020) 利用自训练通过聚类逐步为高度自信的样本分配伪标签,并利用图像内的空间一致性来纠正和重新分配错误分类的伪标签,约束并调节自训练过程。Fang 等 (2022) 提

出一种置信学习方法, 以去除噪声伪标签。Wang 等 (2023) 提出分层的伪标签生成的方法, 该方法首先使用一种分割算法对具有不同最小分辨率的高光谱图像进行分层分割, 将被标记的像素集与每层分割结果结合起来, 生成该层的伪标签。

鉴于自训练算法简单实用, 同时为了减少迭代过程中错误积累, 研究者们将其与其他算法相结合。Dopido 等 (2013) 将主动学习引入到自训练算法中, 将主动学习中的人工监督替换为机器—机器交互, 算法本身自动从获得的候选集中选择具有最高不确定性的样本。Li 等 (2018a) 提出将自训练技术与区域合并的条件随机场相结合, 对分类器进行迭代更新。传统的基于自训练的半监督方法在处理高维多类分类问题时, 往往会产生较差的分类结果。因此, Singh 等 (2020) 提出一种基于单类分类器集成的高光谱遥感影像半监督分类算法。该算法通过有标签样本训练多个局部特化分类器, 再通过这些分类器扩展数据, 以获得高质量伪标签。除此之外, Lu 等 (2016) 探索了多模态数据特征提取方案, 提出一种多源协同分类自学习算法。该算法协同处理高光谱遥感影像和全色图像, 并结合主动学习策略, 通过协同空间—光谱信息来预测候选标签并自动选择最有效的样本。Ding 等 (2022a) 提出了一种用于大规模高光谱遥感影像聚类的自监督局部保持低通图卷积嵌入方法, 该方法使用自训练策略监督聚类过程中软标签使用, 该算法在多个高光谱遥感影像数据集上取得了优异的效果。

转导学习预先观察所有数据, 包括训练和测试数据集。从观察到的训练数据集学习, 然后预测测试数据集的标签 (Vapnik 和 Izmailov, 2021)。这种方法利用已知的标记点和附加信息来预测未标记点的标记。而当引入新数据点时, 转导学习都必须重新运行所有内容, 这样成本可能会很高。典型的转导学习方法包括转导支持向量机 TSVM (Transductive SVM) 和基于图的标签传播算法 LPA (Label Propagation Algorithm) (Zhu 和 Ghahramani, 2002)。

转导支持向量机由 Vapnik 等 (1999) 最早提出, 研究者指出 TSVM 作半监督支持向量机的典型算法仍存在如对参数和数据标签信息的依赖性等劣势 (Guyon 等, 2002)。因此, 研究者们提出最小二乘半监督支持向量机 (Astorino 和 Fuduli,

2015), 拉普拉斯双子半监督支持向量机 (Qi 等, 2012), 鲁棒半监督支持向量机 (Shi 等, 2011), 稀疏正则化半监督支持向量机 (Fan 等, 2011) 等多种改进方法。

标签传播算法是一种基于图的转导学习迭代算法, 通过在数据集中传播标签, 将标签分配给未标记的点。LPA 的求解方法涉及到标签的传播和图结构的更新 (Bai 等, 2020)。LPA 的优势是它可以有效地处理高维、稀疏、噪声数据, 并且可以扩展到大规模数据集。然而, 也存在如灵敏度和对图分割不均匀等缺点 (张俊丽 等, 2013)。

基于转导学习理论, 研究者们提出多种改进方案。Bruzzone 等 (2006) 率先针对高光谱遥感影像提出一种新颖的 TSVM, 验证了 TSVM 有助于从高光谱影像中的未标记数据中提取信息。Huang 等 (2021) 提出了一种利用变分非局部图论进行高光谱遥感影像分类的高效转导学习方法。在 Liu 等 (2021)、Dong 等 (2022) 及 Liu 等 (2022a) 等文献中, 基于标签传播算法提出了将 GCN 和 CNN 融合在一个网络中的模型来提取高光谱遥感图像深度特征。但这些方法训练过程需要将全图的邻接矩阵和特征矩阵放在内存或显存中, 难以聚合新节点, 同时算法复杂度非常高, 并不适用于大规模数据。(Hamilton 等, 2017) 文中提出图样本和聚合 GraphSAGE 解决了全图和全批训练方法计算复杂度高的问题, Yang 等 (2021b) 首先将 GraphSAGE 引入 HSI 分类, 并提出了光谱—空间图形 SAGE (S2GraphSAGE) 算法。之后, Ding 等 (2021) 利用多尺度图卷积, 降低了计算复杂度。Ding 等 (2022b) 结合 GraphSAGE 和注意机制, 提出了图样本和聚合注意 (SAGE-A), 通过注意机制提高了 GraphSAGE 的特征提取能力。为克服极其稀疏的标记数据对分类方法带来的困难, Zhong 等 (2022) 提出一种动态光谱—空间泊松学习。该方法采用泊松学习预测标签, 可以防止传统标签传播方法输出恒定标签。利用像素之间的连接关系构建光谱—空间图, 构成迭代过程的良性循环。实验结果表明, 当标记的像素很少 (每个类别的标记像素为 3、5 或 10 个) 时, 所提出的算法优于其他分类方法。

3.2 生成式方法

生成式方法假设所有数据分布一致, 都由同

一模型生成，然后用参数表示无标签数据属于每个类的概率，最后通过期望最大算法来估计标签和参数。在高光谱遥感影像分类领域，基于生成式半监督模型的方法主要有两种：自编码器 AE

(AutoEncoders) (Gogna 和 Majumdar, 2016) 和生成对抗网络 GAN (Generative Adversarial Networks) (Odena, 2016) (表 2)。

表 2 生成式方法代表性算法

Table 2 Representative algorithms for generative methods

方法	文献	优势	劣势
自编码器	文献(Pande 和 Banerjee, 2020; Feng 等, 2020; Teloglu 和 Aptoula, 2021; Jia 等, 2022a)	降低数据维度	容易过拟合
生成对抗网络	文献(Zhan 等, 2018; Liang 等, 2020, 2021; Wang 等, 2021b, 2022; Zhong 等, 2021;)	生成逼真的数据样本	训练不稳定, 容易出现不收敛、崩溃等问题

自编码器是一种由编码器和解码器组成的结构 (图 4)，编码器用于将高维的输入压缩成低维的特征，解码器将低维的特征还原为原始信号，经过训练以使编码解码后的数据与初始数据之间的重构误差最小 (Vincent 等, 2010)。半监督自编码器 (Gogna 和 Majumdar, 2016) 在生成低维特征的同时，完成标签补全，能兼顾预测标签以及标签对重构的影响。

提出半监督长短时记忆自动编码方法，并应用于多时相遥感数据的作物分类。部分研究者通过引入更多先验知识来改进自编码器，Cai 等 (2022c) 利用数据之间的高阶关系，提出一种超图结构自编码器。该方法采用超图结构正则化的深度自编码器作为骨干网络，与特定任务分支联合训练，形成多任务体系结构。此外，研究者还探索了多种模型结构结合方法。Jia (2022a) 提出了一种集成了自编码器和暹罗网络的半监督暹罗网络，这些方法均取得了不错的效果。

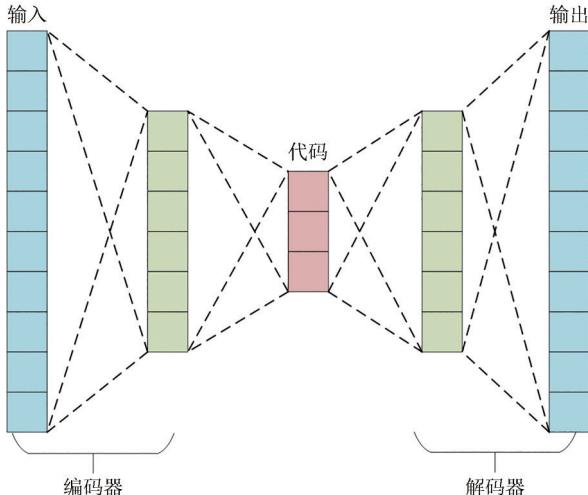


图 4 自编码器结构

Fig. 4 AutoEncoders structure

在模型结构改进方面，Pande 和 Banerjee (2020) 提出一种自动编码器 (3D ResAE)，使用 3D 卷积和残差块将高维 HSI 特征投影到低维空间，有效地处理了光谱空间特征，在 Indian pines 和 Salinas 数据集上取得了良好的分类精度。而 Feng 等 (2020) 则尝试引入注意力机制，提出双分支的自注意半监督双分支卷积自编码器结构，提高了模型的表达能力。Teloglu 等 (2021) 对编码方式进行修改，

标准生成对抗网络分为两个组件，一个为判别器 D ，用于区分真实样本和生成样本；另一个为生成器 G ，用于生成假样本来欺骗判别器 (Radford 等, 2016)。GAN 训练伪代码为

输入：有标签样本集 $L = (x_1, y_1), (x_2, y_2), \dots, (x_L, y_L)$ ；

输出：生成器 G ，判别器 D

for 迭代次数 $n = 1, 2, \dots, N$ do；

 for 第 k 步 do

 基于带有噪声的输入 $p(z)$ 获取噪声样本 Z

$= \{z^1, z^2, \dots, z^m\}$ ； 基于生成器 G 生成样本 $X = x^1, x^2, \dots, x^m$ ； 通过损失函数更新判别器 D 参数。

 end for

 基于带有噪声的输入 $p(z)$ 获取噪声样本 $Z =$

$\{z^1, z^2, \dots, z^m\}$ ；

 更新生成器 G 参数；

 end for

随后，Odena (2016) 提出半监督生成对抗网络 SGAN (Semi-supervised Generative Adversarial Networks)。SGAN 的训练过程与 GAN 类似，但增加了标记数据的使用，具体操作是在 GAN 的损失

函数中加入一个额外的分类损失项，在训练过程中利用标记数据约束分类损失最小化。相比于其他生成式模型，生成对抗网络能适用于任何生成器和判别器，也能有效地产生更为出色的伪样本。但与此同时，GAN也存在不收敛、崩溃问题和模型过于自由等问题（Wang 等, 2017）。

Zhan 等（2018）设计了第一个基于一维 GAN 框架用于 HSI 的半监督分类方法，该框架实现了 HSI 分类的光谱特征自动提取。当使用未标记的高光谱数据训练时，生成器可以生成与真实数据相似的高光谱样本，而鉴别器则包含了特征，可以用少量标记样本对高光谱数据进行分类。针对 GANs 的模型崩溃问题，Wang 等（2021b）提出了一种 ADGAN，同时尝试解决高光谱遥感影像数据中类不平衡问题。Zhong 等（2021）则提出一种背景异常可分性生成对抗网络，针对高光谱遥感影像中样本不平衡、背景复杂多样等问题，该方法的关键在于通过对背景光谱样本的刻画，明确地约束了背景与异常的可分性，同时避免了异常的重建。针对 GAN 特征提取方法的局限性，Liang 等（2020）提出了一种基于自适应邻域策略的生成对抗网络用于半监督 HSI 分类，该方法利用简单线性迭代聚类的超像素算法生成多个空间均匀区域，再合并超像素，然后利用有限的标记样本训练鉴别器，稀疏自编码器利用大量的未标记样本产生噪声并训练鉴别器，以提高鉴别器性能。在模型改进方面，Liang 等（2021）提出基于 GAN 的端到端的半监督光谱空间注意力特征提取方法，构建了光谱空间注意模块。Wang 等人提出基于域的对抗性宽度学习，实现源域和目标域的分布对齐，大幅模型的泛化性能（Wang 等, 2022）。

3.3 基于分歧(差异性)的半监督分类

3.3.1 多视图学习

基于分歧的方法使用多个学习器，学习器之间的分歧对未标记数据的利用至关重要。协同训练（co-training）（Blum 和 Mitchell, 1998）便是针对多视图数据集的典型算法。其主要思想是利用多个分类器同时对多视图数据进行分类，并基于不同分类器的误差和置信程度对数据进行筛选，去除分类中相互矛盾的数据点，并根据这些筛选后的数据点来更新分类器，最终提高分类性能。

协同训练方法的半监督分类过程非常简单（Zhou 和 Li, 2007），其伪代码为

```

输入：有标签样本集  $L = \{ \langle x_1^1, x_1^2 \rangle, y_1 \}, \dots, \langle x_1^1, x_1^2 \rangle, y_1 \};$  无标签样本集  $U = \{ \langle x_1^1, x_1^2 \rangle', \langle x_2^1, x_2^2 \rangle', \dots, \langle x_u^1, x_u^2 \rangle' \};$ 
缓冲池大小  $s;$ 
每轮挑选的正例数  $p;$ 
每轮挑选的反例数  $n;$ 
基学习算法  $\zeta;$ 
学习轮数  $T;$ 
输出：分类器  $h_1, h_2$ 
从  $U$  中随机抽取  $s$  个样本构成缓冲池  $D_s$ ;
 $U = U \setminus D_s;$ 

for  $j = 1, 2$  //各视图的有标签样本
     $L^j = \{ (x_i^j, y_i) | (\langle x_i^j, x_i^{3-j} \rangle, y_i) \in L \}$ 
end for
for  $t = 1, 2, \dots, T$  do
    for  $j = 1, 2$  do
         $h_j = \zeta(L^j)$  //基于每个视图训练学习器  $h_1, h_2$ ;
        挑选  $p$  个正例置信度最高的样本  $D_p \subset D_s$ ;
        挑选  $n$  个反例置信度最高的样本  $D_n \subset D_s$ ;
        由  $D_p$  生成伪标记正例， $D_n$  生成伪标记反例;
         $D_s = D_s \cap (D_p \cup D_n);$ 
    end for
    if  $h_1, h_2$  均未发生改变 then
        Break
    else
        for  $j = 1, 2$  do
             $D_t^j = D_t^j \cap (D_p \cup D_n);$ 
        end for
        从  $D_u$  中随机抽取  $2p + 2n$  个样本加入  $D_s$ ;
    end if
end for

```

基于分歧的方法只需要采用合适的基学习器，就能较少受到模型假设、损失函数非凸性和数据规模问题的影响，学习方法简单有效、理论基础相对坚实、使用范围较为广泛其代表性等法如表 3 所示。当两个视图满足充分冗余和条件独立时，通过协同训练可以利用未标记样本将弱分类器的精度提升（Darnstädt 等, 2014）。但视图的条件独立性在现实任务中通常很难满足，因此性能提升幅度没有那么大（Grolman 等, 2022）。

表3 基于分歧(差异性)的高光谱遥感影像半监督分类代表性算法

Table 3 Representative algorithm for semi supervised classification of hyperspectral remote sensing images based on divergence (Difference)

方法	文献	优势	劣势
多视图 学习	文献(Zhang等,2020a;Huang等,2022;Feng等,2022;Cai等,2022b;Xu等,2022)	理论基础相对坚实,使用范围较广	计算复杂度高
单视图 学习	文献(Cui等,2017,崔颖等,2018;Ou等,2019;Wang等,2021a)	较低的计算复杂度	对噪声和错误标签敏感

因此,如何构造冗余且独立的高光谱遥感影像视图成了研究者们关注的重点。针对部分方法仅将多个视图的特征进行堆叠来构造高维数据的问题, Feng 等 (2022) 提出一种多视图光谱空间特征提取与融合的分析与分类框架。该方法通过将扩展多属性剖面 (EMAPs)、灰度共生矩阵 (GLCM) 和 Gabor 提取的不同互补空间特征, 再由半监督特征提取方法提取多视图数据集, 获得多视图光谱空间特征。Huang 等 (2022) 提出多尺度超像素分割和基于相关的光谱带聚类生成光谱空间多视图。除了手动提取特征外, 研究者们也探索了基于主动学习的视图生成方法。Cai 等 (2022b) 提出一种相诱导的基于 Gabor 的多视图主动学习方法用于高光谱遥感影像分类, 该方法探索了相位偏移项在手工制作的 Gabor 特征提取中的潜力。Li 等 (2020a) 提出基于亚像素—像素—超像素的多视图主动学习, 构建反映光谱混合、光谱判别、光谱—空间结构的多视图; 同样的, Zhang 等 (2020a) 提出一个自适应基于多视图的主动学习, 以提高视图间的充分性和多样性。Xu 等 (2022) 将多视图方法结合主动学习策略, 提出一种由协作代表组成的委员会模型, 形成一种留一分类多视图策略。这些方法均在高光谱遥感影像半监督分类中取得了良好的效果。

3.3.2 单视图学习

得益于多视图半监督分类的成功, 研究者们面对单视图数据集, 自然而然的考虑是否可以通过不同的数据处理方法划分为多视图数据集, 然后使用多视图方法。Nigam 等 (2002) 研究发现, 在数据集包含非常大的属性集和大量的冗余属性时, 随机的把属性集划分为多视图后, 协同训练可以取得很好地效果; 然而在其他数据集上, 视图划分并没有对分类器的精度提升起到明显效

果。Zhou 和 Li (2005) 提出了“三体训练法 (Tri-training)”, 该方法从单视图训练集中产生3种不同数据集, 分别用于训练3个分类器, 然后这3个分类器使用多数表决形式产生伪标记样本。Li 和 Zhou (2007) 提出了协同森林法 (Co-Forest), 该方法将三体训练法中3个分类器推广至更多的分类器。但由于分类器数量的增加, 导致不同分类器之间的特异性减小, 因此, 在学习过程中使用了多种差异引入机制来避免提前停止。Du 等 (2011) 实验研究显示, 在拥有足够多的标记样本时 (单视图中包含充分冗余多视图信息), 可能找出合适的试图划分。然而该结论与半监督分类基本条件相悖, 若有足够的标记样本, 可由监督学习训练出足够好的分类器。后续理论研究表明, 此类算法事实上无需数据拥有多试图, 仅需弱学习器之间具有显著的分歧 (或者差异), 即可通过相互提供伪标记样本的方式来提升泛化性能。

在高光谱遥感影像半监督分类中, 基于单视图的半监督分类方法主要需要增加样本和分类器的多样性和差异性。Cui 等 (2017) 针对标签样本数量有限时, 三体训练在分类器之间缺乏显着多样性的问题, 提出使用多样化分类器和基于标记类的分层抽样, 可有效增加多样性。崔颖等 (2018) 提出一种使用4个不同的分类器: 两个SVM, 一个K近邻 (KNN) 以及一个随机森林 (RF), 增加了分类器的多样性。采用有标签样本与无标签样本错误率加权作为有标签样本集更新的限制条件, 增加了样本标签的差异性。Ou 等 (2019) 提出采用正则化局部判别嵌入方法进行最优特征信息提取, 并构建3种不同基础分类器, 有效的解决局部判别嵌入和局部 Fisher 判别分析方法存在的奇异值和过拟合问题。Wang 等 (2021c) 构建小波光谱角映射三训练模型对9种

蚀变矿物的高光谱影像进行判别，该方法不使用交叉放置策略来确定标签，而是以两个分类器的光谱角度差异作为判断像素是否为改变矿物以及它属于什么类别的标准。9种蚀变矿物上的识别准确率均有提高。

3.4 基于图的方法

HSI通常包含大量波段，导致数据维度非常高。使用图的HSI表示方法可以将高维数据转换为图的结构，从而降低维度，减少特征空间的复杂性。其次，图的表示方法能够自然地捕捉到数据中像素之间的空间关系，并且能够保留像素之间的相互作用信息。而相邻像素之间的空间关系对分类结果具有较大的影响。最后，图的表示方法允许在相邻像素之间建立连接，从而允许信息在不同尺度上进行传播。这使得模型能够融合不同尺度的信息，以更好地捕捉图像中的细节和上下文信息。近年来，基于图的半监督分类方法在HSI分类领域受到越来越多的关注和广泛应用（王健宗等，2021）。

标签传播算法是一种典型的基于图的半监督算法，其伪代码为

输入：有标签样本集 $L = (x_1, y_1), (x_2, y_2), \dots, (x_L, y_L)$ ；无标签样本集 $U = x'_1, x'_2, \dots, x'_u$ ；构图参数 σ ；折中参数 α ；
输出：无标签样本集的类别标签 $\{y'_1, y'_2, \dots, y'_u\}$ ；初始化标签矩阵 Y ，带标签的样本初始化为1，其他样本为0；基于构图方法和构图参数 σ 获得邻接矩阵 W ；基于 W 构造标签传播矩阵 $F = D^{-1/2}WD^{-1/2}$ ；

repeat

$$F(t+1) = \alpha F(t) + (1 - \alpha)Y;$$

更新未标记样本 U 的标签分布 $Y = F(u)/\text{sum}(F(u))$ ；

$$t = t + 1;$$

until F 迭代收敛

随着图神经网络 GNN (Graph Neural Networks) (Scarselli 等, 2005) 以及知识图谱的兴起，带动了一波图算法的热潮。常见的图神经网络大致可以分为4类，即图卷积网络、图循环网络、图生成网络和图注意力网络。其中，图卷积网络在高光谱遥感影像分类任务中发挥越来越重要的作用。图

卷积网络中图卷积核大小由节点邻域结构控制，能够适用于非欧几里得结构的不规则数据，因此能灵活的适应高光谱图像中不规则的类别边界信息。

图卷积网络思想来源于Bruna等(2014)，其首次提出在图上构建卷积神经网络，并基于谱图理论提出了谱卷积神经网络。然而，当图节点增多时，该方法参数量和时间复杂度都急剧增加。随后，Defferrard等(2016)提出了ChebNet，将时间复杂度降低至线性。在此基础上，Kipf和Welling(2017)利用一阶近似进一步简化ChebNet中的卷积操作，提出图卷积网络用于半监督分类。此外，由于早期的图卷积神经网络无法处理归纳式半监督分类问题，Hamilton等(2017)提出了GraphSAGE算法。

在高光谱遥感影像分类的图卷积网络方法中有两个重要模块，建图和图卷积神经模块。其图的构造方法对分类性能有着极其重要的影响，其构造的图是否能反映数据的特性将直接影响分类性能(Dong等, 2011)。总体来说，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(万升等, 2023)。其代表性算法如表4所示。其中，以原始像素作为图节点是最简单直接的建图方式，但由于高光谱遥感影像本身是不具有图结构的数据，因此往往需要设置邻接关系，建立相应邻接矩阵，用于图卷积操作。早期的S²GCN算法(Qin等, 2019)通过融合像素间的空间距离和光谱特征差异，建立邻接矩阵。随后，研究者们提出用深度CNN(Shahraki和Prasad, 2019)、深度自编码器(Sellami等, 2022)、GraphSAGE(Yang等, 2021b)等方式提取特征以计算邻接矩阵。基于相似的思想，Guo等(2021)通过像素间的空间距离和光谱特征差异分别建立两个不同邻接矩阵，有效的保留了不同信息，但同时增加了卷积的复杂度。相较于以上构建固定邻接矩阵的方法，Mou等(2020)提出一种迭代优化邻接矩阵的思路，通过模型学习，在训练过程不断优化邻接矩阵。Liu等(2022b)提出通过神经网络来提取HSI的空间图谱信息。为了减小卷积神经网络规模，研究者们提出用自注意力(Bai等, 2022)、交叉注意力机制(Cai和Wei, 2020)等方式对HSI处理。

表4 基于图的高光谱遥感影像半监督分类代表性算法

Table 4 Representative Algorithm for Semi supervised Classification of Hyperspectral Remote Sensing Images Based on Graphs

建图方法	具体类型	方法	主要贡献	局限性
以像为节点	节点之间权重固定	S ² GCN(Qin等,2019) 文献(Shahraki和Prasad,2019;Yang等,2021b; Guo等,2021;Sellami和Tabbone,2022)	首次将光谱信息和空间信息引入图卷积过程 操作简单,无需复杂处理	节点数量多,图卷积操作复杂度高 邻接矩阵对噪声敏感
	节点间权重可学习	non-local GCN(Mou等,2020) 文献(Cai和Wei,2022;Bai等, 2022;Liu等,2022b)	首次提出迭代优化邻接矩阵的思路 邻接矩阵能迭代优化,减少噪声等因素的干扰	非局部图卷积依赖像素级图学习,复杂度较高 算法时间和空间复杂度较高,模型难以训练
以超像素为节点	超像素划分固定	MDGCN(Wan等,2020) 文献(Yang等,2022;Jia等,2022b)	提出动态图卷积,在图卷积的过程中迭代优化图信息 能预先计算超像素,大幅减少节点数量	无法优化图拓扑结构 超像素分割算法准确度难以保证
	超像素划分可学习	CAD-GCN(Wan等,2021) 文献(Zhang等,2022c)	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 超像素分割结果由模型优化,更准确	训练难度大,对超像素的特征初始化要求较高 算法时间和空间复杂度高,模型训练难度大

尽管直接以像素为节点的构图方法简单实用,但当高光谱遥感影像像素数目增加时,后续图节点和边的数量随着 HSI 的大小呈指数增长。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。该方法有效提高图卷积的效率,因为通常超像素数量远远小于像素数量。Wan 等 (2020) 最早提出利用超像素建图的图神经网络方法 MDGCN。该方法用图像分割算法 SLIC (Simple Linear Iterative Clustering) 提取光谱相似度,根据光谱相似度将空间距离较近的像素聚合为超像素节点,大大减少了图中的节点数量。这也使得自适应学习的超像素节点突破了原始欧几里得数据结构的局限性,可以更清晰地定义相邻不规则区域之间的相关性,从而模拟 HSI 的空间上下文结构。Yang 等 (2022) 提出了一种DNAGSI框架,该框架在每一层构建一个动态生成的图结构,并自适应地将这些新的不同层的图结构与初始图结构集成。此外,Jia 等 (2022b) 探索了像素级和超像素级的图结构,提出的 GiGCN 算法通过融合不同层级图卷积的结果来获得多尺度空谱特征。然而,这类算法依赖超像素分割的准确度,这很大程度上限制了

高光谱遥感影像分类的准确度。因此,研究者们开始探索动态的超像素建图方法,将图像分割和图的构建都加入优化过程。Wan 等 (2021) 提出了一种超像素级的上下文感知动态 GCN (CAD-GCN) 方法来学习图节点之间的远程上下文信息。该方法首先基于相似性关系学习一个邻接矩阵矩阵。随后,在训练过程逐步优化该矩阵,这也是首个基于端到端策略进行超像素建图的算法。EMS-GCN (Zhang 等, 2022c) 方法同样也在网络内进行超像素分割过程,以生成自适应图。这种方法分割结果可由模型自动优化,超像素划分更精确,但其复杂度更高,且分割模块的训练仍存在较大难度。

当前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。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,操作更为直观,定义也相对灵活。Hu 等 (2022) 通过 GNN 对大规模的不规则区域进行特征学习,然后在像素级提取局部空间光谱特征。此外,将边缘卷积 (EdgeConv) 纳入 GNN。Zhao (2022b) 在传统的 GCN 网络中嵌入了图 transformer 网络。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, 因而具有坚实的数据基础。Shahraki 和 Prasad (2019) 首先提出利用图卷积网络模型来进行高光谱图像分类。之后, Qin 等 (2019) 提出了 S2GCN 算法。该算法通过 K-近邻 (KNN) 构造一个图, 将像素作为图节点进行处理, 然后根据相邻像素之间的空间和光谱信息采用 GCN 进行细化。Wang (2021a) 提出了一种基于图卷积宽网络 (GCBN) 的半监督 HSI 分类方法, 具有更好的泛化能力。Chen 等 (2022b) 提出了一种对偶残差图卷积网络 (DRGCN), 提取了更鲁棒和鉴别的特征。MSSGU 算法提出了多级超像素结构图 U-Net, 通过逐步将相邻的超像素合并并将其转换为多级图来提取多尺度信息 (Liu 等, 2022b)。

Li 等 (2018b) 研究指出 GCN 存在如下问题: (1) 半监督时带有标签的节点过少, GCN 的性能会有比较严重的下降。另外, 在训练样本比较小的时候如果没有验证集, 性能也会有明显的下降。(2) 浅层的 GCN 网络不能大范围地传播标签信息 (层级越深, 节点的感受野越大), 因此带标签节点的信息只能在小范围内传递, 不能高效地利用标签的信息。(3) 深层的 GCN 网络会导致过度平滑的问题, 即每个节点的特征十分相近。主要原因是每一层都会附近节点信息融合在一起, 其中可能包括不相关的节点, 最终造成不同类节点的特征向量相近。

针对 GCN 方法在构造和更新图时依赖于人工操作, Chen 等 (2022a) 提出了一种自动图学习卷积网络, 将半监督的 Siamese 网络嵌入到 GCNs 和 HSIC 网络中, 实现图的自动学习和动态更新。Zhang 等 (2022c) 提出了一种端到端的混搭超像素的 GCN 框架用于 HSI 分类, 有效利用超像素内的局部光谱空间信息。针对图方法中容易出现过平滑 (每个节点的表示趋于一致) 和计算成本高, 不能有效地抑制噪声问题。Ding 等 (2022a) 提出一种基于自回归移动平均滤波器和上下文感知学习的半监督位置保持稠密图神经网络用于 HSI 分类。该方法引入了自回归移动平均滤波器来代替光谱滤波器来应用于 GNN, 并提出一个稠密结构。

针对基于图的半监督分类中固有的一些劣势, 研究者们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。例如, 在 WFCG 算法 (Ma 等, 2022) 中设计了一个具有两个分支

的网络, 分支一基于 GAT 提取超像素特征, 分支二则基于 CNN 提取像素特征, 并将超像素和像素传递给网络进行加权特征融合, 实现了对长距离深度特征的捕获。类似地, Liu 等 (2022a) 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 FDGC。与 WFCG 算法不同, FDGC 算法中图神经网络被用来提取高光谱遥感影像中的结构信息, 而 CNN 则被用来提取高光谱图像中不同层次的空谱信息。CEGCN (Liu 等, 2021) 则通过编码和解码图结构, 将 CNN 和 GCN 集成到一个单一的网络中。这类方法将分别由不同分支提取不同类型特征, 再由特征融合提取出判别性特征, 然而如何确定不同类型特征权重仍是不可避免的问题。Li 等 (2022b) 等提出一种不同模型协作运作的 GSANet 算法, 该算法首先利用 CNN 提取空谱特征, 随后利用图卷积网络进一步提取空间结构信息。这种协作运作算法有效的提高了高光谱遥感影像分类的准确度。但由于引入了 CNN, GSANet 算法需要更多的有标签样本指导模型训练。

3.5 常用开源算法对比

为了进一步分析不同算法的特点, 本节在 Indian Pines (IP), Pavia University (PU) 和 Houston2013 数据集上进行实验。其中, 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 OA (Overall Accuracy)、每类平均准确率 AA (Average Accuracy) 和 Kappa 系数。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。

为了评估算法的性能, 我们比较 10 种算法: SSRN (Mei 等, 2019)、SpectralFormer (Hong 等, 2022)、LapSVM (Chen 等, 2014)、3DAES (Jia 等, 2022)、HSGAN (Zhan 等, 2018)、SSGPN (Xi 等, 2021)、MD-GCN (Wan 等, 2020)、XGPN (Xi 等, 2023)、CAD-GCN (Wan 等, 2021)、WFCG (Dong 等, 2022)。其中, SSRN、SpectralFormer 是监督学习方法; LapSVM 是低密度分割法; 3DAES、HSGAN 是半监督生成式算法; SSGPN、MD-GCN、XGPN、CAD-GCN、WFCG 是基于图的算法。表 5—7 分别展示了不同算法在 Indian Pines (IP), Pavia

University (PU) 和 Houston2013 数据集上的定量结果。

观察表 5—表 7 中结果可以发现，WFCG 算法在 Indian Pines、Pavia University 和 Houston2013 数据集中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。其次，基于图的半监督分类方法相比其他半监督分类方法有更好的效果，这可能是因为图模型可以利用样本间的关系和相似性建模，将相似的样本连接，从而捕捉数据集中内在结构和相似性。

表 5 对 Indian Pines(IP)数据集的定量评价

Table 5 quantitatively evaluation for the Indian Pines (IP) dataset

方法	OA	AA	Kappa
SSAN	84.26±0.51	91.82±0.20	82.28±0.57
SpectralFormer	72.55±0.89	82.55±0.72	68.93±0.97
LapSVM	65.33±0.68	70.92±0.97	60.09±0.73
HSGAN	69.22±2.43	78.66±2.17	65.37±2.69
3DAES	74.35±0.44	84.73±0.43	71.15±0.48
SSGPN	76.03±0.51	85.07±0.70	72.76±0.58
MD-GCN	93.47±0.38	96.24±0.21	92.55±0.43
XGPN	89.54±0.77	96.87±0.43	88.18±0.51
CAD-GCN	94.13±0.78	96.38±0.35	93.29±0.88
WFCG	95.58±0.99	97.64±0.39	94.97±1.12

表 6 对 Pavia University (PU)数据集的定量评价

Table 6 quantitatively evaluation for the Pavia University (PU) dataset

方法	OA	AA	Kappa
SSAN	96.91±0.30	96.12±0.30	96.56±0.34
SpectralFormer	92.76±0.41	89.09±0.65	91.90±0.46
LapSVM	69.87±0.44	75.43±0.82	62.07±0.57
HSGAN	90.93±1.68	93.18±1.45	87.37±2.24
3DAES	93.64±0.40	91.47±0.36	92.93±0.44
SSGPN	94.61±0.27	92.20±0.31	93.96±0.30
MD-GCN	95.68±0.22	93.15±0.28	94.25±0.29
XGPN	97.34±0.28	96.29±0.21	97.03±0.32
CAD-GCN	95.68±0.22	93.15±0.28	94.28±0.29
WFCG	99.20±0.34	99.33±0.27	99.09±0.39

表 7 对 Houston2013 数据集的定量评价

Table 7 quantitatively evaluation for the Houston 2013 dataset

方法	OA	AA	Kappa
SSAN	90.04±0.56	91.55±0.42	89.23±0.60
SpectralFormer	88.19±0.52	88.02±0.41	87.22±0.61
LapSVM	67.38±0.67	73.95±0.96	65.79±0.76
HSGAN	85.46±1.57	87.51±2.63	83.11±2.56
3DAES	87.89±0.37	88.78±0.33	86.91±0.37
SSGPN	86.46±0.47	88.38±0.50	88.38±0.50
MD-GCN	91.40±0.92	92.37±0.89	90.70±1.00
XGPN	90.82±0.39	92.46±0.27	90.07±0.46
CAD-GCN	92.51±0.53	93.57±0.41	92.21±0.36
WFCG	97.78±1.02	99.04±0.37	91.53±1.13

4 结语

高光谱遥感影像分类是遥感领域极为热门和重要的研究方向之一。随着高光谱成像仪的广泛使用，面对高光谱数据集急剧增加和高额的标记成本的挑战，如何处理海量的无标签数据和少量的有标签数据，成为当前高光谱遥感影像分类亟待解决的问题。因此，半监督分类技术仍会是未来的研究热点和发展方向，特别是模式识别、机器学习领域的理论新方法。

本文根据近年来的国内外相关文献，对高光谱遥感影像半监督分类进行了梳理和归纳，总结分析了半监督分类常用方法：低密度分割法、生成式模型、基于分歧（差异）的半监督和基于图的半监督四大类，着重分析了其方法的理论和优劣，以及在高光谱遥感影像分类的实际应用，为后续研究提供参考。高光谱遥感影像半监督分类还存在以下一些待研究的问题和发展方向：

(1) 如何有效利用高光谱遥感影像中大量无标签样本将是半监督分类研究中的重点。大多数半监督方法只有在数据集满足数据分布假设才能取得满意的结果。然而在实践中，并不一定满足理想条件。在有标签样本和无标签样本不属于同一分布或者不符合模型假设时，无标签样本的利用反而会导致性能下降。因此，如何在模型中加入丰富、可靠的领域知识，有效利用无标签样本

将是高光谱遥感影像半监督分类的研究重点之一。

(2) 在实际高光谱遥感应用中普遍存在类不平衡问题。类不平衡问题会导致学习框架偏向多数类,甚至可能完全忽略少数类。然而,在半监督分类中,通常假设训练数据集均匀分布在所有的类标签上。高光谱遥感监督分类中的类不平衡问题已有许多研究(Lv等,2021)。如何在半监督分类中使用不平衡的标记数据仍是一个亟待解决的问题。

(3) 在各种方法不断推陈出新之际,更要关注高光谱遥感影像的本质特征,让半监督分类方法为高光谱遥感影像研究服务。目前的半监督分类方法,将HSI视为更高维度的图像,而未有地学、光谱学意义的相关解释和分析。研究表明光谱波段与适用场景之间有较强的相关性(Le等,2009; Oerke等,2016),但对于具体场景有什么适用方法和其意义研究内容较少。随着特征提取算法越来越复杂、分类精度越来越高,理应重新思考其特征、分类结果与物理化学特性的联系与意义,为高光谱遥感提供高水平的理论支撑。

参考文献(References)

- Abdulridha J, Ampatzidis Y, Kakarla S C and Roberts P. 2020. Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. *Precision Agriculture*, 21(5): 955-978 [DOI: 10.1007/s11119-019-09703-4]
- Astorino A and Fuduli A. 2015. Semisupervised spherical separation. *Applied Mathematical Modelling*, 39(20): 6351-6358 [DOI: 10.1016/j.apm.2015.01.044]
- Bai J, Ding B X, Xiao Z, Jiao L C, Chen H Y and Regan A C. 2022. Hyperspectral image classification based on deep attention graph convolutional network. *IEEE Transactions on Geoscience and Remote Sensing*, 60(1): 5504316 [DOI: 10.1109/TGRS.2021.3066485]
- Bai L, Wang J B, Liang J Y and Du H Y. 2020. New label propagation algorithm with pairwise constraints. *Pattern Recognition*, 106: 107411 [DOI: 10.1016/j.patcog.2020.107411]
- Bharathi S P, Srinivasan S and Hariharan R. 2022. Improved chimp optimization with deep transfer learning enabled soil classification technique using hyperspectral remote sensing images. *Journal of Electronic Imaging*, 31(6): 062011 [DOI: 10.1117/1.JEI.31.6.062011]
- Bioucas-Dias J M, Plaza A, Camps-Valls G, Scheunders P, Nasrabadi N and Chanussot J. 2013. Hyperspectral remote sensing data analysis and future challenges. *IEEE Geoscience and Remote Sensing Magazine*, 1(2): 6-36 [DOI: 10.1109/MGRS.2013.2244672]
- Blum A, Lafferty J, Rwebangira M R and Reddy R. 2004. Semi-supervised learning using randomized mincuts//*Proceedings of the 21st International Conference on Machine Learning*. Banff: ACM [DOI: 10.1145/1015330.1015429]
- Blum A and Mitchell T. 1998. Combining labeled and unlabeled data with co-training//*Proceedings of the 11th Annual Conference on Computational Learning Theory*. Madison: ACM: 92-100 [DOI: 10.1145/279943.279962]
- Bruna J, Zaremba W, Szlam A and LeCun Y. 2014. Spectral networks and locally connected networks on graphs. *arXiv*: 1312.6203 [DOI: 10.48550/arXiv.1312.6203]
- Bruzzone L, Chi M and Marconcini M. 2006. A novel transductive SVM for semisupervised classification of remote-sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 44(11): 3363-3373 [DOI: 10.1109/TGRS.2006.877950]
- Cai J N, Chen J, Dou X H and Xing Q G. 2022a. Using machine learning algorithms with in situ hyperspectral reflectance data to assess comprehensive water quality of urban rivers. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5523113 [DOI: 10.1109/TGRS.2022.3147695]
- Cai R L, Liu C Y and Li J. 2022b. Phase-induced Gabor-based multi-view active learning for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 19: 5505005 [DOI: 10.1109/LGRS.2021.3070360]
- Cai W W and Wei Z G. 2022. Remote sensing image classification based on a cross-attention mechanism and graph convolution. *IEEE Geoscience and Remote Sensing Letters*, 19: 8002005 [DOI: 10.1109/LGRS.2020.3026587]
- Cai X L, Wu L Y, Li Y M, Lei S H, Xu J, Lyu H, Li J D, Wang H J, Dong X Z, Zhu Y X and Wang G L. 2023. Remote sensing identification of urban water pollution source types using hyperspectral data. *Journal of Hazardous Materials*, 459: 132080 [DOI: 10.1016/j.jhazmat.2023.132080]
- Cai Y M, Zhang Z J, Cai Z H, Liu X B and Jiang X W. 2022c. Hypergraph-structured autoencoder for unsupervised and semisupervised classification of hyperspectral image. *IEEE Geoscience and Remote Sensing Letters*, 19: 5503505 [DOI: 10.1109/LGRS.2021.3054868]
- Camps-Valls G, Bandos Marsheva T V and Zhou D Y. 2007. Semi-supervised graph-based hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 45(10): 3044-3054 [DOI: 10.1109/TGRS.2007.895416]
- Cao S B, Liu S T, Shi Y F, Pan Y B, Han L F and Yang Y W. 2022. A semi-supervised support vector machines approach for condition monitoring of construction equipment//*2022 IEEE International Conference on Real-time Computing and Robotics (RCAR)*. Guiyang: IEEE: 192-196 [DOI: 10.1109/RCAR54675.2022.9872264]
- Cavalli R M. 2021. Capability of remote sensing images to distinguish the urban surface materials: a case study of Venice city. *Remote Sensing*, 13(19): 3959 [DOI: 10.3390/rs13193959]

- Chaudhri S N, Rajput N S, Singh K P and Singh D. 2019. Different modality based remote sensing data fusion approach for efficient classification of agriculture and urban subclasses//IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium. Yokohama: IEEE: 5710-5713 [DOI: 10.1109/IGARSS.2019.8899201]
- Chen J, Jiao L C, Liu X, Li L L, Liu F and Yang S Y. 2022a. Automatic graph learning convolutional networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5520716 [DOI: 10.1109/TGRS.2021.3135084]
- Chen R, Li G H and Dai C L. 2022b. DRGCN: dual residual graph convolutional network for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 19: 6009205 [DOI: 10.1109/LGRS.2022.3171536]
- Chen W, Ouyang S, Yang J, Li X, Zhou G, & Wang L. 2022c. JAGAN: A Framework for Complex Land Cover Classification Using Gaofen-5 AHSI Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 1591-1603. 15. [DOI:10.1109/JSTARS.2022.3144339]
- Chen W J, Shao Y H, Deng N Y and Feng Z L. 2014. Laplacian least squares twin support vector machine for semi-supervised classification. *Neurocomputing*, 145: 465-476 [DOI: 10.1016/j.neucom.2014.05.007]
- Crowson M, Hagensieker R and Waske B. 2019. Mapping land cover change in northern Brazil with limited training data. *International Journal of Applied Earth Observation and Geoinformation*, 78: 202-214 [DOI: 10.1016/j.jag.2018.10.004]
- Cui Y, Wang X T, Lu Z J and Wang L G. 2018. Hyperspectral image classification based on improved M-training algorithm. *Journal of Harbin Engineering University*, 39(10): 1688-1694 (崔颖, 王雪婷, 陆忠军, 王立国. 2018. 改进M-training算法的高光谱图像分类. 哈尔滨工程大学学报, 39(10): 1688-1694) [DOI: 10.11990/jheu.201707022]
- Cui Y, Song G, Wang X, Lu Z, & Wang L. 2017. Semisupervised classification of hyperspectral images based on tri-training algorithm with enhanced diversity. *Journal of Applied Remote Sensing*, 11(4), 1-[DOI: 10.1117/1.JRS.11.045006]
- Darnstädt M, Simon H U and Szörényi B. 2014. Supervised learning and co-training. *Theoretical Computer Science*, 519: 68-87 [DOI: 10.1016/j.tcs.2013.09.020]
- Defferrard M, Bresson X and Vandergheynst P. 2016. Convolutional neural networks on graphs with fast localized spectral filtering// Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona: Curran Associates Inc.: 3844-3852
- Dempster A P, Laird N M and Rubin D B. 1977. Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society: Series B (Methodological)*, 39(1): 1-22 [DOI: 10.1111/j.2517-6161.1977.tb01600.x]
- Ding Y, Zhang Z L, Zhao X F, Cai Y M, Li S Y, Deng B and Cai W W. 2022b. Self-Supervised locality preserving low-pass graph convolutional embedding for large-scale hyperspectral image clustering. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5536016 [DOI: 10.1109/TGRS.2022.3198842]
- Ding Y, Zhao X F, Zhang Z L, Cai W and Yang N J. 2021. Multiscale graph sample and aggregate network with context-aware learning for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 4561-4572 [DOI: 10.1109/JSTARS.2021.3074469]
- Ding Y, Zhao X F, Zhang Z L, Cai W, Yang N J and Zhan Y. 2022a. Semi-supervised locality preserving dense graph neural network with ARMA filters and context-aware learning for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5511812 [DOI: 10.1109/TGRS.2021.3100578]
- Dong W, Moses C and Li K. 2011. Efficient k-nearest neighbor graph construction for generic similarity measures//Proceedings of the 20th International Conference on World Wide Web. Hyderabad: ACM: 577-586 [DOI: 10.1145/1963405.1963487]
- Dong Y N, Liu Q W, Du B and Zhang L P. 2022. Weighted feature fusion of convolutional neural network and graph attention network for hyperspectral image classification. *IEEE Transactions on Image Processing*, 31: 1559-1572 [DOI: 10.1109/TIP.2022.3144017]
- Dopido I, Li J, Marpu P R, Plaza A, Bioucas Dias J M and Benediktsson J A. 2013. Semisupervised self-learning for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 51(7): 4032-4044 [DOI: 10.1109/TGRS.2012.2228275]
- Du J, Ling C X and Zhou Z H. 2011. When does cotraining work in real data?. *IEEE Transactions on Knowledge and Data Engineering*, 23(5): 788-799 [DOI: 10.1109/TKDE.2010.158]
- Du J, Zhang C M, Zhao B C and Sun Y. 2008. Analysis of the transmittance of modified Savart polariscope in the static large field of view polarization interference imaging spectrometer. *Acta Physica Sinica*, 57(10): 6311-6318 (杜娟, 张淳民, 赵葆常, 孙尧. 2008. 稳态大视场偏振干涉成像光谱仪中视场补偿型Savart偏光镜透射率研究. 物理学报, 57(10): 6311-6318) [DOI: 10.3321/j.issn:1000-3290.2008.10.040]
- Du P J, Xia J S, Xue Z H, Tan K, Su H J and Bao R. 2016. Review of hyperspectral remote sensing image classification. *Journal of Remote Sensing*, 20(2): 236-256 (杜培军, 夏俊士, 薛朝辉, 谭琨, 苏红军, 鲍蕊. 2016. 高光谱遥感影像分类研究进展. 遥感学报, 20(2): 236-256) [DOI: 10.11834/jrs.20165022]
- Elcoroaristizabal S and Amigo J M. 2021. Near infrared hyperspectral imaging as a tool for quantifying atmospheric carbonaceous aerosol. *Microchemical Journal*, 160: 105619 [DOI: 10.1016/j.microc.2020.105619]
- Fan M Y, Gu N N, Qiao H and Zhang B. 2011. Sparse regularization for semi-supervised classification. *Pattern Recognition*, 44(8): 1777-1784 [DOI: 10.1016/j.patcog.2011.02.013]
- Fang B, Li Y, Zhang H K and Chan J C W. 2020. Collaborative learning of lightweight convolutional neural network and deep clustering for hyperspectral image semi-supervised classification with limited

- training samples. *ISPRS Journal of Photogrammetry and Remote Sensing*, 161: 164-178 [DOI: 10.1016/j.isprsjprs.2020.01.015]
- Fang Z Q, Yang Y X, Li Z K, Li W, Chen Y S, Ma L and Du Q. 2022. Confident Learning-Based Domain Adaptation for Hyperspectral Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5527116 [DOI: 10.1109/TGRS.2022.3166817]
- Feng J, Ye Z W, Li D, Liang Y P, Tang X and Zhang X R. 2020. Hyperspectral image classification based on semi-supervised dual-branch convolutional autoencoder with self-attention//IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium. Waikoloa: IEEE: 1267-1270 [DOI: 10.1109/IGARSS39084.2020.9323656]
- Feng J, Zhang J P and Zhang Y. 2022. A multiview spectral-spatial feature extraction and fusion framework for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 19: 5504805 [DOI: 10.1109/LGRS.2021.3066613]
- Flores C A and Verschae R. 2022. A generic semi-supervised and active learning framework for biomedical text classification//2022 44th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Glasgow: IEEE: 4445-4448 [DOI: 10.1109/EMBC48229.2022.9871846]
- Gao Y Z, Chen Y Y, Wang J Q and Lu H Q. 2021. Semi-supervised scene text recognition. *IEEE Transactions on Image Processing*, 30: 3005-3016 [DOI: 10.1109/TIP.2021.3051485]
- Goetz A F H, Vane G, Solomon J E and Rock B N. 1985. Imaging spectrometry for earth remote sensing. *Science*, 228(4704): 1147-1153 [DOI: 10.1126/science.228.4704.1147]
- Gogna A and Majumdar A. 2016. Semi supervised autoencoder//23rd International Conference on Neural Information Processing. Kyoto: Springer: 82-89 [DOI: 10.1007/978-3-319-46672-9_10]
- Gong R. 2018. Gaofen-5 satellite. *Satellite Application*, (5): 1 (龚燃. 2018. 高分五号卫星. 卫星应用, 5: 1) [DOI: 10.3969/j.issn.1674-9030.2018.05.018]
- Gower J F R, Borstadt G A, Gray L H and Edel H R. 1988. The fluorescence line imager: high-resolution imaging spectroscopy over water and land//Proceedings of the 4th International Colloquium on Spectral Signatures of Objects in Remote Sensing. Aussois: [s.n.]: 273-278
- Green R O, Eastwood M L, Sarture C M, Chrien T G, Aronsson M, Chippendale B J, Faust J A, Pavri B E, Chovit C J, Solis M, Olah M R and Williams O. 1998. Imaging spectroscopy and the airborne visible/infrared imaging spectrometer (AVIRIS). *Remote Sensing of Environment*, 65(3): 227-248 [DOI: 10.1016/S0034-4257(98)00064-9]
- Grolman E, Cohen D, Frenklach T, Shabtai A and Puzis R. 2022. How and when to stop the co-training process. *Expert Systems with Applications*, 187: 115841 [DOI: 10.1016/j.eswa.2021.115841]
- Grotte M E, Birkeland R, Honore-Livermore E, Bakken S, Garrett J L, Prentice E F, Sigernes F, Orlandic M, Gravdahl J T and Johansen T A. 2022. Ocean color hyperspectral remote sensing with high resolution and low latency--The HYPSO-1 CubeSat mission. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1000619 [DOI: 10.1109/TGRS.2021.3080175]
- Guo F M, Li Z W, Xin Z Q, Zhu X, Wang L Q and Zhang J. 2021. Dual graph U-nets for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 8160-8170 [DOI: 10.1109/JSTARS.2021.3103744]
- Guyon I, Weston J, Barnhill S and Vapnik V. 2002. Gene selection for cancer classification using support vector machines. *Machine Learning*, 46(1/3): 389-422 [DOI: 10.1023/A:102487302797]
- Hamilton W L, Ying R and Leskovec J. 2017. Inductive representation learning on large graphs//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc.: 1025-1035
- Hong D F, Han Z, Yao J, Gao L R, Zhang B, Plaza A and Chanussot J. 2022. SpectralFormer: rethinking hyperspectral image classification with transformers. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5518615 [DOI: 10.1109/TGRS.2021.3130716]
- Hu H J, Yao M L, He F and Zhang F G. 2022. Graph neural network via edge convolution for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 19: 5508905 [DOI: 10.1109/LGRS.2021.3108883]
- Huang B X, Ge L Y, Chen G, Radenkovic M, Wang X P, Duan J M and Pan Z K. 2021. Nonlocal graph theory based transductive learning for hyperspectral image classification. *Pattern Recognition*, 116: 107967 [DOI: 10.1016/j.patcog.2021.107967]
- Huang S L, Liu Z, Jin W and Mu Y. 2022. A superpixel-correlation-based multiview approach for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 19: 5504605 [DOI: 10.1109/LGRS.2021.3066000]
- Huang Y F, Dong C H and Fan T X. 2006. Using the information of spacecraft SHEN ZHOU-3 moderate resolution imaging spectrometer to retrieve atmospheric water vapour. *Journal of Remote Sensing*, 10(5): 742-748 (黄意玲, 董超华, 范天锡. 2006. 用神舟三号中分辨率成像光谱仪数据反演大气水汽. 遥感学报, 10(5): 742-748) [DOI: 10.11834/jrs.200605110]
- Jan H, Zbyněk M, Lucie H, Kaplan V, Lukeš P and Cudlín P. 2008. Potentials of the VNIR airborne hyperspectral system AISA eagle//15th GIS Ostrava. Ostrava: [s.n.]
- Jia S, Jiang S G, Lin Z J, Xu M, Sun W W, Huang Q, Zhu J S and Jia X P. 2022a. A semisupervised siamese network for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5516417 [DOI: 10.1109/TGRS.2021.3116138]
- Jia S, Jiang S G, Zhang S Y, Xu M and Jia X P. 2022b. Graph-in-graph convolutional network for hyperspectral image classification. *IEEE Transactions on Neural Networks and Learning Systems*. 20: 1-15. [DOI: 10.1109/TNNLS.2022.3182715]
- Joachims T. 1999. Transductive inference for text classification using support vector machines//Proceedings of the 16th International Conference on Machine Learning. San Francisco: Morgan Kaufmann Publishers Inc.: 200-209
- Khan A, Vibhute A D, Mali S and Patil C H. 2022. A systematic review

- on hyperspectral imaging technology with a machine and deep learning methodology for agricultural applications. *Ecological Informatics*, 69: 101678 [DOI: 10.1016/j.ecoinf.2022.101678]
- Kipf T N and Welling M. 2017. Semi-supervised classification with graph convolutional networks. *arXiv:1609.02907* [DOI: 10.48550/arXiv.1609.02907]
- Kunkel B, Blechinger F, Viehmann D, Piepen H V D and Doerffer R. 1991. ROSIS imaging spectrometer and its potential for ocean parameter measurements (airborne and space-borne). *International Journal of Remote Sensing*, 12(4): 753-761 [DOI: 10.1080/01431169108929691]
- Laban N, Abdellatif B, Ebeid H M, Shedeed H A and Tolba M F. 2018. Seasonal multi-temporal pixel based crop types and land cover classification for satellite images using convolutional neural networks//2018 13th International Conference on Computer Engineering and Systems (ICCES). Cairo: IEEE: 21-26 [DOI: 10.1109/ICCES.2018.8639232]
- Laliberte A S, Goforth M A, Steele C M and Rango A. 2011. Multispectral remote sensing from unmanned aircraft: image processing workflows and applications for rangeland environments. *Remote Sensing*, 3(11): 2529-2551 [DOI: 10.3390/rs3112529]
- Le C F, Li Y M, Zha Y, Sun D Y, Huang C C and Lu H. 2009. A four-band semi-analytical model for estimating chlorophyll a in highly turbid lakes: the case of Taihu Lake, China. *Remote Sensing of Environment*, 113(6): 1175-1182 [DOI: 10.1016/j.rse.2009.02.005]
- Li F, Clausi D A, Xu L L and Wong A. 2018a. ST-IRGS: a region-based self-training algorithm applied to hyperspectral image classification and segmentation. *IEEE Transactions on Geoscience and Remote Sensing*, 56(1): 3-16 [DOI: 10.1109/TGRS.2017.2713123]
- Li H Y, Zhu F J, Zheng X Y, Liu M X and Chen G Z. 2022a. MSCDUNet: a deep learning framework for built-up area change detection integrating multispectral, SAR, and VHR data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15: 5163-5176 [DOI: 10.1109/JSTARS.2022.3181155]
- Li M and Zhou Z H. 2007. Improve computer-aided diagnosis with machine learning techniques using undiagnosed samples. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 37(6): 1088-1098 [DOI: 10.1109/TSMCA.2007.904745]
- Li Q M, Han Z C and Wu X M. 2018b. Deeper insights into graph convolutional networks for semi-supervised learning. *arXiv: 1801.07606* [DOI: 10.48550/arXiv.1801.07606]
- Li S T, Song W W, Fang L Y, Chen Y S, Ghamisi P and Benediktsson J A. 2019. Deep learning for hyperspectral image classification: an overview. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9): 6690-6709 [DOI: 10.1109/TGRS.2019.2907932]
- Li W, Wang J J, Gao Y H, Zhang M M, Tao R and Zhang B. 2022b. Graph-feature-enhanced selective assignment network for hyperspectral and multispectral data classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5526914 [DOI: 10.1109/TGRS.2022.3166252]
- Li X Y, Fan H S, Pan S L, Jiang X H and Wu J Q. 2019. Overview of Zhuhai No. 1 hyperspectral satellite data and applications. *Satellite Application*, (8): 12-18 (李先怡, 范海生, 潘申林, 蒋晓华, 吴佳奇. 2019. 珠海一号高光谱卫星数据及应用概况. 卫星应用, (8): 12-18) [DOI: 10.3969/j.issn.1674-9030.2019.08.005]
- Li Y, Lu T and Li S T. 2020a. Subpixel-pixel-superpixel-based multiview active learning for hyperspectral images classification. *IEEE Transactions on Geoscience and Remote Sensing*, 58(7): 4976-4988 [DOI: 10.1109/TGRS.2020.2971081]
- Li Z T, Chen G K and Zhang T X. 2020b. A CNN-transformer hybrid approach for crop classification using multitemporal multisensor images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 847-858 [DOI: 10.1109/JSTARS.2020.2971763]
- Liang H B, Bao W X, Lei B B, Zhang J and Qu K W. 2020. Adaptive neighborhood strategy based generative adversarial network for hyperspectral image classification//IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium. Waikoloa: IEEE: 862-865 [DOI: 10.1109/IGARSS39084.2020.9324088]
- Liang H B, Bao W X, Shen X F and Zhang X W. 2021. Spectral-spatial attention feature extraction for hyperspectral image classification based on generative adversarial network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 10017-10032 [DOI: 10.1109/JSTARS.2021.3115971]
- Liang J Y, Gao J W and Chang Y. 2009. The research and advances on semi-supervised learning. *Journal of Shanxi University (Natural Science Edition)*, 32(4): 528-534 (梁吉业, 高嘉伟, 常瑜. 2009. 半监督学习研究进展. 山西大学学报(自然科学版), 32(4): 528-534) [DOI: 10.13451/j.cnki.shanxi.univ(nat.sci.).2009.04.030]
- Liu C, Xing C Z, Hu Q H, Wang S S, Zhao S H and Gao M. 2022. Stereoscopic hyperspectral remote sensing of the atmospheric environment: innovation and prospects. *Earth-Science Reviews*, 226: 103958 [DOI: 10.1016/j.earscirev.2022.103958]
- Liu Q C, Xiao L, Yang J X and Wei Z H. 2021. CNN-enhanced graph convolutional network with pixel- and superpixel-level feature fusion for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 59(10): 8657-8671 [DOI: 10.1109/TGRS.2020.3037361]
- Liu Q C, Xiao L, Yang J X and Wei Z H. 2022b. Multilevel superpixel structured graph U-nets for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5516115 [DOI: 10.1109/TGRS.2021.3112586]
- Liu Q W, Dong Y N, Zhang Y X and Luo H. 2022a. A fast dynamic graph convolutional network and CNN parallel network for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5530215 [DOI: 10.1109/TGRS.2022.3179419]
- Liu W, Han L, Liu M and Li L Z. 2023. Inversion of Cd content in soil around mining area based on GaoFen-5 hyperspectral band selec-

- tion. *Laser and Optoelectronics Progress*, 60(17): 1728001 (刘雯, 韩玲, 刘明, 李良志. 2023. 基于高分五号高光谱波段选择的矿区周边土壤 Cd 含量反演. 激光与光电子学进展, 60(17): 1728001)
- Liu Y N. 2021. Development of hyperspectral imaging remote sensing technology. *National Remote Sensing Bulletin*, 25(1): 439-459 (刘银年. 2021. 高光谱成像遥感载荷技术的现状与发展. 遥感学报, 25(1): 439-459) [DOI: 10.11834/jrs.20210283]
- Liu Y N, Xue Y Q, Wang J Y and Shen M M. 2002. Operational modular imaging spectrometer. *Journal of Infrared and Millimeter Waves*, 21(1): 9-13 (刘银年, 薛永祺, 王建宇, 沈鸣明. 2002. 实用型模块化成像光谱仪. 红外与毫米波学报, 21(1): 9-13) [DOI: 10.3321/j.issn:1001-9014.2002.01.003]
- Long J, Liang W, Li K C, Wei Y H and Marino M D. 2023. A regularized cross-layer ladder network for intrusion detection in industrial internet of things. *IEEE Transactions on Industrial Informatics*, 19(2): 1747-1755 [DOI: 10.1109/TII.2022.3204034]
- Lopes I, Silva A, Coimbra M, Dinis-Ribeiro M, Libanio D and Renna F. 2022. Supervised and semi-supervised training of deep convolutional neural networks for gastric landmark detection//2022 44th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Glasgow: IEEE: 2025-2028 [DOI: 10.1109/EMBC48229.2022.9870992]
- Lu X C, Zhang J P, Li T and Zhang Y. 2016. A novel synergetic classification approach for hyperspectral and panchromatic images based on self-learning. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8): 4917-4928 [DOI: 10.1109/TGRS.2016.2553047]
- Lucas R, Bunting P, Paterson M and Chisholm L. 2008. Classification of Australian forest communities using aerial photography, CASI and HyMap data. *Remote Sensing of Environment*, 112(5): 2088-2103 [DOI: 10.1016/j.rse.2007.10.011]
- Lv Q Z, Feng W, Quan Y H, Dauphin G, Gao L R and Xing M D. 2021. Enhanced-random-feature-subspace-based ensemble CNN for the imbalanced hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 3988-3999 [DOI: 10.1109/JSTARS.2021.3069013]
- Ma Z T, Jiang Z G and Zhang H P. 2022. Hyperspectral image classification using feature fusion hypergraph convolution neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5517314 [DOI: 10.1109/TGRS.2021.3123423]
- McFee J E and Ripley H T. 1997. Detection of buried land mines using a CASI hyperspectral imager//Proceedings Volume 3079, Detection and Remediation Technologies for Mines and Minelike Targets II. Orlando: SPIE: 738-749 [DOI: 10.1117/12.280902]
- Mei X G, Pan E T, Ma Y, Dai X B, Huang J, Fan F, Du Q L, Zheng H and Ma J Y. 2019. Spectral-spatial attention networks for hyperspectral image classification. *Remote Sensing*, 11(8): 963 [DOI: 10.3390/rs11080963]
- Meng X T, Bao Y L, Liu J G, Liu H J, Zhang X L, Zhang Y, Wang P, Tang H T and Kong F C. 2020. Regional soil organic carbon prediction model based on a discrete wavelet analysis of hyperspectral satellite data. *International Journal of Applied Earth Observation and Geoinformation*, 89: 102111 [DOI: 10.1016/j.jag.2020.102111]
- Meng X T, Bao Y L, Ye Q, Liu H J, Zhang X L, Tang H T and Zhang X H. 2021. Soil organic matter prediction model with satellite hyperspectral image based on optimized denoising method. *Remote Sensing*, 13(12): 2273 [DOI: 10.3390/rs13122273]
- Merz C J, Clair D C and Bond W E. 1992. SeMi-supervised adaptive resonance theory (SMART2)//International Joint Conference on Neural Networks. Baltimore: IEEE: 851-856 [DOI: 10.1109/IJCNN.1992.227046]
- Modzelewska A, Fassnacht F E and Stereńczak K. 2020. Tree species identification within an extensive forest area with diverse management regimes using airborne hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, 84: 101960 [DOI: 10.1016/j.jag.2019.101960]
- Mou L C, Lu X Q, Li X L and Zhu X X. 2020. Nonlocal graph convolutional networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 58(12): 8246-8257 [DOI: 10.1109/TGRS.2020.2973363]
- Mu H W, Zhou L, Dang X W and Yuan B. 2019. Winter wheat yield estimation from multitemporal remote sensing images based on convolutional neural networks. 2019 10th International Workshop on the Analysis of Multitemporal Remote Sensing Images(Multi-Temp). Shanghai: IEEE: 1-4 [DOI: 10.1109/Multi-Temp.2019.8866918]
- Nigam K and Ghani R. 2000. Analyzing the effectiveness and applicability of co-training//Proceedings of the Ninth International Conference on Information Knowledge Management. McLean: ACM: 86-93 [DOI: 10.1145/354756.354805]
- Odena A. 2016. Semi-supervised learning with generative adversarial networks. arXiv:1606.01583 [DOI: 10.48550/arXiv.1606.01583]
- Oerke E C, Herzog K and Toepfer R. 2016. Hyperspectral phenotyping of the reaction of grapevine genotypes to *Plasmopara viticola*. *Journal of Experimental Botany*, 67(18): 5529-5543 [DOI: 10.1093/jxb/erw318]
- Ou DP, Tan K, Du Q, Zhu J S, Wang X and Chen Y. 2019. A novel tri-training technique for the semi-supervised classification of hyperspectral images based on regularized local discriminant embedding feature extraction. *Remote Sensing*, 11(6): 654 [DOI: 10.3390/rs11060654]
- Padmanabha Reddy Y C A, Viswanath P and Reddy B E. 2018. Semi-supervised learning: a brief review. *International Journal of Engineering and Technology*, 7(1.8): 81-85 [DOI: 10.14419/ijet.v7i1.8.9977]
- Pande S and Banerjee B. 2020. Dimensionality reduction using 3D residual autoencoder for hyperspectral image classification//IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium. Waikoloa: IEEE: 2029-2032 [DOI: 10.1109/IGARSS39084.2020.9323359]

- Pise N N and Kulkarni P. 2008. A survey of semi-supervised learning methods//2008 International Conference on Computational Intelligence and Security. Suzhou: IEEE: 30-34 [DOI: 10.1109/CIS.2008.204]
- Pryzant R, Ermon S and Lobell D. 2017. Monitoring Ethiopian wheat fungus with satellite imagery and deep feature learning//2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Honolulu: IEEE: 1524-1532 [DOI: 10.1109/CVPRW.2017.196]
- Qi Z Q, Tian Y J and Shi Y. 2012. Laplacian twin support vector machine for semi-supervised classification. *Neural Networks*, 35: 46-53 [DOI: 10.1016/j.neunet.2012.07.011]
- Qin A Y, Shang Z W, Tian J Y, Wang Y L, Zhang T P and Tang Y Y . 2019. Spectral - spatial graph convolutional networks for semisupervised hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 16(2): 241-245 [DOI: 10.1109/LGRS.2018.2869563]
- Radford A, Metz L and Chintala S. 2016. Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv:1511.06434* [DOI: 10.48550/arXiv.1511.06434]
- Rajesh H M. 2004. Application of remote sensing and GIS in mineral resource mapping - An overview. *Journal of Mineralogical and Petrological Sciences*, 99(3): 83-103 [DOI: 10.2465/jmps.99.83]
- Rasti B, Hong D F, Hang R L, Ghamisi P, Kang X D, Chanussot J and Benediktsson J A. 2020. Feature extraction for hyperspectral imagery: the evolution from shallow to deep: overview and toolbox. *IEEE Geoscience and Remote Sensing Magazine*, 8(4): 60-88 [DOI: 10.1109/MGRS.2020.2979764]
- Sabale S P and Jadhav C R. 2015. Hyperspectral image classification methods in remote sensing - A review//2015 International Conference on Computing Communication Control and Automation. Pune: IEEE: 679-683 [DOI: 10.1109/ICCUBEA.2015.139]
- Sandino J, Pegg G, Gonzalez F and Smith G. 2018. Aerial mapping of forests affected by pathogens using UAVs, hyperspectral sensors, and artificial intelligence. *Sensors*, 18(4): 944 [DOI: 10.3390/s18040944]
- Scarselli F, Yong S L, Gori M, Hagenbuchner M, Tso A C and Maggini M. 2005. Graph neural networks for ranking web pages//The 2005 IEEE/WIC/ACM International Conference on Web Intelligence (WI'05). Compiegne: IEEE: 666-672 [DOI: 10.1109/WI.2005.67]
- Sellami A and Tabbone S. 2022. Deep neural networks-based relevant latent representation learning for hyperspectral image classification. *Pattern Recognition*, 121: 108224 [DOI: 10.1016/j.patcog.2021.108224]
- Shahraki F F and Prasad S. 2019. Graph convolutional neural networks for hyperspectral data classification//2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Anaheim: IEEE: 968-972 [DOI: 10.1109/GlobalSIP.2018.8645969]
- Shi Y, Tian Y J, Kou G, Peng Y and Li J P. 2011. Robust support vector machines//Optimization Based Data Mining: Theory and Applications. London: Springer: 81-105 [DOI: 10.1007/978-0-85729-504-0_5]
- Singh P S, Singh V P, Pandey M K and Karthikeyan S. 2020. One-class classifier ensemble based enhanced semisupervised classification of hyperspectral remote sensing images//2020 International Conference on Emerging Smart Computing and Informatics (ESCI). Pune: IEEE: 22-27 [DOI: 10.1109/ESCI48226.2020.9167650]
- Tang S F, Lu Z J, Wang W G and Li H. 2019. Brief description of space hyperspectral imager (invited). *Infrared and Laser Engineering*, 48(3): 0303003 (唐绍凡, 鲁之君, 王伟刚, 李欢. 2019. 航天高光谱成像仪简述(特邀). 红外与激光工程, 48(3): 0303003)
- Tao X M, Chang R, Shen W, Wang R T and Li C X. 2020. Semi-supervised KFDA algorithm based on low density separation geometry distance. *Journal of Software*, 31(2): 493-510 (陶新民, 常瑞, 沈微, 王若彤, 李晨曦. 2020. 基于低密度分割几何距离的半监督 KFDA 算法. 软件学报, 31(2): 493-510) [DOI: 10.13328/j.cnki.jos.005639]
- Teloglu H K and Aptoula E. 2021. LSTM AutoEncoders applied to semi-supervised crop classification//2021 29th Signal Processing and Communications Applications Conference (SIU). Istanbul: IEEE: 1-4 [DOI: 10.1109/SIU53274.2021.9477933]
- Tong Q X, Zhang B and Zheng L F. 2006. Hyperspectral Remote Sensing: Principles, Techniques, and Applications. Beijing: Higher Education Press (童庆禧, 张兵, 郑兰芬. 2006. 高光谱遥感: 原理、技术与应用. 北京: 高等教育出版社)
- Tong Q X, Zhang B and Zhang L F. 2016. Current progress of hyperspectral remote sensing in China. *Journal of Remote Sensing*, 20(5): 689-707 (童庆禧, 张兵, 张立福. 2016. 中国高光谱遥感的前沿进展. 遥感学报, 20(5): 689-707) [DOI: 10.11834/jrs.20166264]
- Tripathi P and Garg R D. 2023. Potential of DESIS and PRISMA hyperspectral remote sensing data in rock classification and mineral identification: a case study for Banswara in Rajasthan, India. *Environmental Monitoring and Assessment*, 195(5): 575 [DOI: 10.1007/s10661-023-11200-1]
- Vapnik V and Izmailov R. 2021. Reinforced SVM method and memorization mechanisms. *Pattern Recognition*, 119: 108018 [DOI: 10.1016/j.patcog.2021.108018]
- Vapnik V N. 1999. An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, 10(5): 988-999 [DOI: 10.1109/72.788640]
- Vincent P, Larochelle H, Lajoie I, Bengio Y and Manzagol P A. 2010. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion. *The Journal of Machine Learning Research*, 11: 3371-3408
- Wan S, Gong C, Zhong P, Du B, Zhang L F and Yang J. 2020. Multi-scale dynamic graph convolutional network for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 58(5): 3162-3177 [DOI: 10.1109/TGRS.2019.2949180]
- Wan S, Gong C, Zhong P, Pan S R, Li G Y and Yang J. 2021. Hyperspectral image classification with context-aware dynamic graph convolutional network. *IEEE Transactions on Geoscience and Remote Sensing*, 59(1): 597-612 [DOI: 10.1109/TGRS.2020.3000000]

- 2994205]
- Wan S, Yang J and Gong C. 2023. Advances of hyperspectral image classification based on graph neural networks. *Acta Electronica Sinica*, 51(6): 1687-1709 (万升, 杨健, 宫辰. 2023. 基于图神经网络的高光谱图像分类研究进展. 电子学报, 51(6): 1687-1709) [DOI: 10.12263/DZXB.20221295]
- Wang H Y, Cheng Y H, Chen C L P and Wang X S. 2021a. Semisupervised classification of hyperspectral image based on graph convolutional broad network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 2995-3005 [DOI: 10.1109/JSTARS.2021.3062642]
- Wang H Y, Cheng Y H, Chen C L P and Wang X S. 2022. Hyperspectral image classification based on domain adversarial broad adaptation network. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5517813 [DOI: 10.1109/TGRS.2021.3128162]
- Wang J J, Gao F, Dong J Y and Du Q. 2021b. Adaptive DropBlock-enhanced generative adversarial networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 59(6): 5040-5053 [DOI: 10.48550/arXiv.2201.08938]
- Wang J Z, Kong L W, Huang Z C and Xiao J. 2021. Survey of graph neural network. *Computer Engineering*, 47(4): 1-12 (王健宗, 孔令炜, 黄章成, 肖京. 2021. 图神经网络综述. 计算机工程, 47(4): 1-12) [DOI: 10.19678/j.issn.1000-3428.005832]
- Wang K F, Gou C, Duan Y J, Lin Y L, Zheng X H and Wang F Y. 2017. Generative adversarial networks: introduction and outlook. *IEEE/CAA Journal of Automatica Sinica*, 4(4): 588-598 [DOI: 10.1109/JAS.2017.7510583]
- Wang L G, Hao S Y, Wang Q M and Wang Y. 2014. Semi-supervised classification for hyperspectral imagery based on spatial-spectral Label Propagation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 97: 123-137 [DOI: 10.1016/j.isprsjprs.2014.08.016]
- Wang M W, Huang Z Q, Zhang X Y, Zhang Y L and Chen M L. 2021c. Altered mineral mapping based on ground-airborne hyperspectral data and wavelet spectral angle mapper tri-training model: case studies from Dehua-Youxi-Yongtai Ore District, Central Fujian, China. *International Journal of Applied Earth Observation and Geoinformation*, 102: 102409 [DOI: 10.1016/j.jag.2021.02409]
- Wang S, Ben H X, Hao Y B, He X N and Wang M. 2023. Boosting hyperspectral image classification with dual hierarchical learning. *ACM Transactions on Multimedia Computing, Communications, and Applications*, 19(1): 21 [DOI: 10.1145/3522713]
- Wang S, Wu L H, Jiao L C and Liu H Y. 2014. Improve the performance of co-training by committee with refinement of class probability estimations. *Neurocomputing*, 136: 30-40 [DOI: 10.1016/j.neucom.2014.01.039]
- Wu H and Prasad S. 2018. Semi-supervised deep learning using pseudo labels for hyperspectral image classification. *IEEE Transactions on Image Processing*, 27(3): 1259-1270 [DOI: 10.1109/TIP.2017.2772836]
- Wu Y, Mu G F, Qin C, Miao Q G, Ma W P and Zhang X R. 2020. Semi-supervised hyperspectral image classification via spatial-regulated self-training. *Remote Sensing*, 12(1): 159 [DOI: 10.3390/rs12010159]
- Xi B B, Li J J, Li Y S and Du Q. 2021. Semi-supervised graph prototypical networks for hyperspectral image classification//2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS. Brussels: IEEE: 2851-2854 [DOI: 10.1109/IGARSS47720.2021.9553372]
- Xi B B, Li J J, Li Y S, Song R, Xiao Y C, Du Q and Chanussot J. 2023. Semisupervised cross-scale graph prototypical network for hyperspectral image classification. *IEEE Transactions on Neural Networks and Learning Systems*, 34(11): 9337-9351 [DOI: 10.1109/TNNLS.2022.3158280]
- Xia J H, Zhang J B, Wang Y, Han L X and Yan H. 2022. WC-KNNG-PC: watershed clustering based on k-nearest-neighbor graph and Pauta Criterion. *Pattern Recognition*, 121: 108177 [DOI: 10.1016/j.patcog.2021.108177]
- Xu L Z. 2020. Research on Imaging Quality for Airborne Sweeping Hyperspectral Imager. Changchun: Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences (徐力智. 2020. 航空摆扫式成像光谱仪成像质量研究. 长春: 中国科学院长春光学精密机械与物理研究所)
- Xu M, Zhao Q Q and Jia S. 2022. Multiview spatial-spectral active learning for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5512415 [DOI: 10.1109/TGRS.2021.3095292]
- Xu Y H, Du B, Zhang L P, Cerra D, Pato M, Carmona E, Prasad S, Yokoya N, Hansch R and Le Saux B. 2019. Advanced multi-sensor optical remote sensing for urban land use and land cover classification: outcome of the 2018 IEEE GRSS data fusion contest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(6): 1709-1724 [DOI: 10.1109/JSTARS.2019.2911113]
- Yang B, Cao F L and Ye H L. 2022. A novel method for hyperspectral image classification: deep network with adaptive graph structure integration. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5523512 [DOI: 10.1109/TGRS.2022.3150349]
- Yang L, Chen J J, Wang Z, Wang W J, Jiang J J, Dong X Y and Zhang W B. 2021a. Semi-supervised log-based anomaly detection via probabilistic label estimation//2021 IEEE/ACM 43rd International Conference on Software Engineering (ICSE). Madrid: IEEE: 1448-1460 [DOI: 10.1109/ICSE43902.2021.00130]
- Yang P, Tong L, Qian B, Gao Z, Yu J and Xiao C B. 2021b. Hyperspectral image classification with spectral and spatial graph using inductive representation learning network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 791-800 [DOI: 10.1109/JSTARS.2020.3042959]
- Yu B X. 2000. Research on high-resolution imaging spectrometer (C-HRIS). *Optics, Mechanics and Electronics Information*, 17(4): 1-5 (禹秉熙. 2000. 高分辨率成像光谱仪(C-HRIS)研究. 光机电信息, 17(4): 1-5 [DOI: 10.3969/j.issn.1007-1180.2000.04.001])
- Yuan Y H and Lin Z Y. 2007. High spectrum remote sensing technolo-

- gy summary. *China Water Transport*, 7(8): 155-157 (袁迎辉, 林子瑜. 2007. 高光谱遥感技术综述. 中国水运, 7(8): 155-157)
- Yuen P W T and Richardson M. 2010. An introduction to hyperspectral imaging and its application for security, surveillance and target acquisition. *The Imaging Science Journal*, 58(5): 241-253 [DOI: 10.1179/174313110X12771950995716]
- Zhan Y, Hu D, Wang Y T and Yu X C. 2018. Semisupervised hyperspectral image classification based on generative adversarial networks. *IEEE Geoscience and Remote Sensing Letters*, 15(2): 212-216 [DOI: 10.1109/LGRS.2017.2780890]
- Zhang B W, Wang Y D, Hou W X, Wu H, Wang J D, Okumura M and Shinozaki T. 2022a. FlexMatch: boosting semi-supervised learning with curriculum pseudo labeling. arXiv:2110.08263 [DOI: 10.48550/arXiv.2110.08263]
- Zhang D and Zheng Y Q. 2013. Hyperspectral remote sensing and its development and application review. *Optics and Optoelectronic Technology*, 11(3): 67-73 (张达, 郑玉权. 2013. 高光谱遥感的发展与应用. 光学与光电技术, 11(3): 67-73) [DOI: http://ir.ciomp.ac.cn/handle/181722/38415]
- Zhang D Y, Zeng S Y and He W Q. 2022b. Selection and quantification of best water quality indicators using UAV-mounted hyperspectral data: a case focusing on a local river network in Suzhou City, China. *Sustainability*, 14(23): 16226 [DOI: 10.3390/su142316226]
- Zhang H Y, Zou J Q and Zhang L P. 2022c. EMS-GCN: an end-to-end Mixhop superpixel-based graph convolutional network for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5526116 [DOI: 10.1109/TGRS.2022.3163326]
- Zhang J L, Chang Y L and Shi W. 2013. Overview on label propagation algorithm and applications. *Application Research of Computers*, 30(1): 21-25 (张俊丽, 常艳丽, 师文. 2013. 标签传播算法理论及其应用研究综述. 计算机应用研究, 30(1): 21-25) [DOI: 10.3969/j.issn.1001-3695.2013.01.004]
- Zhang L P, Du B and Zhang L F. 2014. *Hyperspectral Remote Sensing Image Processing*. Beijing: Science Press (张良培, 杜博, 张乐飞. 2014. 高光谱遥感影像处理. 北京: 科学出版社)
- Zhang L P and Zhang L F. 2005. *Hyperspectral Remote Sensing*. Wuhan: Wuhan University Press (张良培, 张立福. 2005. 高光谱遥感. 武汉: 武汉大学出版社)
- Zhang T T, Li L and Zheng B J. 2013. Estimation of agricultural soil properties with imaging and laboratory spectroscopy. *Journal of Applied Remote Sensing*, 7(1): 073587 [DOI: 10.1117/1.JRS.7.073587]
- Zhang Y X, Liu K, Dong Y N, Wu K and Hu X Y. 2020a. Semisupervised classification based on SLIC segmentation for hyperspectral image. *IEEE Geoscience and Remote Sensing Letters*, 17(8): 1440-1444 [DOI: 10.1109/LGRS.2019.2945546]
- Zhang Z, Pasolli E and Crawford M M. 2020b. An adaptive multiview active learning approach for spectral-spatial classification of hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 58(4): 2557-2570 [DOI: 10.1109/TGRS.2019.2952319]
- Zhao H Y, Xie J Z and Wang H B. 2022a. Graph convolutional network based on multi-head pooling for short text classification. *IEEE Access*, 10: 11947-11956 [DOI: 10.1109/ACCESS.2022.3146303]
- Zhao J L, Hu L, Dong Y Y, Huang L S, Weng S Z and Zhang D Y. 2021. A combination method of stacked autoencoder and 3D deep residual network for hyperspectral image classification. *International Journal of Applied Earth Observation and Geoinformation*, 102: 102459 [DOI: 10.1016/j.jag.2021.102459]
- Zhao X F, Niu J H, Liu C T, Ding Y and Hong D F. 2022b. Hyperspectral image classification based on graph transformer network and graph attention mechanism. *IEEE Geoscience and Remote Sensing Letters*, 19: 6010605 [DOI: 10.1109/LGRS.2022.3182156]
- Zhong J P, Xie W Y, Li Y S, Lei J and Du Q. 2021. Characterization of background-anomaly separability with generative adversarial network for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 59(7): 6017-6028 [DOI: 10.1109/TGRS.2020.3013022]
- Zhong S W, Zhou T, Wan S, Yang J and Gong C. 2022. Dynamic spectral-spatial Poisson learning for hyperspectral image classification with extremely scarce labels. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5517615 [DOI: 10.1109/TGRS.2021.3125353]
- Zhou J L, Jing B Y, Wang Z Y, Xin H Y and Tong H H. 2022b. SODA: detecting COVID-19 in chest X-rays with semi-supervised open set domain adaptation. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 19(5): 2605-2612 [DOI: 10.1109/TCBB.2021.3066331]
- Zhou L H, Warner J, Nalli N R, Wei Z G, Oh Y, Bruhwiler L, Liu X P, Divakarla M, Pryor K, Kalluri S and Goldberg M D. 2023. Spatio-temporal variability of global atmospheric methane observed from two decades of satellite hyperspectral infrared sounders. *Remote Sensing*, 15(12): 2992 [DOI: 10.3390/rs15122992]
- Zhou Y, Xie H T, Fang S C and Zhang Y D. 2022a. Semi-supervised text detection with accurate pseudo-labels. *IEEE Signal Processing Letters*, 29: 1272-1276 [DOI: 10.1109/LSP.2022.3175667]
- Zhou Z H. 2018. A brief introduction to weakly supervised learning. *National Science Review*, 5(1): 44-53 [DOI: 10.1093/nsr/nwx106]
- Zhou Z H and Li M. 2005. Tri-training: exploiting unlabeled data using three classifiers. *IEEE Transactions on Knowledge and Data Engineering*, 17(11): 1529-1541 [DOI: 10.1109/TKDE.2005.186]
- Zhou Z H and Li M. 2007. Semisupervised regression with cotraining-style algorithms. *IEEE Transactions on Knowledge and Data Engineering*, 19(11): 1479-1493 [DOI: 10.1109/TKDE.2007.190644]
- Zhu X J. 2008. *Semi-Supervised Learning Literature Survey*. Madison: University of Wisconsin-Madison
- Zhu X J and Ghahramani Z. 2002. Learning from labeled and unlabeled data with label propagation. *Tech Report*, 3175(2004), 237-244 [DOI: 10.1007/978-3-540-28649-3_29]
- Zou Y, Yu Z D, Kumar B V K V and Wang J S. 2018. Domain adaptation for semantic segmentation via class-balanced self-training. arXiv:1810.07911 [DOI: 10.48550/arXiv.1810.07911]

Advances in semi-supervised classification of hyperspectral remote sensing images

YANG Xing^{1,2}, FANG Leyuan^{1,2}, YUE Jun³

1.Hunan University, Electrical and Information Engineering, Changsha 410080, China;

2.Pengcheng Laboratory, Shenzhen 518055, China;

3.Central South University, College of Automation, Changsha 410083, China

Abstract: Hyperspectral remote sensing technology has been widely used in remote sensing, agriculture, geological exploration, and other fields, and hyperspectral image classification is one of the most important research directions. Benefiting from sufficient label information, supervised learning has achieved good results in this field. However, in many practical applications of hyperspectral remote sensing images, sufficient label samples are difficult to obtain. One of the most important reasons is the widespread use of hyperspectral remote sensing technology, which produces huge amounts of unlabeled data. Another is the high cost of labeling. Meanwhile, unsupervised learning cannot accurately cluster unknown data, and its clustering categories are to match to real categories. Both supervised and unsupervised learning have their unavoidable disadvantages. Therefore, semi-supervised learning that uses a large number of unlabeled samples and a small number of labeled samples should be explored. In recent years, significant progress has been made in the semi-supervised classification of hyperspectral remote sensing images. Researchers have proposed many innovative algorithms and technologies to address the problem of insufficient data annotation. This article reviews the progress of the semi-supervised classification research on hyperspectral remote sensing images in recent years, discussing key technologies and methods.

This paper starts with semi-supervised classification and hyperspectral remote sensing technologies. First, the first part of this paper introduces some basic concepts of semi-supervised learning, including semi-supervised and unsupervised learning, supervised learning, and the application of semi-supervised learning. The second part introduces the development of hyperspectral remote sensing imaging technology domestically and internationally and the application of hyperspectral remote sensing in various fields, such as land and resource surveys, agriculture and forestry remote sensing, and urban environmental monitoring. Second, the three basic assumptions of the theory, process, and data distribution of semi-supervised learning are analyzed, and four typical types are introduced: low-density separation, generative, disagreement-based (difference-based), and graph-based methods. The algorithm flow and core ideas of each method are introduced in detail. The summarized current development status, typical algorithms, and research progress of hyperspectral remote sensing image classification are analyzed. Further, the advantages and disadvantages of each algorithm are enumerated. Then, common open-source algorithms were compared on three publicly available datasets, namely, Indian Pines, Pavia University, and Houston 2013. Finally, by analyzing existing semi-supervised learning technologies and experimental results, the challenging problems and development trends of semi-supervised learning in hyperspectral remote sensing are summarized.

The graph-based semi-supervised classification method performs better than other semi-supervised classification methods, which may be because the graph model can model the relationship and similarity between samples, connect similar samples, and capture the intrinsic structure and similarity in a dataset.

Semi-supervised learning can efficiently utilize both labeled data and unlabeled data. The future development trend of semi-supervised classification is mainly in three aspects: how to effectively use a large number of unlabeled samples; how to fully consider multiple factors, such as performance and computational complexity; and how to select features. These aspects will affect the stability, generalization, practicability, and performance of the algorithm.

Key words: hyperspectral image, semi-supervised classification, low-density separation, generative model, graph neural network

Supported by National Natural Science Foundation of China (No.U22B2014, 62101072); Hunan Provincial Natural Science Foundation of China (No.2021JJ40570)