

控制与决策

Control and Decision

基于图注意力自编码器的自适应加权深度图聚类算法

徐森, 王作为, 郭乃瑄, 卞学胜, 徐秀芳, 花小朋, 周天

引用本文:

徐森, 王作为, 郭乃瑄, 等. 基于图注意力自编码器的自适应加权深度图聚类算法[J]. 控制与决策, 2026, 41(1): 213-220.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0477>

您可能感兴趣的其他文章

Articles you may be interested in

基于双分支特征融合的场景文本检测方法

A scene text detection based on dual-path feature fusion

控制与决策. 2021, 36(9): 2179-2186 <https://doi.org/10.13195/j.kzyjc.2020.0002>

基于图卷积网络的行为识别方法综述

A survey of action recognition methods based on graph convolutional network

控制与决策. 2021, 36(7): 1537-1546 <https://doi.org/10.13195/j.kzyjc.2020.0514>

融合稀疏编码与深度学习的草图特征表示

A feature representation of sketch based on fusion of sparse coding and deep learning

控制与决策. 2021, 36(3): 699-704 <https://doi.org/10.13195/j.kzyjc.2019.0941>

基于卷积神经网络的云雾遮挡舰船目标识别

Obscured ship target recognition based on convolutional neural network

控制与决策. 2021, 36(3): 661-668 <https://doi.org/10.13195/j.kzyjc.2019.0781>

基于协同聚类和权重注意力稀疏自编码网络的变化检测方法

Change detection approach based on cooperative clustering and weighted attention sparse autoencoder

控制与决策. 2021, 36(10): 2442-2450 <https://doi.org/10.13195/j.kzyjc.2019.1633>

基于图注意力自编码器的自适应加权深度图聚类算法

徐森^{1†}, 王作为¹, 郭乃瑄^{1,2}, 卞学胜¹, 徐秀芳¹, 花小鹏¹, 周天³

- 盐城工学院 信息工程学院, 江苏 盐城 224051;
- 东南大学 计算机网络和信息集成教育部重点实验室, 南京 210000;
- 哈尔滨工程大学 水声工程学院, 哈尔滨 150001)

摘要: 现有深度图聚类方法因依赖静态初始图结构而存在显著局限性, 此类结构通常不完整或存在偏差, 且难以动态捕捉节点相似性变化. 对此, 提出基于图注意力自编码器的自适应加权深度图聚类算法 (AWDGC). 首先, 通过可训练的广义马氏距离结合高斯核函数, 自适应分配边权重以构建加权邻接矩阵; 其次, 设计图注意力自编码器, 通过注意力机制融合多阶邻居信息以增强特征判别性; 然后, 提出基于节点相似性的动态结构优化策略, 周期性更新邻接矩阵以捕捉相似性动态变化; 最后, 引入自监督聚类模块, 通过 KL 散度优化聚类分布对齐, 提升特征表示与聚类任务的协同性. 在 ACM、DBLP、CITeseer、TEXAS 等 6 个公开数据集上的实验表明, AWDGC 在聚类指标上均显著优于 8 个代表性基线方法.

关键词: 深度图聚类; 自适应加权; 图注意力网络; 图自编码器; 动态结构优化; 自监督学习

中图分类号: TP181; TP301 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2025.0477

引用格式: 徐森, 王作为, 郭乃瑄, 等. 基于图注意力自编码器的自适应加权深度图聚类算法 [J]. 控制与决策, 2026, 41(1): 213-220.

Adaptive weighted deep graph clustering based on graph attention autoencoder

XU Sen^{1†}, WANG Zuo-wei¹, GUO Nai-xuan^{1,2}, BIAN Xue-sheng¹, XU Xiu-fang¹, HUA Xiao-peng¹, ZHOU Tian³

- School of Information Engineering, Yancheng Institute of Technology, Yancheng 224051, China;
- Key Laboratory of Computer Network and Information Integration, Southeast University, Nanjing 210000, China;
- School of Underwater Sound Engineering, Harbin Engineering University, Harbin 150001, China)

Abstract: Existing deep graph clustering methods are limited by their reliance on static initial graph structures, which are often incomplete or biased and fail to capture the dynamic changes in node similarities. To address these issues, an adaptive weighted deep graph clustering based on a graph attention autoencoder (AWDGC) is proposed. First, a trainable generalized Mahalanobis distance combined with a Gaussian kernel function is introduced to adaptively assign edge weights for constructing a weighted adjacency matrix. Second, a graph attention autoencoder is designed to enhance feature discriminability by leveraging an attention mechanism to fuse multi-hop neighborhood information. Furthermore, a dynamic structure optimization strategy based on node similarity is proposed to periodically update the adjacency matrix and capture the evolving similarities among nodes. Finally, a self-supervised clustering module is incorporated to improve the synergy between feature representation and clustering performance by optimizing cluster distribution alignment via KL divergence. Extensive experiments on six public datasets, including ACM, DBLP, CITESEER, and TEXAS, demonstrate that the proposed AWDGC significantly outperforms eight representative baseline methods across various clustering metrics.

收稿日期: 2025-05-08; **录用日期:** 2025-07-31.

基金项目: 国家自然科学基金项目 (62076215, 62301473); 中央高校基本科研业务费专项资金项目 (K93-9-2022-03); 江苏省教育厅面上项目 (23KJB520039); 江苏省网络与信息安全重点实验室项目 (BM2003201); 江苏高校“青蓝工程”项目; 盐城市基础研究计划项目 (YCBK2023008); 盐城市产业创新科技支撑 (工业) 专项资金项目 (YCBG2025201).

责任编辑: 何勇.

†通信作者. E-mail: xusen@ycit.cn.

本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

Keywords: deep graph clustering; adaptive weighting; graph attention network; graph autoencoder; dynamic structure optimization; self-supervised learning

0 引言

随着图数据在社交网络分析^[1]、生物信息学^[2]及推荐系统^[3]等领域的广泛应用,图聚类已成为近年来机器学习领域的前沿课题^[4].深度图聚类(DGC)^[5]方法通过结合节点特征和图结构信息,能够有效挖掘数据中的潜在聚类结构,已成为当前的研究热点.

图卷积网络(GCN)作为DGC的核心技术,通过将卷积神经网络的局部感知机制扩展至非欧式图域,实现了节点特征与拓扑结构的联合表征学习.基于GCN的理论框架,研究者提出了一系列改进方法:DAEGC^[6]引入注意力机制,在特征传播过程中动态分配节点与边的重要性权重,增强了对关键拓扑关系的建模能力;SDCN^[7]融合自编码器与GCN,构建属性-结构协同优化框架,显著提升了特征判别性;EFR-DGC^[8]提出动态边特征重构策略,有效捕捉节点间高阶非线性关联.然而,现有方法仍面临两大核心挑战:

1) 静态图结构依赖性,多数方法依赖预定义的邻接矩阵(如基于 K 近邻或领域知识构建),此类结构易受噪声干扰且仅能表达二值化连接关系(0或1);

2) 动态相似性建模缺失,尽管消息传递机制通过迭代聚合邻居信息更新节点表示,但节点间相似性随特征演化动态变化的特性未被充分考虑,传统固定图结构难以适配表示空间的动态分布.

针对上述挑战,本文提出一种基于图注意力自编码器的自适应加权深度图聚类算法(AWDGC),利用可训练的广义马氏距离结合高斯核函数实现边权重的自适应分配,通过图注意力自编码器与自监督聚类模块联合学习判别性节点表示,并引入动态结构优化策略持续调整图结构.

1 相关工作

图神经网络(GNN)作为一种新兴范式,通过深度融合图结构与节点属性信息,显著提升了图数据表征学习能力.其中,GCN与图注意力网络(GAT),作为GNN的典型代表,已在节点分类、链接预测等任务中展现出卓越性能.基于GNN的深度图聚类方法进一步拓展了这一框架:MBN^[9]设计混合双分支架构,分别通过图自编码器(GAE)和传统自编码器捕获拓扑与属性特征,并引入互增强策略迭代优化两类表征的互补性;AGCN^[10]创新性地引入动态注意力机制引入边权重分配,通过可学习的相似性度量

函数自适应调整节点间关联强度.

尽管上述方法在属性-结构融合方面取得了显著进展,但其性能仍受限于静态图依赖性问题,即邻接矩阵通常在预处理阶段固定,导致模型难以适配节点相似性的时变特性.近年来,深度聚类通过端到端联合优化特征表示与聚类目标,为图数据分析提供了新思路.代表性工作如SADC^[11]通过图卷积操作融合节点属性与拓扑信息,生成判别性嵌入以提升聚类精度.HGCPD^[12]结合GCN和节点对采样概率优化节点嵌入特征和社区结构.然而,现有方法在以下两方面仍存在局限性:1) 结构完整性-模式复杂性权衡,基于自编码器的方法虽能保持图结构完整性,但对深层非线性模式的挖掘能力不足;2) 动态图结构建模缺失,尽管DAGC^[13]通过注意力机制动态分配节点与边权重,但其图结构更新仍依赖静态相似性度量,无法捕捉特征传播过程中的动态关联演化.针对多视图图数据,MSAGC^[14]通过分阶段学习各视图的共享-特定表示并融合,显著提升了多视图图聚类性能.综上,现有方法尚未有效解决动态图结构适配与表示-任务协同优化两大核心挑战,而这正是本文研究的重点突破方向.

2 本文方法

定义1 对于给定的无向属性图,记为 $G = (\mathcal{V}, E, X)$, \mathcal{V} 为节点集, E 为边集, X 为属性特征矩阵.特征矩阵 $X \in \mathbb{R}^{N \times d}$ 存储节点属性信息, N 为节点总数, d 表示特征维度.令 A 表示图 G 的邻接矩阵,当节点 v_i 与 v_j 之间存在边时, $A_{ij} = 1$, 否则 $A_{ij} = 0$.图聚类的目标是将 \mathcal{V} 划分为 k 个互不重叠的子集/簇,记为 $C = \{C_1, C_2, \dots, C_k\}$.

本文设计的AWDGC方法包括自适应加权机制,图注意力自编码器,动态结构优化策略和自监督聚类,其框图如图1所示.

2.1 自适应加权机制

GNN本质上基于消息传递范式,其中信息通过图的边进行传播,使节点能够聚合邻居特征并更新自身表示.在此基础上,静态预定义的图结构对GNN适应性与表达能力的制约已成为限制模型性能的重要因素.为此,本文提出一种自适应加权机制.

本文的核心是引入可训练的广义马氏距离.与传统欧氏距离相比,其不再默认各特征维度等权或彼此独立,而是通过马氏范数自动建模维度之间的协同关系,从而更有效地表达节点间的真实语义关

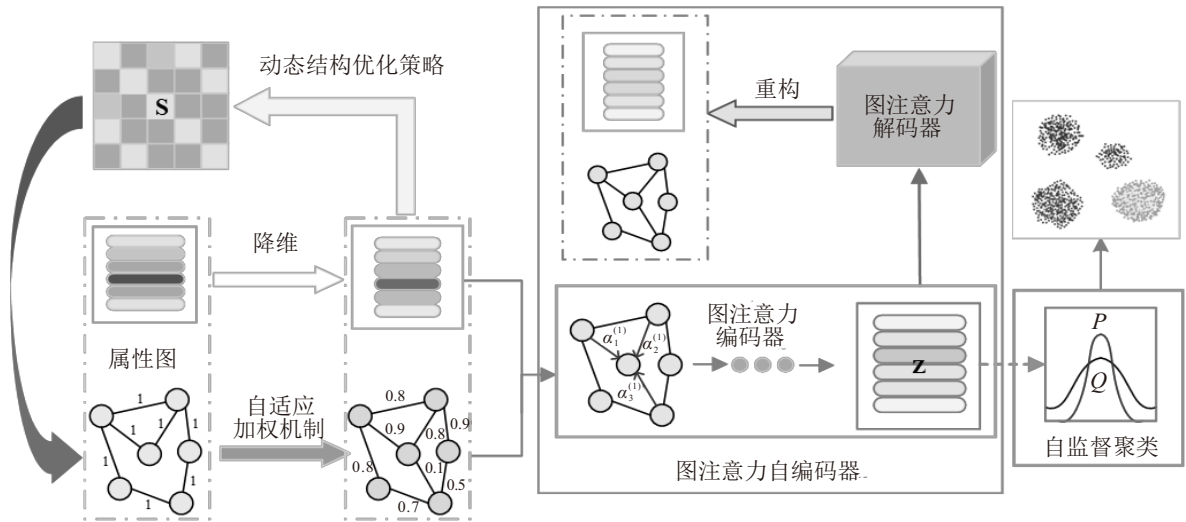


图1 AWDGC 模型框架

联. 在本文中, 节点间的广义马氏距离定义如下:

$$D(x_i, x_j) = \sqrt{(x_i - x_j)^T M (x_i - x_j)}, \quad (1)$$

其中 $M = W_d W_d^T$ 为由可训练参数矩阵 $W_d \in \mathbb{R}^{d \times d}$ 生成的正定矩阵. 相较于欧氏距离 $D_E^2(x_i, x_j) = \sum_{k=1}^d (x_{i,k} - x_{j,k})^2$, 广义马氏距离的优势在于其引入了可训练的协方差矩阵 M , 该机制有效缓解了欧氏距离在高维特征空间下的尺度失衡问题, 提升了相似性度量的判别性与泛化能力.

基于广义马氏距离, 为进一步增强相似性建模的非线性能力, 本文引入高斯核函数将节点对之间的距离转化为连续型相似性权重节点, 节点 v_i 与 v_j 的相似性可通过高斯核函数表示为

$$G_{x_i, x_j} = \exp\left(-\frac{D(x_i, x_j)^2}{2\zeta^2}\right). \quad (2)$$

其中: ζ 为高斯核的标准差参数, 用于调控距离与相似性之间的关联强度; $G_{x_i, x_j} \in (0, 1)$ 通过指数衰减特性, 有效平滑了节点距离与相似性间的非线性关系.

通过高斯核生成的相似性矩阵需进一步归一化处理, 将每行元素转换为表征节点间连接强度的概率分布. 由此得到的变换邻接矩阵为

$$\bar{A}_{ij} = \frac{G_{x_i, x_j}}{\sum_k G_{x_i, x_k}}. \quad (3)$$

随后, 基于归一化邻接矩阵 \bar{A} 构建图拉普拉斯矩阵 L , 其定义如下:

$$L = I - D^{-\frac{1}{2}} \bar{A} D^{-\frac{1}{2}}. \quad (4)$$

其中: D 为归一化邻接矩阵 \bar{A} 的度矩阵, 其对角元素定义为 $D_{ii} = \sum_j \bar{A}_{ij}$, I 为单位矩阵. 最终将 L 作为

图注意力自编码器的输入 A .

2.2 图注意力自编码器

图注意力自编码器 (GATE) 是一种融合图卷积运算与注意力机制的深度图表示学习框架. 其核心思想在于通过分层注意力机制动态建模节点间的局部拓扑关联与全局语义依赖, 从而生成高质量的节点嵌入表示. 然而, 原始高维特征通常包含大量噪声成分与冗余信息, 直接用于构建图结构易导致邻接关系失真. 此外, 尽管现有方法多通过引入复杂模块增强特征表示, 但此类改进常导致计算复杂度增加及过拟合风险上升. 为此, 本文将降维后的特征和新构建的邻接矩阵输入到图注意力自编码器中进行训练.

降维过程定义如下:

$$X' = W_e X + b_e. \quad (5)$$

其中: W_e 为编码器权重矩阵, b_e 为偏置向量. 重构特征矩阵记为 \hat{X} , 其计算式为

$$\hat{X} = W_d X' + b_d. \quad (6)$$

为确保降维特征保留关键信息并过滤噪声, 采用均方误差作为优化目标函数, 有

$$L_{\text{res}} = \frac{1}{2N} \|X - \hat{X}\|_F^2 = \frac{1}{2N} \sum_{i=1}^N \|x_i - \hat{x}_i\|_2^2. \quad (7)$$

其中: N 为节点总数, $x_i \in X$ 与 $\hat{x}_i \in \hat{X}$ 分别表示同一节点的原始特征与重构特征.

本文采用基于 GAT 的编码器架构, 借助自注意力机制来动态地为邻居节点分配不同的权重, 从而生成更加细粒度的节点表示. 图注意力机制的核心思想是通过节点间的相对重要性计算权重, 这些权重会根据邻居节点的特征动态调整. 具体而言, 节点 v_i 和其邻居节点 v_j 的更新表示依赖于其与邻居节点

的关系,这一关系通过注意力系数来量化.为了计算关注系数,有必要确定目标节点*i*与其邻居*j*之间的相关性,即

$$r_{ij} = a^T [Wh_i || Wh_j], \quad (8)$$

其中: $h_i \in \mathbb{R}^d$ 和 $h_j \in \mathbb{R}^d$ 分别表示节点 v_i 和 v_j 的特征向量, $a \in \mathbb{R}^{2a}$ 是可训练的注意力向量, $W \in \mathbb{R}^{d \times d}$ 是可学习的权重矩阵, $||$ 表示拼接操作.

应用带有激活函数 LeakyReLU 的 softmax 函数对其进行归一化,获得注意力系数

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(r_{ij}))}{\sum_{k \in N(v_i)} \exp(\text{LeakyReLU}(r_{ik}))}, \quad (9)$$

其中 $N(v_i)$ 表示节点 v_i 的邻居集.

基于节点间的注意力系数,可以使用加权邻居节点的特征来更新节点的嵌入表示.具体而言,节点 v_i 的新的嵌入表示为

$$h_i^{\text{new}} = \sigma \left(\sum_{j \in N(v_i)} \alpha_{ij} Wh_j \right), \quad (10)$$

其中 σ 是激活函数.

由于提取的潜在嵌入已经包含了属性和结构信息,解码器采用一个简单的内积解码器来预测节点之间的链接,即

$$\hat{A}_{ij} = \sigma(h_i^T h_j), \quad (11)$$

其中 σ 是 sigmoid 激活函数.通过内积操作,可以计算节点对之间的相似度,并根据此相似度推测是否存在边,从而获得图的邻接矩阵的重建值.

GATE 的损失函数采用二元交叉熵损失,其定义如下:

$$L_g = - \sum_{i,j} (A_{ij} \lg \hat{A}_{ij} + (1 - A_{ij}) \lg(1 - \hat{A}_{ij})) + \lambda \frac{1}{N} \sum_{i=1}^N \|\mathbf{x}_i - \hat{\mathbf{x}}_i\|_2^2. \quad (12)$$

其中: A_{ij} 表示图中实际的邻接矩阵元素, \hat{A}_{ij} 是通过解码器预测的邻接矩阵元素, $\hat{X} = ZW_r$ 为重构的节点属性矩阵, λ 为平衡系数.

2.3 动态结构优化策略

在图聚类领域,缺乏明确的性能指标来指导图权重优化.特征相似性作为空间中节点几何距离的表征,为这一任务提供了有效的启发式依据.然而,在分子图、社交网络等非欧几里德空间中,传统欧氏距离可能无法准确捕捉节点间的真实相似性.为应对上述挑战,本文提出一种动态结构优化策略,通过节点特征相似性动态更新邻接矩阵.本文基于降维

后的特征矩阵计算余弦相似性

$$S = \frac{X'}{\|X'\|_2} \times \frac{(X')^T}{\|(X')^T\|_2}. \quad (13)$$

考虑到相似性得分较低的节点更可能属于不同类别,而相似性得分较高的节点通常归于同一类别,本文引入超参数 ρ 作为阈值以指导优化过程.优化后的相似性矩阵 S_{ij} 计算如下:

$$S'_{ij} = \begin{cases} 0, & S_{ij} \leq \rho; \\ 1, & S_{ij} \geq (1 - \rho); \\ S_{ij}, & \text{otherwise.} \end{cases} \quad (14)$$

该方法对相似性矩阵进行逐元素阈值化处理:将低于阈值的弱相似性值置零,高于阈值的强相似性值置 1.最后,采用哈达玛积^[15]进行集成,即

$$\tilde{A}' = \tilde{A} \otimes S'_{ij}. \quad (15)$$

2.4 自监督聚类

由于特征表示模型与聚类任务均为无监督学习,其优化过程本质缺乏强监督信号.为此,本文借鉴自监督聚类方法^[9],通过计算软聚类分布 Q 与辅助聚类分布 P ,并优化聚类损失使 Q 尽可能与 P 对齐.

为优化聚类结果,本文采用学生 t 分布^[16] 计算特征矩阵 Z 中样本 z_i 与聚类中心 c_j 的相似性,并将其转换为概率分布.对于特征矩阵 Z 中的每个样本 z_i ,其对第 j 个聚类中心的隶属度 q_{ij} 计算如下,构成软聚类分布 $Q = [q_{ij}] \in \mathbb{R}^{N \times k}$:

$$q_{ij} = \frac{\exp\left(-\frac{\|z_i - c_j\|^2}{2\tau^2}\right)^{-\frac{\tau+1}{2}}}{\sum_{j=1}^N \exp\left(-\frac{\|z_i - c_j\|^2}{2\tau^2}\right)^{-\frac{\tau+1}{2}}}. \quad (16)$$

其中: τ 为自由度参数,用于控制隶属度的平滑性,在所有实验中固定为 1.为优化聚类结果,定义辅助分布 P 以强化高置信度分配并抑制模糊分配的影响,其元素 p_{ij} 定义为

$$p_{ij} = \frac{q_{ij}^2 / \sum_i q_{ij}}{\sum_k q_{ik}^2 / \sum_i q_{ik}}. \quad (17)$$

模型优化目标为最小化辅助分布 P 与软聚类分布 Q 之间的 Kullback-Leibler(KL) 散度,即

$$L_{\text{KL}} = D(P||Q) = \sum_i \sum_j p_{ij} \lg \frac{p_{ij}}{q_{ij}}. \quad (18)$$

2.5 损失函数

总损失函数由两部分构成: GATE 的重构损失与自监督模块的聚类损失,其数学表达式为

$$L_{\text{total}} = L_g + \delta L_{\text{KL}}, \quad (19)$$

其中超参数 δ 用于平衡两项损失的权重. 本文的核心目标是通过最小化总损失函数 L 优化节点表示.

3 实验分析

实验选取 6 个真实公开数据集: ACM(<http://dl.acm.org/>)、DBLP(<https://dblp.uni-trier.de/>)、CITeseer(<https://citeseer.ist.psu.edu/>)、TEXAS^[5]、AMAP^[5]和 CORA^[7]. 为全面评估方法的聚类性能, 选取 8 种代表性基线方法进行对比: SDCN、DFCN^[17]、GC-SEE^[18]、DCRN^[19]、CCGC^[20]、R2FGC^[21]、DDGAE^[22]和

ARLN^[23]. 为保证实验可重复性, 所有实验均使用固定随机种子 325. 每个数据集统一进行 50 次迭代训练, 以降低随机性偏差并抑制离群值影响, 最终结果取平均值.

实验采用 4 项标准指标评估聚类性能: 准确率 (ACC)、归一化互信息 (NMI)、调整兰德指数 (ARI) 及 F1 分数 (F1). 指标值越高, 表明聚类效果越优.

3.1 实验结果

本文在 6 个公开数据集上开展实验. 表 1 为各数据集的评估指标结果, 超参数设置如表 2 所示.

表1 8种基准算法和AWDGC在6个数据集上具有均值±标准差的聚类性能

数据集	指标	SDCN(2020)	DFCN(2021)	GC-SEE(2023)	DCRN(2023)	CCGC(2023)	R2FGC(2024)	DDGAE(2024)	ARLN(2025)	AWDGC
ACM	ACC	90.45 ± 0.18	90.90 ± 0.20	91.67 ± 0.10	92.46 ± 0.10	88.76 ± 0.91	92.43 ± 0.18	92.03 ± 0.18	92.93 ± 0.30	93.24 ± 0.05
	NMI	68.31 ± 0.25	69.40 ± 0.40	70.83 ± 0.25	72.58 ± 0.15	64.28 ± 1.88	72.42 ± 0.53	72.21 ± 0.12	74.87 ± 0.10	75.59 ± 0.02
	ARI	73.91 ± 0.40	74.90 ± 0.40	76.89 ± 0.24	78.89 ± 0.27	69.86 ± 2.09	78.72 ± 0.47	77.87 ± 0.15	80.15 ± 0.20	82.01 ± 0.08
	F1	90.42 ± 0.19	90.80 ± 0.20	91.66 ± 0.09	91.53 ± 0.36	88.71 ± 0.91	92.45 ± 0.18	92.06 ± 0.13	92.92 ± 0.15	93.02 ± 0.05
DBLP	ACC	68.05 ± 1.81	76.00 ± 0.80	79.23 ± 0.96	78.45 ± 0.13	65.19 ± 4.20	80.95 ± 0.20	80.51 ± 0.21	81.05 ± 0.20	82.56 ± 0.10
	NMI	39.50 ± 1.34	43.70 ± 1.00	48.04 ± 1.46	46.89 ± 0.21	33.48 ± 3.94	50.82 ± 0.32	49.83 ± 0.39	51.74 ± 0.10	54.85 ± 0.08
	ARI	39.15 ± 2.01	47.00 ± 1.50	53.51 ± 1.82	51.22 ± 0.19	34.21 ± 5.43	56.34 ± 0.42	55.66 ± 0.42	56.25 ± 0.25	59.87 ± 0.17
	F1	67.71 ± 1.51	75.70 ± 0.80	78.55 ± 0.99	77.95 ± 0.84	64.00 ± 4.29	80.54 ± 0.19	79.98 ± 0.24	80.75 ± 0.20	82.33 ± 0.11
CITeseer	ACC	65.96 ± 0.31	69.50 ± 0.20	70.90 ± 0.56	71.02 ± 0.77	69.84 ± 0.94	70.60 ± 0.45	71.01 ± 0.24	70.96 ± 0.30	71.59 ± 0.10
	NMI	38.71 ± 0.32	43.90 ± 0.20	44.00 ± 0.64	45.25 ± 0.45	44.33 ± 0.79	45.39 ± 0.37	46.13 ± 0.16	45.90 ± 0.20	46.51 ± 0.07
	ARI	40.17 ± 0.43	45.50 ± 0.30	46.47 ± 0.76	46.29 ± 1.13	45.68 ± 1.80	47.07 ± 0.30	47.87 ± 0.55	47.68 ± 0.25	48.69 ± 0.05
	F1	63.62 ± 0.24	64.30 ± 0.20	63.12 ± 0.66	64.80 ± 1.01	62.71 ± 2.06	65.28 ± 0.12	65.91 ± 0.23	65.85 ± 0.10	66.78 ± 0.12
TEXAS	ACC	55.41 ± 0.44	60.60 ± 0.79	56.78 ± 1.11	58.65 ± 1.35	48.42 ± 2.43	59.56 ± 0.24	61.52 ± 0.28	60.12 ± 1.15	64.12 ± 1.15
	NMI	4.54 ± 0.44	14.57 ± 0.62	8.41 ± 2.76	15.52 ± 1.58	12.59 ± 2.83	13.4 ± 2.34	17.32 ± 0.47	15.67 ± 2.04	26.31 ± 2.90
	ARI	0.72 ± 0.70	26.71 ± 1.47	7.33 ± 5.56	14.31 ± 2.54	10.37 ± 3.56	21.29 ± 2.67	23.84 ± 1.56	22.87 ± 1.87	24.80 ± 1.97
	F1	17.71 ± 0.58	30.71 ± 1.03	22.10 ± 3.41	25.41 ± 1.28	28.85 ± 4.78	24.2 ± 3.75	28.17 ± 1.01	26.7 ± 2.84	31.74 ± 1.05
AMAP	ACC	53.44 ± 0.81	76.88 ± 0.80	77.34 ± 0.80	77.48 ± 0.37	77.25 ± 0.41	81.28 ± 0.05	81.97 ± 0.15	82.51 ± 0.08	83.59 ± 0.03
	NMI	44.85 ± 0.83	69.21 ± 1.00	64.15 ± 0.68	67.67 ± 0.88	67.44 ± 0.48	73.88 ± 0.17	71.54 ± 0.12	72.16 ± 0.23	70.12 ± 0.01
	ARI	31.21 ± 1.23	58.98 ± 0.84	56.76 ± 1.24	58.48 ± 0.72	57.99 ± 0.66	66.25 ± 0.36	65.35 ± 0.64	65.18 ± 0.09	67.08 ± 0.06
	F1	50.66 ± 1.49	71.58 ± 0.31	74.58 ± 0.77	72.22 ± 0.97	72.18 ± 0.57	75.29 ± 0.32	74.15 ± 0.58	76.85 ± 0.18	81.07 ± 0.02
CORA	ACC	50.70 ± 0.09	65.5 ± 0.58	73.58 ± 0.74	73.88 ± 0.88	73.88 ± 1.20	74.56 ± 0.96	73.76 ± 0.28	73.17 ± 0.35	75.81 ± 0.21
	NMI	33.78 ± 0.07	48.41 ± 0.45	53.02 ± 0.41	56.10 ± 0.72	56.45 ± 1.04	56.85 ± 1.20	55.49 ± 0.15	54.34 ± 0.41	55.53 ± 0.15
	ARI	25.76 ± 0.07	44.73 ± 0.35	51.22 ± 0.88	51.79 ± 1.59	52.51 ± 1.89	54.64 ± 0.31	52.54 ± 0.19	53.74 ± 0.36	56.60 ± 0.20
	F1	44.13 ± 0.07	62.25 ± 0.35	71.48 ± 0.79	70.81 ± 1.96	70.98 ± 2.79	72.49 ± 0.20	71.39 ± 0.46	72.17 ± 0.23	73.21 ± 0.13

表2 参数设置

数据集	ζ	λ	ρ	δ	Lr
ACM	0.5	3	0.5	7	1.9e-03
DBLP	0.5	4	0.1	0.06	2e-03
CITeseer	0.5	1	0.2	0.03	2e-03
TEXAS	0.5	5	0.6	9	1.5e-02
AMAP	0.5	4	0.1	0.08	1.5e-03
CORA	0.5	3	0.1	10	1e-03

根据实验结果, AWDGC 在全部 6 个数据集的 4 个聚类指标上均取得了最优或接近最优结果, 尤其在大型结构复杂图 (如 ACM、DBLP) 上优势明显.

以 ACM 数据集举例, AWDGC 的准确率 (ACC) 达到了 93.24%, 较次优方法 ARLN 提升约 0.31%, 这表明 AWDGC 在捕捉数据中隐藏的结构特征和节点间相似性方面具有更强的能力. 在 DBLP 数据集, AWDGC 的 ACC 为 82.56%, 比 DDGAE 提升 2.05%, 显示出其在保持聚类一致性和优化聚类精度方面的优势. 在 Texas 等小规模噪声数据上, AWDGC 的表现也最为稳健, ACC 达到 64.12%, 大幅优于其他方法. 此外, 部分方法 (如 R2FGC) 在某一两个指标上表现较好但不稳定, 而 AWDGC 在 4 项指标上波动

极小,说明其在类内聚合与类间分离两方面兼顾,结构判别性与特征表达能力高度协调.

3.2 消融实验

本节通过消融实验评估自适应加权机制与动态结构优化策略在 AWDGC 中的贡献. 本文设计了

3 种 AWDGC 的变体进行对比: 1) AWDGC-o: 广义马氏距离替换为欧氏距离的变体; 2) AWDGC-e: 无自适应加权的变体; 3) AWDGC-a: 无动态结构优化的变体. 消融实验在 ACM、DBLP、CITSEER 和 TEXAS 四个数据集上进行, 实验结果如图 2 所示.

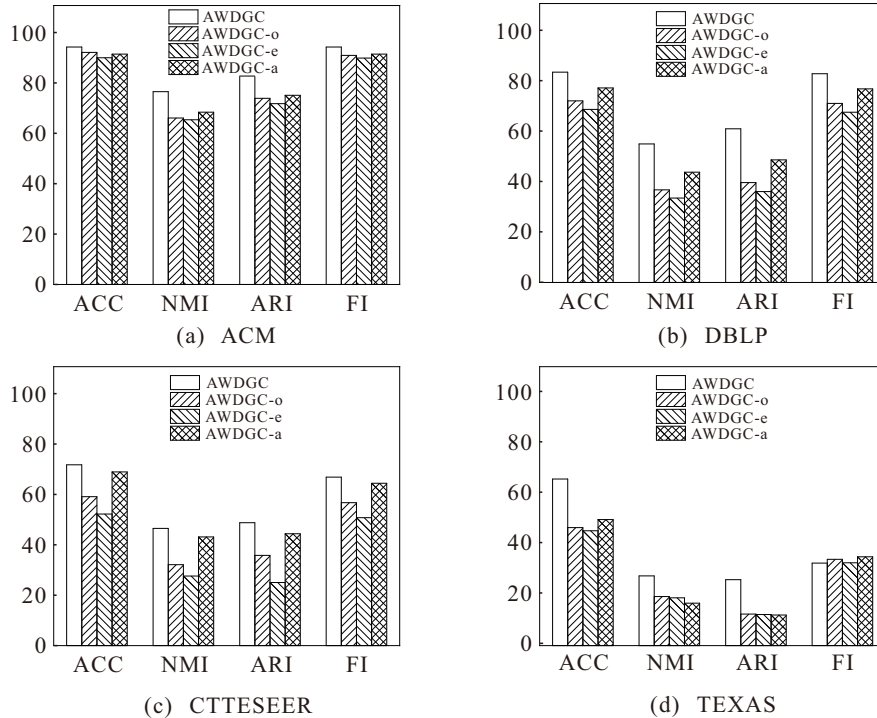


图2 AWDGC 及其 3 个变体 AWDGC-o、AWDGC-e 和 AWDGC-a 的聚类性能

显然, AWDGC 在所有数据集上均优于其 3 个变体, 这表明所提出的自适应加权与结构优化机制在图聚类任务中具有协同增益效应. 特别地, 当采用传统欧氏距离替代广义马氏距离进行图构建时, AWDGC-o 对比 AWDGC 在多个评估指标上均出现明显退化. 其根本原因在于, 欧氏距离认为各特征维度相互独立且尺度一致, 而广义马氏距离通过引入可学习的协方差结构, 能够动态调整特征空间的度量尺度, 更精准地捕捉节点间的真实相似性关系. 此外, 相较于 AWDGC-e, AWDGC 在 DBLP 数据集上, AWDGC 的 ACC 提升了 5.12%, NMI 提升了 8.45%, 表明自适应加权机制对于提取判别性表示至关重要. 另一方面, 与去除动态结构优化的 AWDGC-a 相比, AWDGC 在同一数据集上的 ACC 提升了 4.37%, NMI 提升了 6.92%, 该结果验证了动态结构优化策略在纠正初始邻接结构偏差、提升图结构表达质量方面的关键作用.

3.3 参数分析

本文进一步开展参数分析实验. 具体而言, 本文首先分析了动态结构优化模块中的一个关键超参数:

阈值 ρ . 该参数用于控制边权重调整的允许范围, 阈值从 0.1 ~ 0.9 中选取.

如图 3 所示, 更新阈值对模型性能具有显著影响. 随着阈值的增加, 各指标整体呈下降趋势, 尤其是 NMI 和 ARI 对较高阈值更为敏感. 在较低阈值范围 (0.2 ~ 0.5) 内, 各项指标表现最佳, 表明适当的阈值有助于在优化图结构与避免过度更新之间实现良好平衡. 过高的阈值会导致图结构调整过于激进, 可能破坏部分有用的弱连接. 值得注意的是, 不同数据集对 ρ 的敏感度也存在差异. 例如, Texas 数据集的性能曲线波动较大, 这是因为该数据集本身不稳定的原始图结构使其在动态优化时更容易受到不当调整的影响. 因此, 对于稀疏或噪声较多的数据集, 建议使用更小的 ρ 值 (如 0.2 ~ 0.3) 以保持结构稳定性; 而对于更稠密、结构更清晰的数据集, 则可以探索稍大的 ρ 值以获得更优的性能.

本文同样分析了高斯核标准差 ζ 对模型性能的影响, 结果如图 4 所示. 当 ζ 值过小 (如 0.1) 时, 模型性能不佳, 这是因为生成的图过于稀疏, 未能捕获足够的邻域信息. 随着 ζ 值增大, 模型性能显著提升, 并

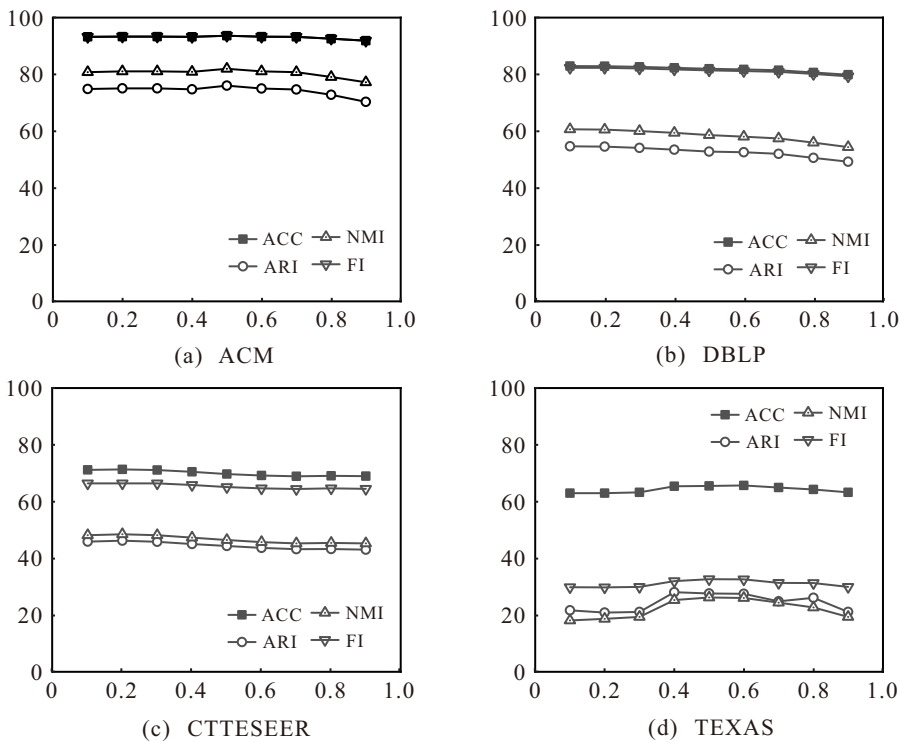


图3 参数 ρ 在4个数据集上的敏感性分析

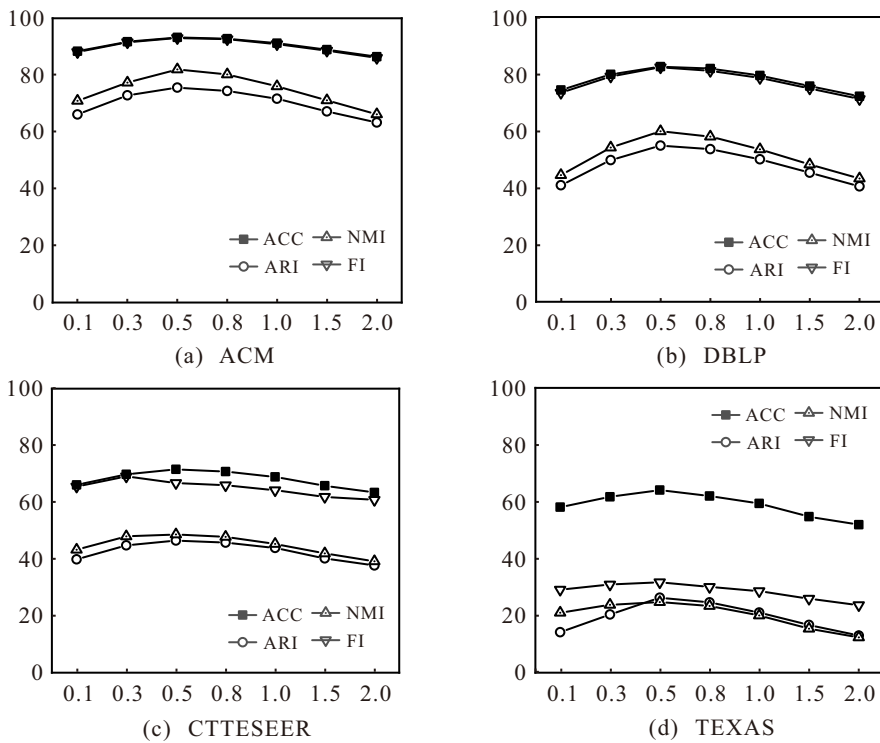


图4 参数 ζ 在4个数据集上的敏感性分析

在 $\zeta = 0.5$ 附近达到最优. 此后若继续增大 ζ 值, 性能则开始平稳下降, 表明过大的 ζ 会引入噪声边.

4 结论

本文聚焦于基于节点相似性的图结构优化问题, 提出基于图注意力自编码器的自适应加权深度图聚类算法. 该方法引入可训练的广义马氏距离, 并结合高斯核函数实现图边权重的自适应分配. 此外, 图注

意力自编码器与自监督聚类模块协同学习有意义的节点表示, 而动态结构优化策略则进一步对图结构进行动态调整. 大量实验验证了 AWDGC 相较于现有方法更具有优越性能.

参考文献 (References)

[1] 卜湛, 王煜尧, 马丽娜, 等. 基于动态类簇形成博弈的属性图聚类方法[J]. 计算机学报, 2021, 44(9): 1824-

1840.
(Bu Z, Wang Y Y, Ma L N, et al. Attributed graph clustering approach based on dynamic cluster formation game[J]. *Chinese Journal of Computers*, 2021, 44(9): 1824-1840.)
- [2] Karim M R, Beyan O, Zappa A, et al. Deep learning-based clustering approaches for bioinformatics[J]. *Briefings in Bioinformatics*, 2021, 22(1): 393-415.
- [3] Wang C, Pan S R, Yu C P, et al. Deep neighbor-aware embedding for node clustering in attributed graphs[J]. *Pattern Recognition*, 2022, 122: 108230.
- [4] Wang Y L, Zou J F, Wang K, et al. Semi-supervised deep embedded clustering with pairwise constraints and subset allocation[J]. *Neural Networks*, 2023, 164: 310-322.
- [5] Wang S P, Yang J B, Yao J, et al. An overview of advanced deep graph node clustering[J]. *IEEE Transactions on Computational Social Systems*, 2024, 11(1): 1302-1314.
- [6] Wang C, Pan S R, Hu R Q, et al. Attributed graph clustering: A deep attentional embedding approach[C]. Proceedings of the 28th International Joint Conference on Artificial Intelligence. Macao, 2019: 3670-3676.
- [7] Bo D Y, Wang X, Shi C, et al. Structural deep clustering network[C]. Proceedings of the Web Conference 2020. Taipei, 2020: 1400-1410.
- [8] Hao J, Zhu W. Deep graph clustering with enhanced feature representations for community detection[J]. *Applied Intelligence*, 2023, 53(2): 1336-1349.
- [9] Yan X Q, Yu X Y, Hu S Z, et al. Mutual boost network for attributed graph clustering[J]. *Expert Systems with Applications*, 2023, 229: 120479.
- [10] Peng Z H, Liu H, Jia Y H, et al. Attention-driven graph clustering network[C]. Proceedings of the 29th ACM International Conference on Multimedia. New York, 2021: 935-943.
- [11] Chen B W, Xu S, Xu H Y, et al. Structure-aware deep clustering network based on contrastive learning[J]. *Neural Networks*, 2023, 167: 118-128.
- [12] 徐森, 刘轩绮, 陈朝峰, 等. 一种基于概率分布分层图聚类网络的社区检测模型[J]. *控制与决策*, 2025, 40(6): 1969-1974.
(Xu S, Liu X Q, Chen C F, et al. A community detection model based on hierarchical graph clustering network with probability distribution[J]. *Control and Decision*, 2025, 40(6): 1969-1974.)
- [13] Peng Z H, Liu H, Jia Y H, et al. Deep attention-guided graph clustering with dual self-supervision[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2023, 33(7): 3296-3307.
- [14] 曹付元, 陈晓惠. 共享和特定表示的多视图属性图聚类[J]. *软件学报*, 2025, 36(3): 1254-1267.
(Cao F Y, Chen X H. Multi-view attributed graph clustering based on shared and specific representation[J]. *Journal of Software*, 2025, 36(3): 1254-1267.)
- [15] Shen X B, Shi L, Gong X W, et al. Unsupervised deep graph structure and embedding learning[C]. Proceedings of the 33rd International Joint Conference on Artificial Intelligence. Jeju, 2024: 2342-2350.
- [16] Flexa C, Gomes W, Moreira I, et al. Polygonal coordinate system: Visualizing high-dimensional data using geometric DR, and a deterministic version of *t*-SNE[J]. *Expert Systems with Applications*, 2021, 175: 114741.
- [17] Tu W X, Zhou S H, Liu X W, et al. Deep fusion clustering network[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(11): 9978-9987.
- [18] Ding S F, Wu B Y, Xu X, et al. Graph clustering network with structure embedding enhanced[J]. *Pattern Recognition*, 2023, 144: 109833.
- [19] Liu Y, Tu W X, Zhou S H, et al. Deep graph clustering via dual correlation reduction[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2022, 36(7): 7603-7611.
- [20] Yang X H, Liu Y, Zhou S H, et al. Cluster-guided contrastive graph clustering network[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2023, 37(9): 10834-10842.
- [21] Yi S Y, Ju W, Qin Y F, et al. Redundancy-free self-supervised relational learning for graph clustering[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 35(12): 18313-18327.
- [22] Wu X L, Lu W Y, Quan Y N, et al. Deep dual graph attention auto-encoder for community detection[J]. *Expert Systems with Applications*, 2024, 238: 122182.
- [23] Chen Z K, Li L F, Zhang X, et al. Deep graph clustering via aligning representation learning[J]. *Neural Networks*, 2025, 183: 106927.

作者简介

徐森 (1983-), 男, 教授, 博士, 主要研究方向为机器学习、数据挖掘、人工智能, E-mail: xusen@ycit.cn;

王作为 (2001-), 男, 硕士生, 主要研究方向为深度学习、图聚类, E-mail: wangzuoweiedu@outlook.com;

郭乃瑄 (1991-), 男, 讲师, 博士, 主要研究方向为网络安全、图像处理, E-mail: guonaixuan@ycit.edu.cn;

卞学胜 (1991-), 男, 讲师, 博士, 主要研究方向为深度学习、医学影像处理, E-mail: xsbian@ycit.edu.cn;

徐秀芳 (1973-), 女, 高级实验师, 硕士, 主要研究方向为机器学习、智能信息处理, E-mail: xxf@ycit.cn;

花小朋 (1975-), 男, 副教授, 博士, 主要研究方向为机器学习、数据挖掘, E-mail: 1462124471@qq.com;

周天 (1980-), 男, 教授, 博士, 主要研究方向为水声目标探测与定位, E-mail: zhoutian@hrbeu.edu.cn.