

基于相位保持的频域MinMax框架图增强方法

华彧, 周效成, 沈项军, 刘志锋, 周从华

引用本文

华彧, 周效成, 沈项军, 刘志锋, 周从华. 基于相位保持的频域MinMax框架图增强方法[J]. 计算机科学 2026, 53(4): 245-251.

HUA Yu, ZHOU Xiaocheng, SHEN Xiangjun, LIU Zhifeng, ZHOU Conghua. Phase-preserved MinMax Framework for Graph Augmentation in Frequency Domain [J]. Computer Science, 2026, 53(4): 245-251.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于主动学习的多模态谣言检测模型](#)

Active Learning-based Multi-modal Fusion Rumor Detection

计算机科学, 2025, 52(12): 391-399. <https://doi.org/10.11896/jsjx.241000161>

[平衡参数自适应下基于模体的混合阶网络多智能体一致性](#)

Motif Based Hybrid-order Network Consensus for Multi-agent Systems with Trade-off Parameter Adaptation

计算机科学, 2024, 51(12): 269-276. <https://doi.org/10.11896/jsjx.231100146>

[一种基于网络顶点割的拓扑优化算法](#)

New Network Topology Optimization Approach Based on Vertex Separator Set

计算机科学, 2010, 37(11): 47-49.

[车联网中可抵制合谋攻击的批量认证方案](#)

Batch Verification Scheme Defensing Collusive Attack in VANET

计算机科学, 2016, 43(6): 135-140. <https://doi.org/10.11896/j.issn.1002-137X.2016.06.028>

[一种基于RBAC的UCON管理模型](#)

Administrative Model for UCON Based on RBAC

计算机科学, 2016, 43(10): 150-153. <https://doi.org/10.11896/j.issn.1002-137X.2016.10.028>

基于相位保持的频域 MinMax 框架图增强方法

华 彧 周效成 沈项军 刘志锋 周从华

江苏大学计算机科学与通信工程学院 江苏 镇江 212013

(2212408023@stmail.ujs.cn)

摘要 图数据增强通过对图结构或节点特征进行局部或全局变换,可有效提高图网络的泛化能力和鲁棒性。现有研究表明,图增强技术能够有效利用低频信息以获取图的全局拓扑,但是对于获取图网络细节结构上的高频信息仍存在一定不足,导致模型在学习图网络的局部特征时可能出现信息丢失或特征偏差。针对这一问题,提出了一种基于相位保持的频域 MinMax 框架图增强方法。该方法首先将频域处理与现有的 MinMax 框架相结合,将图数据划分为高频和低频部分。低频代表图的全局拓扑结构信息,而高频则代表图的丰富的细节信息。通过引入频域上的 MinMax 框架,模型可以更好地保留图的全局拓扑信息并增强高频细节部分,从而更好地捕捉图的多尺度结构。同时,采用自适应增强策略,根据不同频率分量的特征动态调整增强幅度,以提高训练效率。此外,频域相位信息反映了图节点的特征结构,通过在图数据中保留关键的相位信息,进一步提升了图数据的表达能力,为图神经网络提供了更为丰富和精准的特征表示。因此,所提方法从频域分析的角度,不仅保持了图拓扑的关键结构信息,还针对图节点数据特征进行有效增强,提高了模型对图数据的理解和泛化能力。在多个数据集上进行的实验表明,与传统方法相比,所提方法在图节点分类任务中将准确率提升了 2 个百分点以上。实验结果证明,所提方法在提升图模型性能的同时,也提高了计算效率,其在大规模图数据应用中的有效性与优势得到验证。

关键词: 图增强;相位保持;频域 MinMax 框架;拓扑优化;幅度调整

中图分类号 TP181

Phase-preserved MinMax Framework for Graph Augmentation in Frequency Domain

HUA Yu, ZHOU Xiaocheng, SHEN Xiangjun, LIU Zhifeng and ZHOU Conghua

School of Computer Science and Communication Engineering, Jiangsu University, Zhenjiang, Jiangsu 212013, China

Abstract Graph data augmentation enhances the generalization and robustness of graph neural networks (GNNs) by performing local or global transformations on graph structures or node features. While existing studies have shown that graph augmentation techniques can effectively leverage low-frequency information to capture the global topology of graphs, they often fail to preserve high-frequency components that encode fine-grained structural details. This shortcoming may result in information loss or feature distortion when learning local representations. To address this challenge, this paper proposes a phase-preserving frequency-domain MinMax framework for graph augmentation. The proposed method integrates frequency-domain analysis with the MinMax optimization paradigm, decomposing graph signals into low and high-frequency components. The low-frequency part captures global topological patterns, whereas the high-frequency part represents rich local structural information. By applying the MinMax strategy in the frequency domain, the proposed framework simultaneously preserves global structure and enhances high-frequency details, leading to more expressive multi-scale graph representations. In addition, it adopts an adaptive augmentation strategy that dynamically adjusts the perturbation amplitude based on the characteristics of different frequency components, thereby improving training efficiency. The phase information, which encodes intrinsic structural relations between graph nodes, is explicitly preserved to further enrich the expressive capacity of node representations. Through this frequency-aware design, the proposed method maintains essential topological structures while effectively enhancing node-level features, improving the GNN's ability to capture both global and local semantics. Extensive experiments on multiple benchmark datasets demonstrate that the proposed method achieves over a 2 percentage points accuracy gain on node classification tasks compared to existing approaches. Moreover, it delivers superior computational efficiency, validating its effectiveness and scalability for large-scale graph learning scenarios.

Keywords Graph augmentation, Phase preservation, Frequency domain MinMax framework, Topological optimization, Amplitude adjustment

到稿日期:2025-07-14 返修日期:2025-09-05

基金项目:国家自然科学基金(62376108)

This work was supported by the National Natural Science Foundation of China(62376108).

通信作者:沈项军(xjshen@ujs.edu.cn)

1 引言

近年来,图神经网络(Graph Neural Networks, GNNs)在处理图结构数据方面取得了显著突破,被广泛应用于社交网络分析、推荐系统、生物信息学等领域^[1]。然而,随着图数据规模的不断扩大和复杂性的增加,如何有效提升图神经网络的性能和泛化能力成为了当前研究中的关键挑战之一。图增强技术^[2]作为一种有效的优化手段,通过对图数据的多维度操作,能够在不改变数据原始信息的基础上改善图模型的表现。这些增强方法通常包括节点特征变换、图结构调整、边的添加或删除等,旨在通过丰富数据的表达方式,使模型能够更好地捕捉到图数据中的潜在规律。

为了提升图神经网络的性能和泛化能力,Wei等^[3]指出图数据增强能够有效解决图神经网络中的过度平滑和过度拟合问题,并提升图神经网络的性能。图对比学习(Graph Contrastive Learning, GCL)是一种自监督学习方法,旨在从图结构数据中学习有用的表示。在图对比学习中,FeatAA方法通过识别并保留重要特征,避免了传统增广方法对关键信息的破坏,从而提升了图表示学习的准确性和鲁棒性^[4]。与此同时,文献^[5-6]提出了一种MinMax框架,其通过最大化增强视图与原图之间的互信息,并最小化不同视图之间的互信息,避免了无关信息的干扰,从而提高了图表示学习的效率。该方法不仅能够加强模型在不同视图之间的知识共享,还能提升其在实际任务中的表现,进一步推动了图对比学习的应用。此外,Liu等^[7]提出了面向频域的复数图神经网络,将节点嵌入扩展为复数向量,以探索频域信息在图表示学习中的潜力。该方法开创性地将频域分析引入图神经网络,解决了图池化和梯度反向传播等关键问题。同时,其他研究也开始关注图的频域特征,特别是高频和低频信息的不同作用。Sun等^[8]提出了两种新的图卷积层——NGAT和HLGAT,分别聚焦于图中高频和低频信息的聚合。实验表明,NGAT专门聚合邻居节点的高频信息,而HLGAT则同时聚合低频和高频信息,这种频域分析显著提升了异嗜图的性能,验证了高频信息在节点分类任务中的关键作用。如今,频域分析方法在图神经网络中的应用越来越受到关注,特别是在增强图数据表达能力和提高图学习性能方面^[9]。Tang等^[10]将CSI的相位和振幅信息结合,构建了用于图神经网络的结构化图数据。相位信息在此过程中起到了表征图中局部拓扑关系的关键作用,增强了模型的图学习能力。

基于上述研究成果,图增强技术在有效利用低频信息方面表现优异,但在高频信息的捕获与保留方面仍存在一定的局限性,这可能导致模型在学习图网络的局部细节时出现信息丢失或特征偏差。针对这一问题,本文提出了一种基于相位保持的频域MinMax框架图增强方法。该方法充分结合频域分析与MinMax框架学习策略,对图数据进行高低频划分并分别建模,从而更准确地捕获图的局部细节与全局拓扑结构。在频域中,低频分量主要反映整体的拓扑结构,而高频分量是对局部结构细微变化的刻画。现有方法在增强过程中对高频信息的利用较少,可能会导致特征偏差或信息丢失,从而影响模型的性能和准确性。因此,本文首先引入频域增强的

方法,通过分别优化高、低频信息的表达,让模型在保持全局信息的同时可以更有效地捕捉高频特征,弥补传统方法在高频信息利用上的不足。具体而言,本文方法首先利用图的拉普拉斯特征分解,将图数据转换到频域表示,并基于拉普拉斯特征值对频域进行划分,从而区分高频和低频。随后,在MinMax框架下对低频部分采用最小化策略,这样可以确保增强后的图数据能够保留整体拓扑结构信息;而对高频部分则采用最大化策略增强局部信息细节,使模型在增强过程中得到充分学习。为了进一步提升模型对图数据结构的建模能力,本文方法在频域增强过程中引入了相位保持策略,利用相位信息描述节点与边的拓扑关系以及局部结构变化趋势。由于相位信息对图的拓扑完整性至关重要,因此在增强过程中让频域数据在相位上保持稳定,避免增强过程对原始拓扑关系的破坏,从而提升特征表示的准确性。最后,为了提高训练效率,减少计算开销,本文方法还结合了MinMax框架的动态优化策略,以自适应的方式调整增强幅度。在训练过程中,通过损失函数动态评估增强效果,并在不同频率分量上优化增强幅度,从而在不同数据分布下实现最优的增强策略。综上所述,本文方法的主要贡献如下:

1)结合频域分析与MinMax框架,提出了一种新的图增强方法,其能够在保持全局拓扑信息的同时增强高频细节,提高模型的多尺度学习能力;

2)在增强过程中引入相位保持策略,以保持图的拓扑结构完整性,从而进一步提升图的特征表达能力,确保增强后的数据能够更好地适应不同任务的需求;

3)采用自适应增强策略,根据不同频率分量的特征动态调整增强幅度,提高训练效率,抑制增强过程中的噪声。

本文方法在多个数据集上均优于传统方法的分类性能,并在计算效率上展现出优势。

2 相关工作

近年来,图神经网络在复杂结构数据的建模能力上不断提升,因此对数据的优化处理方式就显得尤为重要。如何使用不同的增强策略来提高模型的泛化能力,也成为了研究者关注的重要问题。早期的方法大多采用随机增强策略。例如, DGI(Deep Graph Infomax)^[11]采用随机增强策略对节点特征进行扰动以生成正负对比样本,通过最大化全局图表示与局部节点表示之间的互信息来优化节点嵌入。该方法利用无监督对比学习机制^[12],在无需标签的情况下有效提取图结构与特征信息,从而提高了模型的泛化能力。而GRACE(Graph Contrastive Coding)^[13]则通过随机添加或删除边来构造不同的视图。这类方法尽管能够提升模型的多样性,但由于缺乏对图结构信息的精细控制,可能会破坏原始图的拓扑结构^[14],影响学习到的特征的表达能力。

为了解决这一问题,研究者提出了自适应增强策略^[15],使图数据增强的过程变得更加合理和高效。GCA(Graph Contrastive Augmentation)方法^[16-17]基于注意力机制识别关键边,对不重要的连接进行扰动,从而减少对全局拓扑的破坏。另一种方法ProGCL^[18]则利用梯度信息引导增强过程,在训练过程中逐步调整图的结构或特征,使模型能够自适应

地选择需要修改的结构,以优化对比学习目标。与此同时,频域增强方法在图数据增强中的应用也受到了广泛关注。傅里叶变换^[19]可以将图信号从空间域映射到频域,分析不同频率分量对图结构的影响。传统的图信号处理方法,如 GSP (Graph Signal Processing)^[20],在分析和处理图数据时通常依赖固定的滤波参数,这在面对复杂和多变的图结构时可能难以适应。由于图的拓扑结构具有较大的差异性,预设参数的滤波方式往往难以捕捉图数据的多尺度特征,因此在不同应用场景下的泛化能力受到限制。为提升频域增强的自适应性,GFTNN(Graph Fourier Transform Neural Network)^[21]通过学习频域中的关键分量,并在增强过程中选择性地保留或调整不同频率的信号,来优化模型的特征学习。此外,GWNN(Graph Wavelet Neural Network)方法^[22-23]采用小波变换对图数据进行自适应频域分析,使增强策略能够依据多尺度信号特性动态调整滤波参数,从而适应不同类型的图数据。这些研究充分利用了图的频域特性,使得增强方法更加灵活,并在保持图整体结构的同时提高了模型对局部细节的刻画能力。

然而,除了频谱振幅,相位信息在图结构中同样扮演着至关重要的角色^[24]。相位不仅影响节点之间的相对关系,还决定了图信号的特征分布和局部模式。Xu 等^[25]研究了稀疏 SAR 成像的相位保持能力,通过对比分析验证了稀疏重建方法在干涉测量中的相位稳定性。结果表明,相位保持不仅能有效抑制噪声和旁瓣,还能提高成像精度。该研究表明,在图数据增强中引入相位保持约束,同样能够提升模型的结构稳定性和特征表达能力。

3 基于相位保持的频域 MinMax 框架图增强算法设计

3.1 频域 MinMax 框架构建

本节在频域下构建 MinMax 框架,以有效区分并利用图数据的高频与低频信息。通过对图的拉普拉斯矩阵进行特征分解,将图信号映射到频域,并根据特征值的分布划分高频和低频分量,同时分别采用最大化和最小化策略进行增强。该方法能够在保持全局拓扑结构的同时,加强对局部细节的建模。

3.1.1 频域信号分解与高低频划分

图信号的频域分析依赖于对图拉普拉斯矩阵的谱分解。给定图结构 $\mathcal{G}=(\mathcal{V},\mathcal{E},\mathbf{X})$,其中 \mathcal{V} 代表图中的节点集合, $\mathcal{V}=\{v_1,v_2,\dots,v_n\}$, \mathcal{E} 表示节点间的连接关系,而 $\mathbf{X}\in\mathbf{R}^{n\times d}$ 是节点特征矩阵。图 \mathcal{G} 的对称归一化拉普拉斯矩阵为:

$$\mathbf{L}=\mathbf{I}-\mathbf{D}^{-1/2}\mathbf{A}\mathbf{D}^{-1/2}\in\mathbf{R}^{n\times n} \quad (1)$$

其中, \mathbf{D} 为度矩阵,对角元素 $D_{ii}=\sum_j A_{ij}$; \mathbf{A} 为邻接矩阵。对 \mathbf{L} 进行谱分解:

$$\mathbf{L}=\mathbf{U}\mathbf{A}\mathbf{U}^T \quad (2)$$

$$\mathbf{A}=\text{diag}(\lambda_1,\lambda_2,\dots,\lambda_n)$$

其中,正交矩阵 $\mathbf{U}=\{u_1,u_2,\dots,u_n\}$ 的列向量构成图傅里叶基;特征值 λ_k 表征频率分量,较小的 λ_k 对应低频,较大的 λ_k 对应高频。随后,将节点特征矩阵 $\mathbf{X}\in\mathbf{R}^{n\times d}$ 通过图傅里叶变换投影至频域:

$$\hat{\mathbf{X}}=\mathbf{U}^T\mathbf{X}=\{\hat{\mathbf{x}}_1,\hat{\mathbf{x}}_2,\dots,\hat{\mathbf{x}}_n\}^T \quad (3)$$

其中, $\hat{\mathbf{x}}_k=\mathbf{U}_k^T\mathbf{X}$, $\mathbf{X}\in\mathbf{R}^d$ 表示第 k 个频率分量上的信号投影。接着,根据特征值的大小,将频域信号划分为高频和低频。这里,特征值 λ_k 按升序排序,即 $\lambda_1\leq\lambda_2\leq\dots\leq\lambda_n$ 。定义固定的比例进行频域划分。

1) 低频子集:选取前 $k(k=\lfloor n/3 \rfloor)$ 个特征值对应的分量, $S_L=\{1,2,\dots,k\}$ 。

2) 高频子集:选取后 k 个特征值对应的分量, $S_H=\{n-k+1,n-k+2,\dots,n\}$ 。

通过固定比例直接划分高频和低频,避免了动态阈值的学习成本,确保了增强的可复现性。

3.1.2 傅里叶 MinMax 框架

传统图对比学习中的 MinMax 框架通过对抗性优化生成两个增强视图,目的是通过最大化视图间的差异来提升模型鲁棒性。其核心思想为:通过扰动矩阵的优化,驱动一个分支增强图的谱范数,另一个分支抑制谱范数,从而构造出谱域上的最大边界。设原始图的邻接矩阵为 \mathbf{A} ,其归一化拉普拉斯矩阵为 $\mathbf{Lap}(\mathbf{A})$,对应的特征值向量为 $\mathbf{eig}(\mathbf{Lap}(\mathbf{A}))$,定义扰动矩阵 $\Delta\in S$,其中 $S=\{s|s\in[0,1]^{n\times n},\|s\|_1\leq\epsilon\}$, ϵ 控制全局扰动强度。单分支优化目标为最大化增强图与原始图的谱差异:

$$\text{Single}_{\text{way}}:\max_{\Delta\in S}\|\mathbf{eig}(\mathbf{Lap}(\mathbf{A}+\mathbf{C}\odot\Delta))-\mathbf{eig}(\mathbf{Lap}(\mathbf{A}))\|_2^2 \quad (4)$$

其中, \mathbf{C} 为扰动方向矩阵, $C_{ij}=1$ 表示添加边,而 $C_{ij}=-1$ 表示删除边; \odot 表示哈达玛积,是指两个同维矩阵的逐元素乘积,即为 $(\mathbf{A}\odot\mathbf{B})_{ij}=A_{ij}\cdot B_{ij}$; $\|\cdot\|_2^2$ 为欧氏距离的平方,用于量化谱差异,这里通过优化扰动矩阵 Δ ,生成在期望上与原始图谱差异最大的单视图。

与此同时,为了提升增强多样性,引入了双扰动矩阵 Δ_1 和 Δ_2 :

$$\begin{cases} \mathbf{A}'_1=\mathbf{A}+\mathbf{C}\odot\Delta_1 \\ \mathbf{A}'_2=\mathbf{A}+\mathbf{C}\odot\Delta_2 \end{cases} \quad (5)$$

从而分别生成视图来最大化二者间的谱差异:

$$\text{Double}_{\text{way}}:\max_{\Delta_1,\Delta_2\in S}\|\mathbf{eig}(\mathbf{Lap}(\mathbf{A}'_1))-\mathbf{eig}(\mathbf{Lap}(\mathbf{A}'_2))\|_2^2 \quad (6)$$

式(6)为式(4)的拓展,通过联合优化两个扰动矩阵,构造更具有挑战性的视图对。当 $\Delta_2=0$ 时,式(6)变为式(4)。同时,直接优化式(6)需要联合求解高维度矩阵,这样会使计算成本较高。为此,利用谱范数的三角不等式 $\|a-b\|_2\geq\|a\|_2-\|b\|_2$,将其分解为独立优化目标:

$$\max_{\Delta_1,\Delta_2\in S}(\|\mathbf{eig}(\mathbf{Lap}(\mathbf{A}'_1))\|_2^2-\|\mathbf{eig}(\mathbf{Lap}(\mathbf{A}'_2))\|_2^2) \quad (7)$$

此分解将双分支目标分解为两个独立问题,即最大化 Δ_1 对应视图的谱范数,同时最小化 Δ_2 对应视图的谱范数,形成对抗机制。

前文提到为了进一步区分高、低频特性,定义图谱 $\mathbf{eig}(\mathbf{Lap}(\mathbf{A}))$ 按升序排列为 $\lambda_1\leq\lambda_2\leq\lambda_3\leq\dots\leq\lambda_n$,并且划分频段:前 k 个特征值为低频子集对应的全局连通性,后 k 个特征值为高频子集对应的局部细节噪声。因此,本文在 MinMax 对抗优化框架的基础上,将扰动目标函数细化为频段选择性的优化目标。通过引入频域掩码矩阵,模型可以实现高频增强

与低频抑制的差异化调节策略。这里的 \mathbf{M}_L 指高频权重, 而 \mathbf{M}_H 指低频权重。具体地, 定义两个扰动分支分别优化如下目标:

$$Opposite_{direction} : \max_{\mathbf{A}_1 \in S} \mathcal{L}_{GS}(\mathbf{A}_1), \min_{\mathbf{A}_2 \in S} \mathcal{L}_{GS}(\mathbf{A}_2) \quad (8)$$

其中, \mathbf{A}_1 表示高频增强方向的扰动变量, \mathbf{A}_2 表示低频抑制方向的扰动变量, 二者共同构成对抗优化机制。该机制确保在增强图节点局部细节表达能力的同时, 保持整体图结构的拓扑稳定性。

上述优化目标函数 $\mathcal{L}_{GS}(\mathbf{A})$ 可表示为:

$$\mathcal{L}_{GS}(\mathbf{A}) = \|\mathbf{M}_H \odot \text{eig}(\text{Lap}(\mathbf{A}_1'))\|_2^2 - \|\mathbf{M}_L \odot \text{eig}(\text{Lap}(\mathbf{A}_2'))\|_2^2 \quad (9)$$

其中, \mathbf{M}_L 为对角矩阵, 前 k 个对角线元素为 1, 其余为 0; \mathbf{M}_H 也为对角矩阵, 其后 k 个对角线元素为 1, 其余为 0。该目标函数驱动 \mathbf{A}_1 增强高频差异 ($\max_{\mathbf{A}_1 \in S} \mathcal{L}_{GS}(\mathbf{A}_1)$), \mathbf{A}_2 抑制低频偏移 ($\min_{\mathbf{A}_2 \in S} \mathcal{L}_{GS}(\mathbf{A}_2)$), 从而实现在频域上的优化。为了更加具体地说明高频增强的实现过程, 进一步梳理了高频信息增强的步骤。高频信息增强的具体算法流程如下:

- 1) 设置可训练参数 θ_L 和 θ_H , 其中 θ_L 为低频抑制因子, θ_H 为高频增强因子;
- 2) 对节点特征矩阵进行傅里叶变换, 根据式(3)对节点特征进行频域投影, 得到频域分量;
- 3) 进行频段划分, 按照特征值大小排序定义高频子集 S_H , 通过固定比例划分确保可复现性;
- 4) 提取高频分量投影, 构建高频掩码矩阵 \mathbf{M}_H ;
- 5) 应用增强因子对高频信息进行增强, 避免全频增强造成过拟合;
- 6) 增强之后进行逆傅里叶变换, 得到增强后的节点特征矩阵。

其中, θ_L 和 θ_H 在训练过程中通过损失函数的反向传播自动更新。通过这种方式, 模型能够根据当前任务的语义需求和图结构的局部差异, 动态调整不同频段的表示强度, 从而有效避免了静态增强策略可能引起的过拟合或结构扰动失衡问题。后续步骤中, 节点特征矩阵首先经过图傅里叶变换转换为频域表示, 再通过对特征值排序实现频段划分, 确保高频子集的定义具有一致性与可复现性。步骤 4 所提到的高频掩码矩阵 \mathbf{M}_H 可被看作一种频段选择器, 它通过屏蔽非目标频段的幅度分量, 使增强操作仅在高频区域生效, 进而避免对图的整体结构造成无效扰动。随后, 在步骤 5 中, 增强幅度与频谱成分进行逐元素乘法, 从而完成频域上的高频放大操作, 这一过程在数学上对应于频率选择性地调节节点特征的局部响应能力。最后, 通过逆傅里叶变换将调整后的频域特征还原回时域, 完成整个高频增强流程。

3.2 节点相位保持策略

受到 Huang 等^[26]研究的启发, 注意到相位信息反映了图节点的特征结构, 对图的拓扑完整性至关重要, 因此本文提出了节点相位保持策略。频域相位信息反映了图节点的特征结构, 给定节点特征矩阵 $\mathbf{X} \in \mathbb{R}^{n \times d}$, 其傅里叶变换为 $\mathbf{F}_x = FFT(x)$, 每个频率分量 $\mathbf{F}_x(u)$ 的相位定义为:

$$PS_x(u) = \arctan\left(\frac{\text{Imag}(\mathbf{F}_x(u))}{\text{Real}(\mathbf{F}_x(u))}\right) \quad (10)$$

相位保持通过直接复用原始特征的相位谱实现, 具体来说, 增强后的频域信号 $\mathbf{F}_{x'}$ 由修正后的幅度谱 AS_x^{aug} 与原始相位谱 PS_x 组合生成。修正后的幅度谱为:

$$AS_x^{aug} = \begin{cases} \theta_L \cdot AS_x(u) \text{ 低频分量}, & u \in S_L \\ \theta_H \cdot AS_x(u) \text{ 高频分量}, & u \in S_H \end{cases} \quad (11)$$

其中, θ_L 和 θ_H 是设置的两个可训练的参数, θ_L 用于低频分量, θ_H 用于高频分量。因此, 增强后的频域信号为:

$$\mathbf{F}_{x'} = AS_x^{aug} \odot e^{I \cdot PS_x} \quad (12)$$

其中, \odot 为哈达玛积, I 为虚数单位。经过逆傅里叶变换后, 得到增强特征:

$$x' = iFFT(\mathbf{F}_{x'}) \quad (13)$$

相位分量 PS_x 编码了节点特征在频域中的相对位置和局部模式。为保持增强过程中拓扑结构的完整性, 约束增强后的特征 x' 必须与原始 x 共享相同的相位谱, 即:

$$PS_{x'}(u) = PS_x(u), \forall u \quad (14)$$

该约束确保了增强仅作用于幅度谱 $AS_x(u) = |\mathbf{F}_x(u)|$, 避免了相位扰动对节点特征局部结构的破坏。将相位保持和幅度调整结合后可得到:

$$\mathcal{L}_{AS} = \sum_{j \in S_H} \|AS_x^{aug}(j)\|_2^2 - \sum_{i \in S_L} \|AS_x^{aug}(i)\|_2^2 \quad (15)$$

其中, 在相位保持策略部分, 扰动矩阵 \mathbf{A} 以频域幅度谱调整的形式存在, 具体体现在式(11)中的两个可训练参数中。结合式(9), 定义联合损失函数为:

$$\mathcal{L}_{total} = \mathcal{L}_{GS}(\mathbf{A}) + \mathcal{L}_{AS} \quad (16)$$

最终的损失函数由两部分组成, 分别针对边和节点进行设计。其中, $\mathcal{L}_{GS}(\mathbf{A})$ 通过对图结构进行扰动, 生成结构上具有对比性的视图; 而 \mathcal{L}_{AS} 则通过相位保持, 对幅度谱进行调整, 从而对节点特征进行增强。两者共同构成整体优化目标, 从结构与特征两个角度提升图表示学习效果。

综上所述, 本文提出的相位保持策略通过严格约束增强后的频域相位信息与原始相位信息一致, 来确保节点特征的结构模式在增强过程中被完整保留; 并且, 相位分量的不变性避免了特征增强过程中的局部失真问题。结合动态调整的幅度信息, 本文方法在强化高频细节差异的同时, 通过频域 MinMax 框架优化特征的多尺度表达能力。这一设计显著提升了节点特征的区分度, 为图神经网络提供了更精准的局部语义表示, 从而增强了模型对复杂图数据的泛化能力。

本文算法的详细步骤如算法 1 所示。

算法 1 基于相位保持的频域 MinMax 算法

输入: 原始邻接矩阵 $\mathbf{A} \in \mathbb{R}^{n \times n}$, 节点特征矩阵度矩阵 $\mathbf{X} \in \mathbb{R}^{n \times d}$, 频段划分比例 ρ (默认 $\rho = 1/3$), 最大迭代次数 T

输出: 优化后的扰动矩阵 \mathbf{A}_1^* 和 \mathbf{A}_2^* , 生成的增强视图 \mathbf{A}_1^* 和 \mathbf{A}_2^*

1. 计算度矩阵 \mathbf{D} , 并由度矩阵计算归一化图拉普拉斯矩阵 \mathbf{L}
2. 根据式(2)对 \mathbf{L} 特征分解, 得到特征向量和特征值
3. 由式(3)对节点特征频域投影, 得到频域分量
4. 进行频段划分, 定义高频子集 S_H 与低频子集 S_L , 构建频域掩码矩阵 \mathbf{M}_H 和 \mathbf{M}_L
5. 初始化扰动矩阵, 根据式(8)和式(9)定义频域对抗目标函数
6. 设置可训练参数 θ_L 和 θ_H , 计算增强后的频域信号, 由逆傅里叶变换得到增强后的特征
7. 结合相位保持策略, 进一步定义联合损失函数
8. 如果达到最大迭代次数 T 或者是低频差异收敛: $\|\mathbf{M}_L \odot (\mathbf{A}' -$

$\Lambda) \|\frac{1}{2} < \delta$, 高频差异饱和: $\|M_H \odot (\Lambda' - \Lambda)\|_2 > \gamma$ 时终止训练, 并生成增强视图

4 实验与结果分析

为了验证本文算法的有效性, 本章选取了若干具有代表性的数据集, 如 Cora 和 Citeseer 等进行实验, 将所提算法与其他优秀的图增强算法进行对比分析。所有实验都在 Linux 系统环境下, 借助 Python 3.7 语言以及深度学习框架 PyTorch 1.12.1 完成。训练过程中使用了 NVIDIA Quadro RTX8000 专业显卡进行加速。

4.1 数据集、对比算法与评估标准

如表 1 所列, 本文选取了 6 个具有代表的数据集进行实验。

表 1 实验所用数据集

Table 1 Datasets used in the experiments

数据集	节点数量	节点特征维度	类别数
Cora	2708	1433	7
Wiki-CS	11701	300	10
PubMed	19717	500	3
Citeseer	3327	3703	6
Amazon-Photo	7650	745	8
Amazon-Computer	13572	767	10

1)Cora: 一个被广泛使用的引文网络数据集, 包含 2708 篇计算机科学领域的论文, 每篇论文以 1433 维的词向量表示, 并被划分为 7 个主题类别。节点之间的边表示引用关系, 被广泛用于图神经网络的性能评估。

2)Wiki-CS: 由英文维基百科条目构成, 节点表示词条, 边表示词条之间的内部链接关系。该数据集包含 11701 个节点、300 维特征, 划分为 10 个学科类别, 常用于评估跨领域图表示学习模型的泛化能力。

3)PubMed: 一个被广泛用于图神经网络研究的引文网络数据集, 包含 19717 篇医学论文, 节点以 500 维 TF-IDF 特征表示, 边表示论文之间的引用关系。该数据集包含 3 个疾病类别, 常用于评估图神经网络在大规模图结构上的表示学习能力。

4)Citeseer: 一个经典的图神经网络基准数据集, 构建自科学文献的引文网络, 包含 3327 篇论文与 4732 条引用边。每个节点以 3703 维词袋特征表示, 划分为 6 个学科类别, 用于评估模型在稀疏图和高维特征条件下的表示能力。

5)Amazon-Photo: 来源于亚马逊的商品共购网络, 节点表示商品, 边表示被共同购买的关系。该数据集包含 7650 个节点、745 维特征, 划分为 8 个商品类别, 常用于评估图神经网络在电商推荐与社区划分任务中的表现。

6)Amazon-Computer: 同样来源于亚马逊的共购网络, 节点代表计算机类商品, 边表示共购关系。该数据集包含 13752 个节点、767 维特征, 划分为 10 个商品类别, 常用于评估图神经网络在电商图结构上的表示与分类性能。

本文基于相位保持的频域 MinMax 算法将与以下几个图增强算法进行比较分析。

1)DGI^[11]: 一种无监督图表示学习方法, 通过最大化局部节点表示与全局图表示之间的互信息挖掘图结构中的潜在特征模式。该方法通过引入图结构扰动生成负样本, 提升模型对结构和特征噪声的鲁棒性。

2)MVGR^[27]: 一种基于多视图学习的图增强算法, 通过引入不同的图表示学习策略, 增强图数据的表示能力。

3)GCA^[16-17]: 通过对图结构进行对比增强, 利用图的局部和全局信息提升表示学习的效果。该算法通过自监督对比学习策略, 增强了图神经网络对不同视图的适应能力。

4)GRACE^[13]: 通过自监督对比学习增强图数据的表示能力, 利用图结构中的局部和全局信息进行有效的特征学习。该算法通过图的对比增强策略, 优化了节点和图的表示效果。

5)GBT: 通过引入冗余抑制机制, 最大限度地保留图结构和节点特征的信息。该方法在自监督对比学习框架下, 实现了高效且稳定的图表示增强。

6)GCL-SPAN: 通过频谱增强策略对图数据进行对比学习, 提升图神经网络的表示能力。该算法结合频谱信息与对比学习方法, 优化了图的表示学习效果。

为了评估本文算法的有效性, 采用准确率、F1 值和运行时间 3 个指标进行实验分析。将各个方法在每个数据集中进行 10 次测试并取平均值作为结果来减少实验的偶然性。

1)准确率: 评估分类模型性能的基本指标之一, 反映了模型在整体样本中预测正确的比例。

$$Accuracy = \frac{TN + TP}{FN + FP + TN + TP} \quad (17)$$

其中, TP 表示将正类正确分类为正类的样本数, TN 表示将负类正确分类为负类的样本数, FP 表示将负类错误分类为正类的样本数, FN 表示将正类错误分类为负类的样本数。

2)F-score: 分类任务中常用的综合评价指标, 主要用于衡量模型在正类样本上的精确率与召回率之间的平衡。

$$F1 = 2 \times \frac{precision \times recall}{precision + recall} \quad (18)$$

其中, 精确率 $precision = \frac{TP}{TP + FP}$, 召回率 $recall = \frac{TP}{TP + FN}$ 。

4.2 实验结果

为了验证所提方法的有效性, 在多个常用于节点分类任务的图数据集上进行了系统实验, 这些数据集已广泛作为图表示学习标准评估基准。本文方法与多种主流图神经网络进行了对比分析, 包括 DGI, MVGR, GCA, GRACE, GBT 以及 GCL-SPAN。每组实验均在每个数据集上重复运行 10 次来保证实验结果的稳定性和公平性, 并且取平均值作为最终结果。具体的准确率和 F1-score 结果分别如表 2 和表 3 所列。

表 2 列出了各个算法在不同数据集下的平均准确率, 其中最高准确率用加粗表示, 次高准确率用下划线表示。需要特别指出的是, GCL-SPAN 代表的是标准 MinMax 图对比学习框架下的性能基线, 而本文方法是在此基础上集成了相位保持策略后的结果。由表 2 可以看出, 本文方法在多个基准数据集上均取得了最优或者是次优的性能表现, 在整体上超越了主流图表示学习方法。更重要的是, 与基线 GCL-SPAN 相比, 本文方法在 Cora, PubMed, Citeseer, Photo 和 Computer 这 5 个数据集上均取得了显著的准确率提升, 尤其是在 PubMed 数据集中, 比次优方法的准确率提高了 4 个百分点。同时, 在 Cora 和 Amazon-Photo 数据集中也有不错的提升。所提方法虽然在 WIKI-CS 数据集中的准确率仅为次优, 但是和最优算法的准确率差距也只在 1 个百分点内, 这可能是训练过程中的随机性导致的。这一显著的性能提升主要

得益于所引入的频域图增强机制,尤其是在保持相位信息不变的前提下对频谱幅值进行针对性扰动的设计。频域变换中的相位保持策略保证了图结构中的核心拓扑不被破坏,而在增强过程中避免了无效扰动带来的性能波动,这也解释了

所提方法在各数据集上所体现出的低方差与高稳定性。总体而言,所提方法不仅在准确率上优于当前主流方法,还在设计理念上实现了从时域增强到频域增强的范式迁移,兼顾了表达能力与稳定性。

表2 算法的平均准确率

Table 2 Average accuracy of algorithms

Methods	Cora	Wiki-CS	PubMed	Citeseer	Photo	Computer
GCN	81.32±0.50	76.85±0.10	77.69±0.30	70.84±0.70	92.16±0.20	87.06±0.50
DGI	82.34±0.64	75.35±0.14	76.82±0.61	71.85±0.74	91.61±0.22	83.95±0.47
MVGRL	85.16±0.52	77.52±0.08	80.13±0.84	<u>72.14±1.35</u>	92.78±0.30	87.52±0.11
GCA	83.67±0.44	78.35±0.05	78.87±0.49	71.48±0.26	92.53±0.16	88.94±0.15
GRACE	83.33±0.43	80.14±0.48	78.72±0.13	72.10±0.54	92.78±0.30	<u>89.53±0.35</u>
GBT	80.24±0.42	76.65±0.62	78.29±0.43	69.39±0.56	92.63±0.44	88.14±0.33
GCL-SPAN	<u>85.86±0.57</u>	79.13±0.15	<u>81.54±0.24</u>	70.96±0.63	<u>93.52±0.26</u>	88.95±0.12
Ours	87.42±0.29	<u>79.23±0.25</u>	85.12±0.31	72.55±0.29	94.23±0.22	89.85±0.21

(%)

表3 算法的平均 F1-score

Table 3 Average F1-score of algorithms

Dataset	Metrics	DGI	MVGRL	GCA	GRACE	GBT	GCL-SPA	Ours
Cora	Ma-F1	80.40±0.7	81.50±0.5	79.90±1.1	79.20±1.0	79.60±0.3	<u>84.82±0.3</u>	86.80±0.3
	Mi-F1	82.00±0.5	82.80±0.4	81.10±1.0	80.00±1.0	80.24±0.4	<u>84.93±0.12</u>	87.42±0.2
PubMed	Ma-F1	76.80±0.9	79.80±0.4	80.80±0.6	80.00±0.7	78.20±0.3	<u>81.04±0.3</u>	84.63±0.2
	Mi-F1	76.70±0.9	79.70±0.3	81.40±0.6	79.90±0.7	78.30±0.4	<u>81.54±0.2</u>	85.05±0.3
Citeseer	Ma-F1	66.70±0.9	<u>66.80±0.7</u>	65.90±1.0	65.10±1.2	64.6±0.7	63.09±0.10	67.60±0.3
	Mi-F1	<u>71.70±0.8</u>	71.50±0.5	71.60±0.4	68.70±1.1	69.40±0.5	70.36±0.21	72.20±0.3

(%)

表3进一步从宏平均与微平均两个维度对比了各类方法在Cora, PubMed与Citeseer这3个标准数据集上的分类性能,以全面评估模型在类别分布不均或多类别场景下的表现。同样地,GCL-SPAN作为标准MinMax框架的基线,而本文方法则融入了相位保持策略。结果显示,基于相位保持的频域MinMax图增强算法在所有度量指标上均取得了领先表现,尤其在Cora与PubMed两个数据集上实现了全面领先,在Ma-F1和Mi-F1两项指标中分别达到了86.8%和87.42%以及84.63%和85.05%的准确率,明显优于当前主流对比方法,这进一步验证了模型在保持类别均衡识别与全局分类性能方面的双重优势。

为保证实验的公平性,所有实验结果都在NVIDIA Quadro RTX8000专业显卡上进行加速训练。本文提出的相位保持频域增强框架在计算复杂度方面有所优化。相较于传统图对比学习方法(如MVGRL的 $O(n^2d)$ 全局注意力瓶颈,GRACE的 $O(m)$ 边扰动约束),本文方法将核心计算复杂度降至 $O(n \log n \cdot d + k \log k \cdot d)$,其中 n 为节点总数, d 为特征维度, k 为选定的部分关键节点数。该复杂度有如下几个优势点:1)将全局傅里叶变换FFT的 $O(n \log n \cdot d)$ 开销限定于初始化阶段;2)通过节点重要性采样,仅对部分关键节点执行相位保持重组,使特征重构复杂度降至 $O(k \log k \cdot d)$;3)幅度缩放操作在频域直接进行,避免了 $O(nd)$ 的显式特征重建。在空间复杂度方面,采用频谱矩阵解耦存储技术,将传统复数矩阵的 $O(2nd)$ 开销优化为幅度矩阵 $O(nd)$ 与相位矩阵 $O(kd)$ 的分离存储。同时,图傅里叶变换(FFT)及其逆变换(IFT)作为经典可并行操作,能充分利用GPU的加速能力实现高效计算。幅度缩放操作在频域以逐元素方式独立执行,无数据依赖关系,支持细粒度并行。关键节点的相位重组

过程同样具备节点级独立性;此外,所有频域操作在特征维度 d 上均支持并行化计算。实验结果表明,基于相位保持的频域MinMax方法在图数据增强任务中实现了效率与性能的显著平衡。在Wiki-CS, PubMed, Amazon-Photo和Citeseer数据集上,本文方法的运行时间相比传统方法都有一定缩短,尤其是在PubMed数据集中效果显著,其余算法均在2600s以上,本文算法只使用了1600s。从图1可以看出,不管是在大型数据集PubMed,还是在一些小型数据集(如Citeseer)上,所提方法在计算效率上都有一定提升。

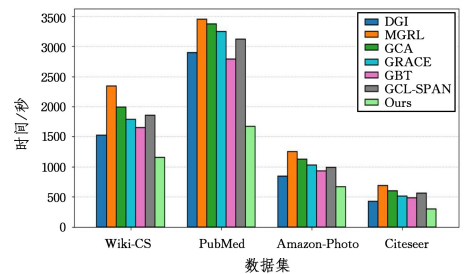


图1 各类算法运行时间的对比

Fig. 1 Comparison of runtime among various algorithms

结束语 本文针对图增强技术对高频信息利用不足的问题,提出了一种基于相位保持的频域MinMax框架图增强方法。通过将频域分析与MinMax对抗优化机制深度融合,本文方法在增强过程中显式区分高频和低频分量,并引入相位保持策略来保护局部拓扑结构的完整性,实现了图数据表达能力的显著提升。实验结果表明,在Cora, PubMed和Citeseer等数据集上,所提方法在节点分类任务中的准确率平均提升2个百分点以上,且在PubMed数据集中达到了85.12%的分类精度,较现有最优方法GCL-SPAN提升了3个百分点以上。

同时,所提方法在计算效率上也有一定提升,在多个数据集中均优于现有算法,在大规模图数据场景下具有可扩展性。

参 考 文 献

[1] ZHANG Y, XIONG S, WANG Z, et al. Local augmented graph neural network for multi-omics cancer prognosis prediction and analysis [J]. *Methods*, 2023, 213: 1-9.

[2] ZHOU J, XIE C, GONG S, et al. Data augmentation on graphs: a technical survey [J]. *arXiv:2212.09970*, 2022.

[3] WEI Z, XIAO X, ZHANG B, et al. Graph Data Augmentation for Node Classification[C]// *Proceedings of the 2022 26th International Conference on Pattern Recognition(ICPR)*. 2022.

[4] ALI A, LI J. Features based adaptive augmentation for graph contrastive learning [J]. *Digital Signal Processing*, 2024, 145: 104312.

[5] XU Y, WANG J, GUANG M, et al. Graph contrastive learning with min-max mutual information [J]. *Information Sciences*, 2024, 665: 120378.

[6] ZHOU X C, SHEN X J. Graph Augmentation Method Based on Fourier Spectrum Perception[J]. *Journal of Chinese Computer Systems*, 2025, 46(11): 2667-2673.

[7] LIU Y, DU B. Frequency Domain-Oriented Complex Graph Neural Networks for Graph Classification [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2025, 36(2): 2733-2746.

[8] SUN Y, DUAN Y, MA H, et al. High-frequency and low-frequency dual-channel graph attention network [J]. *Pattern Recognition*, 2024, 156: 110795.

[9] LIANG Z, GONG R, TAN G, et al. A Frequency Domain Kernel Function-Based Manifold Dimensionality Reduction and Its Application for Graph-Based Semi-Supervised Classification [J]. *Applied Sciences*, 2024, 14(12): 5342.

[10] TANG X, YAN J. A CSI Amplitude-phase Information Based Graph Construction for GNN Localization[C]// *Proceedings of the 2023 International Conference on Computer, Information and Telecommunication Systems(CITS)*. 2023.

[11] ZHOU Z, HU Y, ZHANG Y, et al. Multiview Deep Graph Info-max to Achieve Unsupervised Graph Embedding [J]. *IEEE Transactions on Cybernetics*, 2023, 53(10): 6329-6339.

[12] XIE Y, LUO L, CAO T, et al. Contrastive Learning Network for Unsupervised Graph Matching [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2025, 35(1): 643-656.

[13] REN Y, BAI J, ZHANG J. Label Contrastive Coding based Graph Neural Network for Graph Classification[C]// *Proceedings of the International Conference on Database Systems for Advanced Applications*. 2021.

[14] AN D, PAN Z, ZHAO Q, et al. Unsupervised Graph Structure Learning Based on Optimal Graph Topology Modeling and Adaptive Data Augmentation [J]. *Mathematics*, 2024, 12(13): 1991.

[15] XU X, ZHAO H. Universal adaptive data augmentation [J]. *arXiv:2207.06658*, 2022.

[16] ZHUO W, TAN G. Graph contrastive learning with adaptive proximity-based graph augmentation [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(10): 14.

[17] LI X, WANG Y, WANG Y, et al. Graph contrastive learning for recommendation with generative data augmentation [J]. *Multimedia Systems*, 2024, 30(4): 170.

[18] XIA J, WU L, WANG G, et al. Progcl: Rethinking hard negative mining in graph contrastive learning [J]. *arXiv:2110.02027*, 2021.

[19] BAGHERI BARDI A, YAZDANPANA H T, DAKOVIC M, et al. Graph Fourier Transform Enhancement through Envelope Extensions [J]. *arXiv:2407.19934*, 2024.

[20] ORTEGA Y R, GUERREIRO I M, HUI D, et al. Supervised learning and graph signal processing strategies for beam tracking in highly directional mobile communications [J]. *Transactions on Emerging Telecommunications Technologies*, 2019, 30(9): e3687.

[21] NEUMEIER M, TOLLKÜHN A, BOTSCH M, et al. A multidimensional graph fourier transformation neural network for vehicle trajectory prediction[C]// *Proceedings of the 2022 IEEE 25th International Conference on Intelligent Transportation Systems(ITSC)*. IEEE, 2022.

[22] WANG P, WEN Z. A spatio-temporal graph wavelet neural network(ST-GWNN) for association mining in timely social media data [J]. *Scientific Reports*, 2024, 14(1): 31155.

[23] DEB S, RAHMAN S, RAHMAN S. GA-GWNN: Generalized Adaptive Graph Wavelet Neural Network [J]. *Pattern Recognition Letters*, 2024, 177: 128-34.

[24] CHAN V, GAN Q, BAYEN A. A Graph Convolutional Network with Signal Phasing Information for Arterial Traffic Prediction [J]. *arXiv:2012.13479*, 2020.

[25] XU Z, ZHANG B, LI G, et al. Analysis of phase preservation and interferometric offset test in sparse SAR imaging [J]. *Science China Information Sciences*, 2024, 67(2): 122303.

[26] HUANG H, KANG H, LIU S, et al. Paddles: Phase-amplitude spectrum disentangled early stopping for learning with noisy labels[C]// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2023.

[27] JIAO Z, ZHANG H, LI X. Deep Graph Multi-View Representation Learning With Self-Augmented View Fusion [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2025, 36(8): 14119-14130.



HUA Yu, born in 2002, postgraduate. His main research interests include graph neural networks and deep learning.



SHEN Xiangjun, born in 1977, Ph. D, professor, is a member of CCF (No. E200029891M). His main research interests include cross multimedia analysis, computer vision, pattern recognition and statistical machine learning.