

基于深度图卷积网络的自监督群体发现模型

王栽胜, 汪晓锋*, 沈国栋, 张增杰, 全大英

(中国计量大学 信息工程学院, 杭州 310018)

摘 要: 为缓解图神经网络在群体发现任务中对先验知识的过度依赖并提高识别准确性, 提出了一种基于自监督学习和深度图卷积网络 (GCN) 的群体发现模型。该模型充分利用少量标记节点的语义特征, 并通过语义对齐机制获得未知节点的伪标签, 从而引入一种自监督学习模块以缓解 GCN 模型训练过程中对大量先验标签的依赖性。同时, 为通过获取网络全局信息以提高群体识别的准确性, 通过堆叠多个自监督学习模块构建一种深度图自监督学习模型, 并利用初始残差和恒等映射 2 种策略来克服深度模型带来的过平滑问题。在公开数据集上的实验表明: 在给定少量先验标签和加深模型深度的情况下, 所提模型与现有模型相比在群体识别精度上表现出了明显优势。

关 键 词: 复杂网络; 群体发现; 图卷积网络; 残差连接; 自监督学习

中图分类号: TP39

文献标志码: A

文章编号: 1001-5965(2025)06-2022-11

目前, 复杂网络已经成为描述和建模复杂系统的通用语言^[1], 其将复杂系统中的个体及个体间的相互关系表示为由节点和连边组成的图结构。同时, 复杂网络广泛应用于现实网络场景中, 如社交网络、生物网络、引文网络等^[2]。大量研究表明, 复杂网络中的节点呈现出普遍的群体聚集特性, 群体结构已成为复杂网络的一种重要中观结构特征^[3]。群体结构通常与复杂系统中相应功能模块及群体属性有着紧密联系, 因此, 有效揭示复杂网络中的群体结构对于分析网络节点特征、结构属性、群体行为模式等问题有着重要意义, 同时为研究网络动态演化机制、信息传播规律、群体行为分析等提供重要的理论支撑^[4]。群体发现是网络科学中的重要研究问题之一, 其相关技术已大量应用于社交网络分析、信息检索与推荐、公共安全事件管控与生物结构预测等领域^[5]。近年来, 随着信息技术和大数据的快速发展, 网络应用场景变得复杂多样, 除了复杂的拓扑结构外, 还存在大量的与节点及网络相

关的属性信息, 如文本、图像、节点语义等, 这给群体发现任务带来了极大挑战^[6]。

群体发现旨在从未标记的网络中识别具有潜在相似属性或功能的节点集合, 通常被当作一种节点聚类任务来研究。由于不同领域学者的研究视角不同, 目前对群体结构没有统一的定义, 从而导致群体发现方法多样但普适性较低。早期的群体发现工作也称社区发现, 主要基于网络拓扑特性将整个网络按某种相似性或划分标准划分为不同子图结构, 典型的方法有基于图划分和节点/边聚类^[7]。然而, 针对当前多源异构的复杂网络, 传统方法很难同时整合高维结构信息和内容属性信息, 如矩阵分解^[8]、贝叶斯模型^[9]等。为解决该问题, 近年来深度学习技术不断被引入到图数据挖掘中, 形成了新兴的图深度学习研究领域^[10]。基于图深度学习的群体发现方法通过对高维图数据进行分布式表示学习, 并提取具有判别性的节点特征用于群体识别。相比传统方法, 图深度学习技术在网络群体

收稿日期: 2023-06-21; 录用日期: 2023-11-21; 网络出版时间: 2023-12-06 13:16
网络出版地址: link.cnki.net/urlid/11.2625.V.20231205.1639.003
基金项目: 浙江省自然科学基金 (LQ20F020021); 国家重点研发计划 (2019YFB1707104)
*通信作者. E-mail: xfwang@cjlu.edu.cn

引用格式: 王栽胜, 汪晓锋, 沈国栋, 等. 基于深度图卷积网络的自监督群体发现模型 [J]. 北京航空航天大学学报, 2025, 51 (6): 2022-2032. WANG Z S, WANG X F, SHENG G D, et al. Self-supervised learning for community detection based on deep graph convolutional networks [J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51 (6): 2022-2032 (in Chinese).

发现任务中有效融合了高维图数据和节点属性, 从而提高群体发现的效率及准确性。此外, 图深度学习模型相比传统模型能更有效地处理大规模、稀疏的复杂网络数据。

目前, 许多用于群体发现的图深度学习模型相继被提出^[1], 包括图卷积网络 (graph convolutional network, GCN)^[12]、图注意力网络 (graph attention network, GAT)^[13] 和图生成对抗网络 (graph generative adversarial network, GraphGAN)^[14] 等。其中, GCN 是图深度学习的一个重要分支, 在各种图挖掘任务中广泛应用。对于群体发现问题, GCN 通过图卷积操作来聚合邻域节点信息, 可同时融合网络拓扑结构和节点属性来学习复杂的节点特征以识别群体。近年来, GCN 及其变体在群体发现任务中表现出了明显优势^[15-17], 但大多数方法仍是基于浅层的 GCN 模型, 即利用 2~3 层图卷积操作来聚合邻域信息, 从而忽略了高阶邻域信息对群体发现的影响。然而, 简单地叠加更多的卷积层会导致模型过平滑问题, 即随着卷积层增加, 网络节点的特征表示会趋于相似而变得难以区分, 使得模型性能急剧下降。为此, 近年来一些学者提出了改进模型以解决深度 GCN 带来的过平滑问题^[18-20]。尽管这些改进模型一定程度上缓解了过平滑问题, 但随着模型进一步加深, 性能下降明显。

同时, 作为一种半监督学习模型, GCN 模型在训练过程中依赖大量先验的带标签节点, 而真实网络场景下大多数节点的群体标签是未知的, 这给半监督的群体发现任务带来了极大挑战。近年来, 自监督学习 (self-supervised learning, SSL) 由于可缓解模型对先验知识的依赖而受到大量关注, 并逐渐应用于图深度学习领域^[21]。自监督学习旨在根据数据本身设计辅助任务以挖掘数据的表征特性作为监督信息, 来提升模型的特征提取能力。You 等^[22] 利用预先计算的聚类索引作为自监督信息, 提出一种自监督节点聚类方法。为同时利用网络结构和属性信息, 无监督图表示学习的集群感知图神经网络 (cluster-aware graph neural network, CAGNN) 模型^[23] 利用聚类标签作为自监督信号来实现无监督的网络表示学习。此外, 多阶段自监督学习 (multi-stage self-supervised learning, M3S) 模型^[24] 及自监督语义对齐图卷积网络 (self-supervised semantic alignment graph convolution network, Self-SAGCN)^[25] 等典型的图自监督学习模型相继被提出以缓解 GCN 对先验标签的过度依赖, 但这些方法仍基于浅层的网络结构。

综上所述, 针对群体发现任务, 目前基于

GCN 的图神经网络模型大都采用半监督学习范式, 尽管相对于无监督模型能够取得较高的识别精度, 但过度依赖于先验标签。同时, 浅层的 GCN 结构进一步限制了模型捕获全局信息的能力。尽管自监督学习技术的引入不同程度上缓解了模型对大量标签的依赖, 但模型性能仍会随着模型的加深而不断下降。因此, 如何设计一种不依赖大量训练标签同时保持较高性能的 GCN 模型仍然是一个值得研究的问题。

因此, 本文提出一种基于深度 GCN 的自监督群体发现模型。该模型在图卷积操作的基础上引入了一种自监督学习模块, 以利用特征聚合从少量标记节点中提取语义信息, 并利用语义对齐机制来获得未知节点的伪标签, 采用伪标签训练模型, 从而降低模型对已知标签的依赖性。同时, 为利用高阶领域信息来提高群体识别的准确性, 通过堆叠多层自监督学习模块构建一种深度图自监督学习模型, 利用初始残差和恒等映射 2 种策略来缓解深度模型带来的过平滑问题。通过在真实网络数据集的实验, 验证了该模型在给定少量先验标签的情况下, 加深模型深度仍能取得较好的效果。

1 相关工作

1.1 群体发现

群体发现作为网络科学中的一个重要课题, 在过去 10 年中得到了广泛研究。早期的大量研究工作对网络群体结构提出了各种不同定义, 并相应地设计了各种群体发现方法。传统方法包括层次聚类^[26]、模块度优化^[27] 及谱聚类^[28] 等, 主要利用网络拓扑特征来识别群体, 也称为社区发现。Louvain 方法^[29] 通过贪婪地优化模块度以揭示社区结构的层次性, 随机块模型 (stochastic block model, SBM)^[30] 通过控制连接边生成的概率来生成不相交的群体结构。此外, 带有扰动的谱聚类 (spectral clustering with perturbations, SCP)^[31] 方法通过归一化拉普拉斯矩阵和正则化邻接矩阵来划分网络。然而, 传统方法特别是涉及到矩阵分解的方法存在计算复杂度高的问题, 无法应用于大规模网络。同时, 随着当前网络环境的复杂化, 除网络拓扑场景外, 大量与网络或节点相关的高维属性信息未得到充分利用。因此, 大多数传统方法已无法适用于大规模、多源异构的复杂网络。

近年来, 深度学习技术被引入到图表示学习中以克服上述挑战^[5]。基于图深度学习的群体发现方法能同时利用网络结构特征和高维属性信息, 可更好地适应复杂场景中的群体发现任务。GCN^[12] 作

为图深度学习中最重要图神经网络模型之一,在群体发现中被广泛应用。Jin 等^[15]提出了一个基于半监督 GCN 的 MRFasGCN 模型,该模型通过将马尔可夫随机场 (Markov random field, MRF) 扩展为一个新的卷积层来表征隐藏群体,再与 GCN 模型相结合以构成端对端的群体发现模型。为实现无监督群体发现, Hu 等^[16]提出了一种图卷积梯形网络 (graph convolutional ladder-shape network, GCLN) 模型,先对称地构建收缩路径和扩展路径,再从收缩路径中捕获上下文特征,与在扩展路径中学习到的本地化信息融合在一起进行群体发现。同时, Jin 等^[17]提出了一种通过嵌入属性网络的联合 GCN 进行社区检测 (community detection via joint graph convolutional network embedding in attribute network, JGE-CD) 模型,该模型由基于 GCN 的双编码器、群体发现模块及拓扑重构模块组成,通过联合嵌入学习过程来实现群体发现任务。此外,一些工作将对比学习与 GCN 相结合来识别属性网络中的群体结构。Zhang 等^[32]通过节点和群体上的互信息 (mutual information, MI) 联合优化图表示和聚类,提出了一种基于互信息最大化图对比学习的群体发现模型 (community deep graph infomax, CommDGI)。Zhao 等^[33]提出了一种图去偏对比学习模型以同时进行节点表示学习和聚类,该模型通过将节点表示与聚类结果进行对齐以实现联合优化,从而学习到更具有区分性的节点表示和聚类结果。

总体来说,半监督的 GCN^[12]被大量用于群体发现问题,但 GCN 在训练过程中需要大量带标签节点,同时随着网络层次的加深,不可避免地带来了过平滑问题。为缓解深度模型带来的过平滑问题,基于 GCN 的各种变体及改进模型相继被提出。Xu 等^[18]提出的 JKNet (jumping knowledge network) 模型,以半监督的方式将前一层的输出与密集跳跃连接相结合,以保留节点的局部特征。在此基础上, Chen 等^[20]提出了 GCNII (graph convolutional network via initial residual and identity mapping) 模型,通过初始残差和恒等映射 2 种方法,极大地缓解了深度卷积网络带来的过度平滑问题。Rong 等^[19]通过随机删除输入图中的一些边来减少过平滑的影响,提出了一种 DropEdge 模型。此外,为降低训练模型对标签的依赖性, Wang 等^[34]提出了一种基于 GCN 的属性网络社区检测无监督学习模型,通过局部标签采样模型定位群体的结构中心,并通过 GCN 对网络拓扑和节点属性进行编码,从而在没有任何先验信息的情况下推断节点的群体标签。无监督方法减少了对已知标签的依赖,同时也降低了模型的

性能。

1.2 图自监督学习

自监督学习通过精心设计的辅助任务来挖掘数据自身的表征特性作为监督信息,提升模型的特征提取能力,已成为图数据挖掘的一个重要方向^[35]。由于图域的复杂网络有着复杂的数据结构,图域的自监督学习可通过设计各种辅助任务来获取监督信息。在图自监督学习中,图神经网络^[10]通常作为编码器,从下游任务的输入图中学习节点表示。图自监督学习的核心是如何设计有效的辅助任务。现有相关工作中的辅助任务可主要分为 3 类:掩码特征回归、图对比学习和辅助属性预测 (auxiliary property prediction, APP)。本文工作主要涉及基于辅助属性预测的图自监督学习。

基于辅助属性预测的自监督学习方法的基本思想是:通过预测结构和属性构建各种辅助任务来提供自监督信息。Jin 等^[36]提出通过预测节点特定属性或全局结构信息,如计算未标记节点和预定义集群之间的距离,以构建局部结构感知的辅助任务。此外,另一部分基于分类的辅助属性预测方法通过构建伪标签来指导模型训练。Sun 等^[24]引入了基于 DeepCluster 的多阶段自训练机制,并利用嵌入空间对齐机制来获得高置信度的伪标签以扩展标签数据,从而提出了一种 M3S 模型以缓解 GCN 对大量先验标签的依赖。然而,由于过平滑问题,如大多数基于 GCN 的自监督学习模型(包括 M3S)都利用了 GCN 的浅层架构,极大限制了节点标签信息的有效传播。因此, Yang 等^[25]提出了 Self-SAGCN 模型,该网络通过特征聚合和语义对齐来缓解多层引起的过平滑和过拟合问题,然而,其仅在 4 层结构时达到了最佳性能,随着更多卷积层的堆叠,性能下降明显。因此,如何缓解深度模型的过平滑问题和降低模型对已知标签依赖性仍然是一个挑战。为此,本文引入了一种用于群体发现的深度自监督学习模型,该模型有效弥补了 GCN 及自监督学习方法存在的不足。

2 基于深度自监督 GCN 的群体发现

2.1 基本定义

对于一个无向的属性网络,可表示为图 $G = (V, E, X)$, 其中, $V = \{v_i\}_{i=1,2,\dots,N}$ 表示网络节点集合, N 表示节点数量, E 为节点连边集合, $X \in \mathbf{R}^{N \times F}$ 为网络属性矩阵,其包含各节点的 F 维实值属性向量。 $A \in \mathbf{R}^{N \times N}$ 表示网络对应的邻接矩阵,当节点 v_i 和节点 v_j 之间存在连边时,则 $A_{ij} = 1$, 否则 $A_{ij} = 0$ 。

$\mathbf{D} \in \text{diag}(d_1, d_2, \dots, d_i)$ 表示图 G 对应的度矩阵, 其中,

$$d_i = \sum_{j=1}^n A_{ij}.$$

GCN 将传统的卷积神经网络 (convolutional neural network, CNN) 推广到图域, 目前主要有空域 GCN 和频域 GCN 这 2 种类型, 本文主要采用频域 GCN, 也即常规意义下的 GCN。GCN 通过在频域上分解图信号并对频域分量应用频谱滤波器来定义卷积操作。图卷积的逐层传播规则可以表示为

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

式中: $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N$ 为添加了自环的无向图 G 的邻接矩阵, $\mathbf{I}_N$ 为单位矩阵; $\mathbf{H}^{(l)}$ 为第 l 层的输出矩阵, $\mathbf{H}^{(0)} = \mathbf{X}$, $l = \{0, 1, \dots, L-1\}$ 为卷积层层数; $\mathbf{W}^{(l)}$ 为特定层的可训练权重矩阵; $\sigma(\cdot)$ 表示激活函数, 如 ReLU。

通过重归一化技巧, 将 $\tilde{\mathbf{P}}$ 表示为 $\tilde{\mathbf{P}} = \tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}}$, 则式 (1) 可进一步简化为

$$\mathbf{H}^{(l+1)} = \sigma \left(\tilde{\mathbf{P}} \mathbf{H}^{(l)} \mathbf{W}^{(l)} \right) \quad (2)$$

2.2 模型整体框架

本文基于自监督学习和深度 GCN (self-supervi-

sion learning based on deep graph convolutional network, SDGCN) 的群体发现模型的整体结构如图 1 所示, 其中, 输入图中的不同颜色表示不同类别的节点。一方面, 为充分利用节点的语义信息, 模型在传统 GCN 基础上增加了一个语义特征提取通道, 并以自监督学习的方式来降低模型对大量先验标签的依赖; 另一方面, 为有效缓解过平滑影响, 模型引入了初始残差和恒等映射来加深模型深度。此外, 为加快模型训练过程, 本文模型的输入和输出端分别使用了一个全连接层以降低节点特征维度。从模型构成来看, 该模型可分为自监督学习模块和深度 GCN 这 2 个层次。具体地, 自监督学习模块利用语义对齐机制来获取节点特征为未知节点提供判别信息以扩展训练标签, 以自监督学习模块作为基础层进行叠加来构建深度自监督学习 GCN。同时, 在每层输入都融合初始输入, 以确保模型在堆叠了很多层后仍使得每个节点表示中至少保留了一部分来自输入层的原始特征。此外, 恒等映射策略的引入有效缓解了深度模型带来的训练参数过多的问题。与 Self-SAGCN 相比, 本文模型将带有自监督学习机制的 GCN 进行了加深, 更有效缓解了过平滑问题。




图 1 本文模型整体框架

Fig. 1 Overall framework of the proposed model

2.3 自监督学习模块

基于大量先验的训练数据, 传统 GCN 在半监督节点分类任务中取得了巨大的成功, 然而在群体发现任务中, 大多数节点的标签信息通常是难以获取的, 而人工标注成本是非常昂贵的。因此, 利用自监督学习技术设计辅助任务来挖掘无标签数据自身的表征特性作为监督信息以减少模型对先验知识的依赖成为了一种有效途径。对于群体发现来说, 属于同一群体结构的节点间的连接更加紧密, 同时更倾向于共享相同的语义特征及标签。因此, 在给定少量先验标记节点的情况下, 模型训练过程可利用 GCN 的局部特征聚合过程, 通过自监督学习的方式提取节点语义信息来分配伪标签并扩展训练集。因此, 本文基于 GCN 模型引入了一

种自监督学习模块, 将属性图和先验标签信息分别作为 2 个不同的输入, 通过语义对齐机制提取监督信息, 该模块结构如图 2 所示, 其中, 输入图中的不同颜色表示不同类别的节点。




图 2 自监督学习模块结构框图

Fig. 2 Structure of the self-supervised learning module

给定一个无向图 G , 将其特征矩阵 $\mathbf{H}^{(k)}$ 作为第一个输入, k 为卷积层层数, 且 $\mathbf{H}^{(0)} = \mathbf{X}$ 。为从已知节点学习语义特征, 构造一个输入 $\mathbf{F}_E^{(k)}$, 通过单位矩阵 $\mathbf{I}$ 的特征聚合提取标记节点集 E 的语义信息, 其中, $\mathbf{F}_E^{(0)} = \mathbf{X}_E$ 表示带标签的节点属性。因此, 该输入经过卷积层的输出可表示为

$$\mathbf{H}^{(k+1)} = \sigma(\tilde{\mathbf{P}}\mathbf{H}^{(k)}\mathbf{W}^{(k+1)}) \quad (3)$$

$$\mathbf{F}_E^{(k+1)} = \sigma(\mathbf{I}\mathbf{F}_E^{(k)}\mathbf{W}^{(k+1)}) \quad (4)$$

为在模型训练期间利用来自少数标记节点的先验信息并指导特征 $\mathbf{H}^{(k)}$, 本文进一步采用语义对齐来确保 $\mathbf{H}^{(k)}$ 和 $\mathbf{F}_E^{(k)}$ 中来自同一群体的节点特征在邻域映射。对于 $\mathbf{H}^{(k)}$ 和 $\mathbf{F}_E^{(k)}$ 中的带标签节点, 直接应用相应的标签作为集群信息, 对于 $\mathbf{H}^{(k)}$ 中的未标记节点, 根据当前网络参数为节点分配伪标签。将伪标签与从已知标签中提取的语义信息进行语义对齐。具体来说, 模型在训练过程中, 利用已知标签的语义信息建立与伪标签节点间的语义对应关系, 从而确定具有相同类别特征的未标记节点。为减轻伪标签对节点划分的负面影响, 利用标记节点和未标记节点的中心相似性来提供额外的监督信息。自监督学习模块的损失定义如下:

$$\mathcal{L}_S = \sum_{j=1}^c d(C_j(\mathbf{F}_E^{(k)}), C_j(\mathbf{H}^{(k)})) \quad (5)$$

式中: d 为平方欧几里得距离函数; $C_j(\cdot)$ 表示第 j 类特征的质心。此外, $\mathbf{H}^{(k)}$ 中的伪标签在 $\mathbf{H}^{\text{out}}$ 中采用。

另外, 由于利用伪标签构建的质心在半监督群体发现任务中可能缺乏稳定性, 模型在每次迭代过程中, 用 $\mathbf{H}^{(k)}$ 和 $\mathbf{F}_E^{(k)}$ 对应的特征来更新 $C_j'(\mathbf{H}^{(k)})$ 和 $C_j'(\mathbf{F}_E^{(k)})$ 的质心, 并添加质心最后一次迭代来抑制不稳定性。质心更新过程定义如下:

$$C_j'(\mathbf{H}^{(k)}) \leftarrow (1-\alpha)C_j'(\mathbf{H}^{(k)}) + \alpha C_j^{(t-1)}(\mathbf{H}^{(k)}) \quad (6)$$

$$C_j'(\mathbf{F}_E^{(k)}) \leftarrow (1-\alpha)C_j'(\mathbf{F}_E^{(k)}) + \alpha C_j^{(t-1)}(\mathbf{F}_E^{(k)}) \quad (7)$$

式中: $\alpha \in [0, 1]$ 用来平衡权重。

2.4 深度 GCN

尽管自监督学习模块理论上可利用节点语义特征来降低模型对先验标签的依赖, 但浅层结构仍难以捕获高阶邻域信息而取得理想的群体识别精度, 因此, 需要进一步加深模型结构。然而, 与原始 GCN 模型类似, 叠加更多的自监督学习模块同样会带来过平滑问题。受 ResNet^[37] 模型的启发, 本文尝试在模型中引入初始残差连接和恒等映射 2 种模型优化策略。

研究表明, 残差连接只能缓解深度 GCN 模型的过度平滑问题, 随着层数的增加, 其性能仍然会

下降。因此, 受 GCNII 模型启发, 本文将残差连接替换为初始残差连接, 区别在于: 初始残差连接模拟 ResNet 中的跳跃连接, 其构建初始层到输出层的连接, 而不是深度模型中常用的逐层残差连接。在使用初始残差连接情况下, 即使模型堆叠了更多层, 也能确保最终节点表示保留至少一部分来自输入层的信息。与传统 GCN 模型不同, SDGCN 群体发现模型提供 2 个不同的输入, 其中, 使用特征矩阵 $\mathbf{H}^{(0)}$ 作为第一个输入, 为提取已知标签中的语义信息, 通过特征聚合构造另一个输入 $\mathbf{F}^{(0)}$ 。因此, 将初始残差加入到 GCN 模型后, 网络模型的卷积层定义如下:

$$\mathbf{H}^{(l+1)} = \sigma(((1-\alpha_l)\tilde{\mathbf{P}}\mathbf{H}^{(l)} + \alpha_l\mathbf{H}^{(1)})\mathbf{W}^{(l)}) \quad (8)$$

$$\mathbf{F}^{(l+1)} = \sigma(((1-\alpha_l)\mathbf{I}\mathbf{F}^{(l)} + \alpha_l\mathbf{F}^{(1)})\mathbf{W}^{(l)}) \quad (9)$$

式中: α_l 为超参数; $\tilde{\mathbf{P}} = \tilde{\mathbf{D}}^{-\frac{1}{2}}\tilde{\mathbf{A}}\tilde{\mathbf{D}}^{-\frac{1}{2}}$ 为重标准化的图卷积矩阵; $\mathbf{I}$ 为单位矩阵; $\mathbf{H}^{(1)}$ 为第一层的初始残差连接。因此, 将初始层 $\mathbf{H}^{(1)}$ 添加到卷积层 $\tilde{\mathbf{P}}\mathbf{H}^{(l)}$ 中, 通过 α_l 来控制初始残差的比重, 其完整形式为 $(1-\alpha_l)\tilde{\mathbf{P}}\mathbf{H}^{(l)} + \alpha_l\mathbf{H}^{(1)}$ 。

此外, 模型同时引入了恒等映射作为补充策略。虽然初始残差极大缓解了深度图神经网络中过度平滑的问题, 但多层卷积层带来的训练参数过多的问题仍有待解决。Klicpera 等^[38] 提出了一种基于 GCN 的近似个性化传播模型 APPNP, 极大简化了训练参数。受 APPNP 的启发, 本文模型将 ResNet 的恒等映射应用到权重矩阵上, 当超参数 β_l 足够小时, 本质上可以模拟 APPNP。因此, 恒等映射可有效提高模型学习效率, 同时配合初始参数策略可确保深层模型达到与浅层模型相近的性能。实验结果也证明了恒等映射可有效提高模型的性能。基于自监督学习模块的深度 GCN 的卷积层重新定义如下:

$$\mathbf{H}^{(l+1)} = \sigma(((1-\alpha_l)\tilde{\mathbf{P}}\mathbf{H}^{(l)} + \alpha_l\mathbf{H}^{(1)})(\mathbf{I}_n + \beta_l\mathbf{W}^{(l)})) \quad (10)$$

$$\mathbf{F}^{(l+1)} = \sigma(((1-\alpha_l)\mathbf{I}\mathbf{F}^{(l)} + \alpha_l\mathbf{F}^{(1)})(\mathbf{I}_n + \beta_l\mathbf{W}^{(l)})) \quad (11)$$

式中: β_l 为超参数, 单位矩阵 $\mathbf{I}_n$ 添加到权重矩阵 $\mathbf{W}^{(l)}$ 中, 通过 β_l 来控制恒等矩阵权重, 其完整形式为 $(1-\beta_l)\mathbf{I}_n + \beta_l\mathbf{W}^{(l)}$, 体现了恒等映射的思想。

将深度 GCN 的输出映射为节点标签, 并在最小化交叉熵损失的约束下进行模型训练, 该交叉熵损失函数定义如下:

$$\mathcal{E}_D = -\sum_{i \in E} \sum_{j=1}^c (Y_{ij} \ln \mathbf{H}_{ij}^{\text{out}} + Y_{ij} \ln \mathbf{F}_{ij}^{\text{out}}) \quad (12)$$

式中: E 为标记节点的集合; $Y_i(i \in E)$ 表示 Y 中第 i 个标记节点的标记指示向量; $\mathbf{H}^{\text{out}} = \text{softmax}(\tilde{\mathbf{H}}^{(l)}) \in \mathbf{R}^{n \times c}$, $\mathbf{F}^{\text{out}} = \text{softmax}(\tilde{\mathbf{F}}^{(l)}) \in \mathbf{R}^{n \times c}$, c 为群体的数量。

将 2 部分损失联合起来, 得到整个模型最终的损失函数:

$$\mathcal{L} = \mathcal{L}_D + \lambda \mathcal{L}_S \tag{13}$$

式中: λ 为超参数, 用于调整自监督信息权重。

3 实验结果与分析

本节通过实验验证本文模型在给定少量已知节点情况下的性能表现, 以及在加深模型深度的情况下对过平滑问题的有效抑制。实验主要采用 3 个真实的引文数据集: Cora、Citeseer、PubMed。Cora 数据集由 2 708 篇机器学习领域相关的论文组成, 一篇论文至少引用或被引用于另外一篇论文, 每篇论文的特征使用 1 433 个单词表示。Citeseer 数据集由 3 327 篇机器学习领域相关的论文组成, 保留论文间引用和被引用的关系, 每篇论文的特征使用 3 703 个单词表示。PubMed 数据集由 19 717 篇生物医学领域相关的论文组成, 保留论文之间的引用和被引用关系, 每篇论文使用 500 个单词表示。论文之间的引用和被引用关系均视为无向连接。实验数据集具体信息如表 1 所示。

表 1 数据集基本信息

Table 1 Basic information of datasets

数据集	节点数	边数	社群数	特征维度
Cora	2 708	5 429	7	1 433
Citeseer	3 327	4 732	6	3 703
PubMed	19 717	44 338	3	500

本文采用 4 种不同类型的基线模型进行对比实验: ①多层感知机 (multilayer perceptron, MLP) 作为简单的神经网络模型; ②传统的图神经网络模型,

包括 GCN^[12] 和 GAT^[13]; ③深度图神经网络模型 (deep adaptive graph neural network, DAGNN)^[39] 模型; ④基于 GCN 改进的自监督学习模型 Self-SAGCN^[25]。另外, 在深度模型实验中, 本文模型 SDGCN 与另外 3 种半监督深度模型 (即 GCNdrop^[16]、JKNet^[18] 和 GCNII^[20]) 进行了对比。

实验参数设置如下: 本文在实验中分别将卷积层设置为 4/16/32/64 层, 分别进行 10 轮训练, 每次训练 1 000 次, 将结果取平均值。模型使用 Adam 优化器进行实验, 训练迭代 1 000 次, 学习率设置为 0.05, 权重损失设置为 5×10^{-4} 。对于卷积层, 其超参数 α_l 设置为 0.1。在实验中, $\lambda \leftarrow \frac{2}{1 + e^{-10p}} - 1$ 用于在训练的初始阶段抑制噪声标签, 其中, p 为迭代次数, $\lambda \in (0, 1)$ 随着迭代次数逐渐增加。其余基线模型按照论文的参数设置。在实验中, 评价指标采用聚类精度 (cluster accuracy, AC) 来评估机器学习中各种算法的性能。给定真实标签 t_i 和预测标签 p_i , 聚类精度可以定义为

$$A_C = \frac{\sum_{i=1}^n \delta(t_i, \text{map}(p_i))}{N} \tag{14}$$

式中: n 为数据总的个数; δ 表示指示函数; t_i 表示样本 i 对应的真实标签; $\text{map}(\cdot)$ 表示最佳类标的重现分配, 以确保统计的正确。

实验环境如下: 操作系统为 Windows10 64 bit, CPU 为 Intel(R)Core i7-7700HQ, 频率为 3.4 GHz, GPU 为 NVIDIA GeForce 1060, 存储器为 DDR4 16 GB, 编程语言及环境为 Python3.6+Pytorch1.7.0。

3.1 少量已知标签实验

为验证本文模型 SDGCN 在少量标签情况下在群体发现任务中的性能, 基于 3 个基准数据集, 在分别提供少量已知标签情况下, 将 SDGCN 与其他基线模型进行对比, 实验结果如表 2 所示。

表 2 在不同数量的已知标签条件下模型聚类精度比较

Table 2 Comparison of clustering accuracy of various models under different numbers of known labels

模型	每类 1 个标签			每类 2 个标签			每类 5 个标签		
	Cora	Citeseer	PubMed	Cora	Citeseer	PubMed	Cora	Citeseer	PubMed
MLP	42.5	27.9	49.5	48.9	33.6	55.9	59.9	43.2	65.1
GCN ^[12]	43.2	33.6	51.9	50.1	41.8	54.9	69.0	53.2	68.1
GAT ^[13]	44.6	33.9	52.1	59.6	44.1	58.6	70.6	54.3	68.8
DAGNN ^[39]	59.1	44.3	56.3	64.2	53.8	64.8	71.2	54.7	70.6
Self-SAGCN ^[25]	61.2	56.8	63.2	70.8	63.9	68.8	75.1	66.9	71.9
SDGCN	63.8	57.8	65.3	71.5	64.4	70.9	78.6	68.1	73.5

从表 2 中可以看出, 简单的神经网络 MLP 模型相比传统的 GCN 模型性能较差。而深度半监督

模型 DAGNN 的性能比浅层模型 GCN 和 GAT 性能表现更好, 验证了深度模型确实能够提升模型性

能。本文模型 SDGCN 和 DAGNN 相比,在每类仅提供 1 个已知标签情况下,在聚类精度上分别提升了 4.7%、13.5%、9.0%;在每类提供 2 个已知标签情况下,在聚类精度上分别提升了 7.3%、10.6%、6.1%。随着训练规模的增加,SDGCN 模型仍然优于 DAGNN 模型,证明了本文模型的有效性。其原因在于:本文模型引入了自监督学习模块,大大降低了群体发现中对先验标签的依赖。即使与自监督学习模型 Self-SAGCN 相比,SDGCN 模型在每类提供 1 个已知标签情况下,在聚类精度上仍有提升,

分别提升了 2.6%、1.0%、2.1%。这是由于本文模型使用了更深层次的模型架构,可有效获取高阶邻居信息来提升群体发现准确性。

图 3 为在不同数量标记节点条件下 SDGCN 模型和 Self-SAGCN 模型在 Cora 数据集上获得的节点特征分布 t-SNE 可视化结果。可以看出,在不同数量的已知标签下,SDGCN 模型相比 Self-SAGCN 模型获得了更清晰的聚类特征。随着先验标签数量的增加,其结果变得更具区分性,这也从聚类精度的提高上得到了证实。




图 3 不同已知标签数量条件下 2 种模型在 Cora 数据集上获得的节点特征 t-SNE 可视化

Fig. 3 t-SNE visualization of node features obtained by two model on Cora dataset under different numbers of known labels

3.2 深度模型实验

为进一步验证本文模型能够有效缓解深度架构所造成的过平滑影响,实验将对 SDGCN 模型与其他深度模型在不同层数深度条件下的性能表现。为保证所有基线模型有一致的实验条件,实验在给定每类 20 个已知标签情况下,调节不同的模型深度来验证包括 SDGCN 在内的深度模型在本地环境中的性能。实验结果如表 3 所示。从实验结果可以发现,SDGCN 模型能够有效缓解过度平滑的问题,在将自监督学习模块扩展到深度模型时,其聚类精度仍然优于其他模型,且 SDGCN 模型聚类精度随着层数的增加仍在不断上升。

与 GCNII 相比,SDGCN 模型在大型数据集上的深度架构表现更好。例如,在 Citeseer 数据集上,SDGCN 模型在聚类精度上分别提升了 3.2%、1.4%、1.9%、0.6%。对于大型网络,每个类别仅提供 20 个已知标签时,半监督模型仍不足以将标签信息传遍到全局网络。SDGCN 模型引入自监督学习模块来学习已知节点的语义信息,并进一步使用

伪标签来不断扩展已知节点,因此,可以进一步提高性能。此外,与自监督学习模型 Self-SAGCN 相比,SDGCN 模型通过堆叠更多的卷积层(自监督学习模块),可更好地利用伪标签信息。同时,从表 3 中可以观察到,Self-SAGCN 模型在 16 层后性能急剧下降,而 SDGCN 模型性能依然能够保持稳定且有上升趋势。其主要原因是:在深度架构中引入了初始残差和恒等映射,大大降低了过度平滑的影响,同时也提高了模型性能。由于 Citeseer 数据集的边集数量较少,在所有模型上的精度都低于其他数据集。

同时,从图 4 中对 Cora 数据集上的 t-SNE 可视化结果可以观察到,随着层数的叠加,不同类别节点的特征区分性愈加明显。对比 GCNII 在 64 层的 t-SNE 可视化图可以发现,SDGCN 模型获得的节点特征更具有判别性。这是因为:模型中的自监督学习模块为节点特征提供了判别语义信息,且在初始残差和恒等映射的辅助下,更有效缓解了过度平滑问题。

3.3 超参数分析

进一步研究了 SDGCN 模型的超参数敏感性。实验在 Cora 上测试不同损失权重下准确率的变化, 如图 5 (a) 所示。其表明 SDGCN 模型对参数 λ 在 $[0.1,0.5]$ 范围内不敏感。在极少量已知标签情况

下, 当 $\lambda = 0.3$ 时, 提供了自监督损失和图卷积损失之间的最佳权衡, 取得最优结果。在每类提供 5 个或 20 个已知标签情况下, $\lambda = 0.5$ 决定了自监督损失和图卷积损失之间达到最佳权衡。此外, 随着标记节点数量的增加, SDGCN 模型可以保持稳定的性

表 3 在不同模型深度条件下模型聚类精度对比
Table 3 Comparison of clustering accuracy of various models under different model depth

模型	层数为4			层数为16			层数为32			层数为64		
	Cora	Citeseer	PubMed	Cora	Citeseer	PubMed	Cora	Citeseer	PubMed	Cora	Citeseer	PubMed
GCN ^[12]	67.8	15.6	17.2	16.4	50.6	18.9	14.9	17.6	71.6	40.2	36.6	39.9
GCN(drop)	80.6	75.7	62.5	49.5	68.6	57.3	41.1	33.2	78.3	77.6	76.2	61.1
JKNet ^[18]	78.9	79.3	80.6	70.9	67.9	68.2	69.2	63.1	78.1	72.1	73.6	73.1
GCNII ^[20]	79.2	83.1	83.9	84.1	67.0	70.2	70.8	71.6	79.1	77.6	79.6	79.9
Self-SAGCN ^[25]	75.1	34.6	31.6	30.8	62.5	48.9	26.2	18.1	75.3	50.8	43.7	40.1
SDGCN	81.2	82.6	84.1	85.2	70.2	71.6	72.7	72.2	78.6	79.2	80.1	80.6




图 4 不同模型深度下 2 种模型在 Cora 数据集上获得的节点特征 t-SNE 可视化

Fig. 4 t-SNE visualization of node features obtained by two models on Core dataset under different model depth




图 5 超参数对模型聚类准确率的影响

Fig. 5 The influence of hyper-parameters on model clustering accuracy

能。此外,图 5 (b) 表明,语义对齐中采用的中心相似度优化方法可以有效提高模型性能,主要是因为逐步更新机制抑制了伪标签的噪声信号。

4 结 论

为解决 GCN 过度依赖先验标签和深度模型所导致的过平滑问题,本文提出了一种基于深度 GCN 的自监督学习群体发现模型。

1) 本文模型通过引入自监督学习模块,利用少量先验节点标签信息,通过语义对齐机制来推断未知节点的标签,有效降低了 GCN 对大量先验标签的依赖。

2) 本文模型提出利用初始残差和恒等映射 2 种策略,有效缓解了深度 GCN 架构带来的过平滑问题,从而获得网络全局信息并提高模型性能。

3) 实验结果表明,即使在给定少量先验标签条件下,本文模型在深度达到 64 层构架时,仍然能够保持接近 80% 的识别准确率。相较于其他模型,该模型在群体识别精度上有显著的提升。

4) 为进一步提高模型的计算效率和性能,仍需要优化模型结构,如引入图注意力机制和多层次特征融合技术,以更精确地捕获全局信息。

参考文献 (References)

[1] BEDRU H D, YU S, XIAO X R, et al. Big networks: a survey[J]. *Computer Science Review*, 2020, 37: 100247.

[2] DA MATA A S. Complex networks: a mini-review[J]. *Brazilian Journal of Physics*, 2020, 50(5): 658-672.

[3] 潘理, 吴鹏, 黄丹华. 在线社交网络群体发现研究进展[J]. *电子与信息学报*, 2017, 39(9): 2097-2107.

PAN L, WU P, HUANG D H. Reviews on group detection in online social networks[J]. *Journal of Electronics & Information Technology*, 2017, 39(9): 2097-2107(in Chinese).

[4] CAI B, ZENG L N, WANG Y P, et al. Community detection method based on node density, degree centrality, and K-means clustering in complex network[J]. *Entropy*, 2019, 21(12): 1145.

[5] SU X, XUE S, LIU F Z, et al. A comprehensive survey on community detection with deep learning[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(4): 4682-4702.

[6] 齐金山, 梁循, 李志宇, 等. 大规模复杂信息网络表示学习: 概念、方法与挑战[J]. *计算机学报*, 2018, 41(10): 2394-2420.

QI J S, LIANG X, LI Z Y, et al. Representation learning of large-scale complex information network: concepts, methods and challenges[J]. *Chinese Journal of Computers*, 2018, 41(10): 2394-2420(in Chinese).

[7] ZHOU Z, AMINI A A. Analysis of spectral clustering algorithms for community detection: the general bipartite setting[J]. *The Journal of Machine Learning Research*, 2019, 20(1): 1774-1820.

[8] ZHANG Y, YEUNG D Y. Overlapping community detection via bounded nonnegative matrix tri-factorization[C]//Proceedings of the

18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2012: 606-614.

[9] YANG B, ZHAO X H, LIU X Y. Bayesian approach to modeling and detecting communities in signed network[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Austin: AAAI, 2015: 1952-1958.

[10] 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.

[11] 徐冰冰, 岑科廷, 黄俊杰, 等. 图卷积神经网络综述[J]. *计算机学报*, 2020, 43(5): 755-780.

XU B B, CEN K T, HUANG J J, et al. A survey on graph convolutional neural network[J]. *Chinese Journal of Computers*, 2020, 43(5): 755-780(in Chinese).

[12] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[EB/OL]. (2017-02-22)[2023-05-25]. <https://arxiv.org/abs/1609.02907>.

[13] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[EB/OL]. (2018-02-04)[2023-05-25]. <https://arxiv.org/abs/1710.10903>.

[14] WANG H W, WANG J, WANG J L, et al. GraphGAN: graph representation learning with generative adversarial nets[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New Orleans: AAAI, 2018: 2508-2515.

[15] JIN D, LIU Z Y, LI W H, et al. Graph convolutional networks meet Markov random fields: semi-supervised community detection in attribute networks[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Honolulu: AAAI, 2019: 152-159.

[16] HU R Q, PAN S R, LONG G D, et al. Going deep: graph convolutional ladder-shape networks[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: AAAI, 2020: 2838-2845.

[17] JIN D, LI B Y, JIAO P F, et al. Community detection via joint graph convolutional network embedding in attribute network [C]//Proceedings of International Conference on Artificial Neural Networks. Berlin: Springer, 2019: 594-606.

[18] XU K, LI C, TIAN Y, et al. Representation learning on graphs with jumping knowledge networks[C]//Proceedings of the International conference on machine learning. Stockholm: PMLR, 2018: 5453-5462.

[19] RONG Y, HUANG W B, XU T Y, et al. DropEdge: towards deep graph convolutional networks on node classification[EB/OL]. (2010-03-12)[2023-05-26]. <https://arxiv.org/abs/1907.10903>.

[20] CHEN M, WEI Z, HUANG Z, et al. Simple and deep graph convolutional networks[C]//Proceedings of the International Conference on Machine Learning. Vienna: PMLR, 2020: 1725-1735.

[21] LIU X, ZHANG F J, HOU Z Y, et al. Self-supervised learning: generative or contrastive[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(1): 857-876.

[22] YOU Y N, CHEN T L, WANG Z Y, et al. When does self-supervision help graph convolutional networks?[EB/OL]. (2020-06-18)[2023-05-26]. <https://arxiv.org/abs/2006.09136>.

[23] ZHU Y Q, XU Y C, YU F, et al. CAGNN: cluster-aware graph neural networks for unsupervised graph representation learning[EB/OL]. (2020-09-03)[2023-05-26]. <https://arxiv.org/abs/2009.01674>.

[24] SUN K, LIN Z C, ZHU Z X. Multi-stage self-supervised learning

- for graph convolutional networks on graphs with few labeled nodes [C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: AAAI, 2020: 5892-5899.
- [25] YANG X, DENG C, DANG Z Y, et al. Self-SAGCN: Self-supervised semantic alignment for graph convolution network[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2021: 16770-16779.
- [26] JIA S W, GAO L, GAO Y, et al. Defining and identifying cograph communities in complex networks[J]. *New Journal of Physics*, 2015, 17(1): 013044.
- [27] ZHANG P, MOORE C. Scalable detection of statistically significant communities and hierarchies, using message passing for modularity[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2014, 111(51): 18144-18149.
- [28] FANUEL M, ALAÍZ C M, SUYKENS J A K. Magnetic eigenmaps for community detection in directed networks[J]. *Physical Review E*, 2017, 95(2-1): 022302.
- [29] BLONDEL V D, GUILLAUME J L, LAMBIOTTE R, et al. Fast unfolding of communities in large networks[J]. *Journal of Statistical Mechanics: Theory and Experiment*, 2008, 2008: 10008.
- [30] HOLLAND P W, LASKEY K B, LEINHARDT S. Stochastic block models: first steps[J]. *Social Networks*, 1983, 5(2): 109-137.
- [31] LIU J H, MA G X, JIANG F, et al. Community-preserving graph convolutions for structural and functional joint embedding of brain networks[C]//Proceedings of the IEEE International Conference on Big Data. Piscataway: IEEE Press, 2019: 1163-1168.
- [32] ZHANG T Q, XIONG Y, ZHANG J W, et al. CommDGI: community detection oriented deep graph infomax[C]//Proceedings of the ACM International Conference on Information & Knowledge Management. New York: ACM, 2020: 1843-1852.
- [33] ZHAO H, YANG X, WANG Z, et al. Graph debiased contrastive learning with joint representation clustering[C]//Proceedings of the International Joint Conference on Artificial Intelligence. Montreal: IJCAI, 2021: 3434-3440.
- [34] WANG X F, LI J H, YANG L, et al. Unsupervised learning for community detection in attributed networks based on graph convolutional network[J]. *Neurocomputing*, 2021, 456: 147-155.
- [35] QIAO F, HUANG C X, XU S, et al. Community detection model based on graph representation and self-supervised learning[C]//Proceedings of the Artificial Intelligence and Security. Berlin: Springer, 2021: 27-40.
- [36] JIN W, DERR T, LIU H, et al. Self-supervised learning on graphs: deep insights and new direction[EB/OL]. (2020-06-17)[2023-05-20]. <https://doi.org/10.48550/arXiv.2006.10141>.
- [37] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 770-778.
- [38] KLICPERA J, BOJCHEVSKI A, GÜNNEMANN S. Predict then propagate: graph neural networks meet personalized PageRank[EB/OL]. (2022-04-05) [2023-05-28]. <https://arxiv.org/abs/1810.05997>.
- [39] LIU M, GAO H Y, JI S W. Towards deeper graph neural networks[C]//Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2020: 338-348.

Self-supervised learning for community detection based on deep graph convolutional networks

WANG Zaisheng, WANG Xiaofeng*, SHEN Guodong, ZHANG Zengjie, QUAN Daying

(College of Information Engineering, China Jiliang University, Hangzhou 310018, China)

Abstract: To alleviate the excessive dependence of graph neural networks on prior knowledge in community discovery and improve recognition accuracy, a novel self-supervised learning model for community detection based on a deep graph convolutional network (GCN) is proposed. The model makes full use of the semantic features of a small number of nodes and obtains pseudo-labels of unknown nodes through a semantic alignment mechanism, and thus introduces a self-supervised module to alleviate the dependence on a large number of prior labels during the training of GCN. Furthermore, by stacking self-supervised modules, a deep graph self-supervised learning model is built to increase the accuracy of community detection by obtaining the global information of networks. Two strategies, identity mapping and initial residual, are employed to address the over-smoothing issues that the deep model introduces. According to experiments conducted on publicly available datasets, the suggested approach outperforms current models in terms of community recognition accuracy when a limited number of prior labels are used and the model depth is increased.

Keywords: complex network; community detection; graph convolutional network; residual connection; self-supervised learning

Received: 2023-06-21; **Accepted:** 2023-11-21; **Published Online:** 2023-12-06 13:16
URL: link.cnki.net/urlid/11.2625.V.20231205.1639.003
Foundation items: Zhejiang Provincial Natural Science Foundation of China (LQ20F020021); National Key Research and Development Program of China (2019YFB1707104)
* **Corresponding author.** E-mail: xfwang@cjl.u.edu.cn