

通过因果边分离和频谱解决图异常检测

Zengyi Wo

wozengyi1999@tju.edu.cn

Tianjin University

Tianjin, China

Wenjun Wang

Tianjin University

Tianjin, China

Minglai Shao*

shaoml@tju.edu.cn

Tianjin University

Tianjin, China

Chang Liu

Tianjin University

Tianjin, China

Yumeng Wang

Tianjin University

Tianjin, China

Yueheng Sun†

yhs@tju.edu.cn

Tianjin University

Tianjin, China

摘要

在现实世界中，异常实体通常会添加更多合法连接，同时隐藏与其他异常实体的直接联系，导致异常网络出现异质结构，而大多数基于 GNN 的技术无法解决这个问题。已经提出了一些方法来处理空间域中的这一问题。然而，这些方法忽略了节点结构编码、节点特征及其环境背景之间的复杂关系，并依赖于原理性指导，在频谱域异质问题上的研究仍然有限。本研究分析了不同异质程度的节点的频谱分布，并发现异常节点的异质性导致频谱能量从低频向高频转移。为了解决上述挑战，我们提出了一种基于因果边分离的光谱神经网络 CES2-GAD 用于异质图中的异常检测。首先，CES2-GAD 将原始图通过因果干预分成同质和异

质边缘。随后，使用各种混合频谱滤波器来捕捉分割后的图中的信号。最后，来自多个信号的表示被拼接并输入分类器以预测异常情况。大量基于真实数据集的实验验证了我们提出方法的有效性。

CCS CONCEPTS

• Computing methodologies → Neural networks.

KEYWORDS

图异常检测；因果分析；异质性；频谱

ACM Reference Format:

Zengyi Wo, Wenjun Wang, Minglai Shao, Chang Liu, Yumeng Wang, and Yueheng Sun. 2024. 通过因果边分离和频谱解决图异常检测. In *Proceedings of Make sure to enter the correct conference title from your rights confirmation email (KDD WorkShop)*. ACM, New York, NY, USA, 7 pages. <https://doi.org/XXXXXXX.XXXXXXX>

1 介绍

在当前的数字技术时代，互联网上的信息量正在经历指数级增长。同时，在金融网络 [1]、社交网络 [2] 和学术网络 [3] 等各个领域中，异常活动也在不断增加，并变得越来越猖獗，给众多行业带来了重大损失。因此，准确检测潜在的异常活动变得紧迫且至关重要。这一问题最近引起了研究人员的广泛关注。

*Corresponding author

†Corresponding author

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. Copyrights for components of this work owned by others than the author(s) must be honored. Abstracting with credit is permitted. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee. Request permissions from permissions@acm.org.

KDD WorkShop, August 25-26, 2024, Barcelona, Spain

© 2024 Copyright held by the owner/author(s). Publication rights licensed to ACM.

ACM ISBN 978-1-4503-XXXX-X/18/06

<https://doi.org/XXXXXXX.XXXXXXX>




图 1: 分析不同程度异常对空间域（顶部）和频谱域（底部）图的影响，特别关注 Barabási-Albert 图 (a) 和 Minnesota 道路图 (b) 在不同异常比例 ($\alpha = 0\%$, 5% , 10% , 20%) 下的情况。

图神经网络 (GNNs) 近年来在各个领域得到了广泛应用，这得益于它们能够有效地建模图形结构数据的能力。研究中出现了一种趋势，将 GNNs 整合到图异常检测 (GAD) 系统中，以利用异常图中存在的复杂拓扑信息。然而，由于同质性和异质性的结合，异常图提出了独特的挑战。异常实体经常与合法用户互动，以掩盖它们与其他异常实体的直接联系，在异常图中产生了更高比例的异质性边。这种复杂性使异常检测工作变得困难，因为传统的 GNN 算法在消息聚合和传播过程中基于同质性假设，这会平滑节点表示。现有基于 GNNs 及同质性假设的异常检测 [4, 5] 方法可能在学习表示时引入不准确之处，最终影响异常检测方法的有效性。

最近，许多研究正在探索解决上述挑战的方法 [6]。空间域。这些方法旨在缓解异质邻居在消息聚合过程中引入的噪声。它们通过诸如聚合相似邻居 [5]、重新采样邻居 [4] 和重新加权边 [7] 等策略来解决异常图中的异质性问题。谱域。这种方法通常基于谱 GNN，设计适当的滤波器 [8] 以区分高频和低频信号。这有助于更有效地处理异质信息。这些方法忽视了节点结构编码、节点特征及其环境背景之间的复杂关系。没有指导原则，这可能导致性能不佳，并且可能不适合异常检测。

为了解决上述挑战，我们提出了一种基于因果边分离的光谱神经网络 CES2-GAD 用于异质图上的异常检测。首先，CES2-GAD 将原始图通过因果干预分为同构和异构边。随后，使用各种混合频谱滤波器来捕捉分割后的图中的信号。最后，将多个信号的表示进行拼接并输入分类器以预测异常。我们工作的贡献总结：

- 我们分析了由同质边和异质边构建的图的谱能量分布。我们观察到，异质性导致谱能量从低频向高频转移，在分离后高频频段信号获得了更真实的表示。
- 我们提出了一种基于因果边分离的光谱神经网络 CES2-GAD，用于异质图上的异常检测。
- 在真实世界数据集上进行了广泛的实验，结果显示 CES2-GAD 的性能超过了现有的最先进的方法。

2 相关工作

2.1 异构图神经网络

异质性已成为 GNNs 的一个重要关注点，这个问题最初由 [9] 指出。分离自我和邻居嵌入 [10] 证明是一种在异质图上学习的有效技术。由于在同一类中的节点在异质图中相距甚远，一些方法旨在通过整合多层 [11] 来扩展局部邻居到非局部邻居，并通过注意力机制 [12] 或相似性度量 [13] 识别潜在的邻居。基于谱的方法 [14] 通过引入额外的图滤波器和混合策略来克服这一挑战，该策略旨在自适应地整合信息并强调某些频率。

2.2 基于 GNN 的异常检测

为了使基于同音假设的图神经网络在图异常检测中更有效，许多研究人员进行了广泛的研究。

与直接聚合相邻嵌入不同，Graph-Consis[5] 设计了三个模块来同时解决 GNN 在 GAD 中的三种不一致性问题。CARE-GNN[4] 结合了一种标签感知相似性度量方法，用于识别信息丰富的邻节点，并且包含了一个相似性感知邻节点选择器。PC-GNN[15] 结合了用于

构建子图的标签平衡采样器和用于选择候选邻节点的邻居采样器。GAGA[16] 提出了组聚合，明确地用它们的标签增强邻居特征，并将未标记的邻居视为一个独立类别。IHGAT[17] 同时捕获序列式的意图并编码交易之间的关系。

3 初步的

3.1 背景

3.1.1 多关系图. 设 $\mathcal{G} = \{\mathcal{V}, \mathbf{X}, \{\mathcal{E}_r^+, \mathcal{E}_r^-\}_{r=1}^R, \mathbf{Y}\}$ 表示一个多关系图，包含一组 N 节点 $\mathcal{V} = \{v_1, v_2, \dots, v_N\}$ ，一个同质边集 $\mathcal{E}_r^+$ 和一个异质边集 $\mathcal{E}_r^-$ 。这里， R 是关系的总数， $\mathbf{X} \in \mathbb{R}^{N \times D}$ 表示节点属性矩阵，而 $\mathbf{Y} \in \mathbb{R}^{N \times 1}$ 表示标签集其中 $y = 1$ 表示异常节点， $y = 0$ 表示正常节点。

3.1.2 基于图的异常检测方法. 基于图的异常检测探索涉及半监督二元分类问题。给定一个多关系图 $\mathcal{G}$ ，目标是根据节点集 $\mathcal{V}$ 、边集 $\{\mathcal{E}_r^+, \mathcal{E}_r^-\}$ 和部分标签数据 $\mathbf{Y}_{\text{train}}$ 训练一个分类器 f_θ ，以预测每个节点的标签，具体而言是检测某个节点是否异常。

3.1.3 图异质性. 对于一个图 $\mathcal{G}$ ，如果一条边连接了两个具有不同标签的节点（这里指的是异常节点和正常节点），那么这条边就是异亲性边。一个异常图同时包含同亲性和异亲性的边。一个节点的异亲性可以通过以下公式表示：

$$heter_{v_i} = \frac{|\{v_j : v_j \in \mathcal{N}(i) \mid y_i \neq y_j\}|}{|\mathcal{N}(i)|}, \quad (1)$$

其中， $\mathcal{N}(i) = \{v_j \mid (v_i, v_j) \in \mathcal{E}\}$ 表示节点 v_i 的邻居集。整个图的异质性可以定义为：

$$heter_{\mathcal{G}} = \frac{|\{e_{ij} : y_i \neq y_j\}|}{|\mathcal{E}|}, \quad (2)$$

其中， $e_{ij} \in \mathcal{E}$ 表示节点 v_i 和节点 v_j 之间的边。

3.1.4 图谱. 图拉普拉斯矩阵 [18] 可以定义为标准形式 $\mathbf{L} = \mathbf{D} - \mathbf{A}$ 或归一化形式 $\mathbf{L} = \mathbf{I} - \mathbf{D}^{-1/2} \mathbf{A} \mathbf{D}^{-1/2}$ ，其中 $\mathbf{A}$ 表示 $\mathcal{G}$ 的邻接矩阵， $\mathbf{D}$ 是度矩阵， $\mathbf{I}$ 是单位矩阵。 $\mathbf{L}$ 是一

个具有特征值的对称矩阵，即 $0 = \lambda_1 \leq \dots \leq \lambda_N$ ，对应的特征向量为 $\mathbf{U} = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_N)$ 和 $\hat{\mathbf{x}}$ 作为 $\mathbf{x}$ 的图傅里叶变换。通过提供一个任意阈值 λ_k ，我们可以将特征值分为低频 $\{\lambda_1, \lambda_2, \dots, \lambda_k\}$ 和高频 $\{\lambda_{k+1}, \lambda_{k+2}, \dots, \lambda_N\}$ 。

为了提供异常图分布的理论分析，我们给出以下定义：

- 光谱能量分布在 λ_k 处定义为： $\hat{\mathbf{x}}_k^2 / \sum_{i=1}^N \hat{\mathbf{x}}_i^2$ 。
- 谱能量比在 λ_k 处定义为前 k 个特征值的累积光谱能量分布，即 $\eta_k(\mathbf{x}, L) = \sum_{i=1}^k \hat{\mathbf{x}}_i^2 / \sum_{i=1}^N \hat{\mathbf{x}}_i^2$ 。
- 高频区域可以定义为：

$$S_{\text{high}} = \frac{\sum_{k=1}^N \lambda_k \hat{\mathbf{x}}_k^2}{\sum_{k=1}^N \hat{\mathbf{x}}_k^2} = \frac{\mathbf{x}^T \mathbf{L} \mathbf{x}}{\mathbf{x}^T \mathbf{x}}. \quad (3)$$

3.2 异质性和光谱与 GAD

3.2.1 观察. 在图 1 的顶部，我们使用橙色表示空间域中的异常节点。橙色节点越多，异常程度越高。在图的底部，我们展示了 $\mathbf{x}$ 在不同异常比例下在谱域中的能量分布。可以观察到，随着异常节点的异质性增加，低频部分的谱能量显著降低，而高频部分的谱能量显著增加。考虑到异常节点的稀有性和整个图的异质性相对稳定性，这非常引人注目。

3.2.2 分析. 根据谱图理论，给定图拉普拉斯矩阵 $\mathbf{L}$ 和类别标签作为真实信号 $\mathbf{Y}$ ，图的高频区域 S_{high} 随异常节点的异质性程度单调增加。

$$S_{\text{high}} = \frac{\mathbf{y}^T \mathbf{L} \mathbf{y}}{\mathbf{y}^T \mathbf{y}} = \frac{1}{2} \sum_{v_i \in \mathcal{V}} \sum_{v_j \in \mathcal{V}} A_{i,j} (y_i - y_j)^2 / \mathbf{y}^T \mathbf{y}, \quad (4)$$

异常节点的异质性表明，异常倾向于隐藏异常-异常边并构建更多的良性异常边。因此，高频率区域 S_{high} 将随着异质性的增加而增加。

给定同质子图 $\mathcal{G}_r^+$ 及其拉普拉斯矩阵 $\mathbf{L}_r^+$ ，以及异质子图 $\mathcal{G}_r^-$ 及其拉普拉斯矩阵 $\mathbf{L}_r^-$ 。异质子图 $\mathcal{G}_r^-$ 的高频区域 S_{high} 大于同质子图 $\mathcal{G}_r^+$ ，即， $S_{\text{high}}(\mathcal{G}_r^-) > S_{\text{high}}(\mathcal{G}_r^+)$ 。

4 方法论

概述如第 3.2 节所述, 我们通过分析异质图分布来强调高频信号在 GAD 中的重要性。为了有效提取这些信号, 我们提出了一种方法来分离原始图中的边, 并使用混合滤波器学习节点表示以进行异常检测, 该方法名为 CES2-GAD。

我们的模型包含三个主要模块: (1) 因果边分离, (2) 混合图谱滤波器, 以及 (3) 异常检测。在因果边分离模块中, 通过标记节点的监督信号, 因果干预方法区分同质边和异质边。这个过程有助于将原始图分解为同质边和异质边。混合图谱滤波器模块对这些分离后的图形应用特定滤波器以捕捉多样化的信号, 并结合来自各种关系的表现形式。最后, 使用多层感知机分类器根据获得的节点表示来识别异常节点。以下部分将详细介绍每个模块。

4.1 因果边分离

为了成功地从原图中分离出同质边和异质边, 我们提出了一种因果干预方法。通过研究图生成过程, 我们的目标是估计异质处理对两个节点之间边缘概率的影响, 以便我们可以通过操纵异质处理来干预图的分离。

4.1.1 因果处理. 我们将 T_{ij} 定义为节点对 (v_i, v_j) 的同质性, 表明这两个节点是否表现出同质性。当 $T_{ij} = 1$ 时, 表示相似的节点对 (v_i, v_j) 之间存在边且不相似的节点对 (v_i, v_j) 之间不存在边, 否则为 $T_{ij} = 0$ 。

4.1.2 反事实结果. 我们现在将解释用于生成反事实结果的方法。由于我们只能见证每个节点对的事实和结果的进展, 因此, 我们的目标是估计尽可能接近观测结果的反事实结果。实际上, 我们的目的是使用一组特定的观察到的节点对来确定那些经历相反过程且最相似的节点对, 并将其标记为反事实节点对。对于每一对节点 (v_i, v_j) , 我们定义它们的反事实连接如下:

$$(v_a, v_b) = \arg \max_{v_a, v_b \in V} [s(\tilde{x}_i, \tilde{x}_a) + s(\tilde{x}_j, \tilde{x}_b) \mid T_{ab} = 1 - T_{ij}], \quad (5)$$

其中 $s(\cdot, \cdot)$ 在嵌入空间 $\tilde{X}$ 中实现为欧几里得相似度。经验上, 嵌入 $\tilde{X}$ 通过将节点的原始特征与其结构编码 (通过拉普拉斯结构编码获得) 连接起来而得到, 受同质性的影响很小。

4.1.3 边缘分类器. 在事实结果和反事实结果的指导下, 我们现在可以学习一个边缘分类器, 该分类器旨在通过控制处理变量来生成增强视图。给定我们混合编码器 (稍后详细说明) 中的中间节点表示 Z 和治疗指示 T 或 T^{CF} , 我们可以按照以下方式分离同质子图 $\mathcal{G}_r^+$ 和异质子图 $\mathcal{G}_r^-$:

$$\mathcal{G}_r^+ = g_\theta(Z, T), \quad \mathcal{G}_r^- = g_\theta(Z, T^{CF}), \quad (6)$$

其中 $g_\theta(\cdot, \cdot)$ 表示边分类器, 我们经验性地采用简单的多层感知器 (MLP)。

4.2 混合图谱滤波器

在将原始图的边分开后, 同质性图代表了更多的低频信号, 而异质性图突出了高频信号。然后在分离后的图上应用各种滤波器以捕获不同频率范围内的信号。主要目标是从同质性和异质性的角度捕捉相似节点之间共享的共同信息。

4.2.1 低通图谱滤波器. 为了捕捉连接相似节点的同质性视角, 我们将邻接矩阵归一化为 $\tilde{\mathcal{E}}_r^+ = \hat{D}^{-1/2} \mathcal{E}_r^+ \hat{D}^{-1/2}$ 并在 SGC 中使用低通图滤波器来平滑节点表示如下:

$$Z_l^{\text{homo}} = \tilde{\mathcal{E}}_r^+ Z_{l-1}^{\text{homo}} W_{l-1}^{\text{low}}, \quad \text{and } Z_0^{\text{homo}} = X, \quad (7)$$

其中 $l \in \{1, \dots, L\}$ 表示层索引。最终层次的同质性视角表示矩阵是 $Z^{\text{homo}} = f_\phi^{\text{low}}(X, \mathcal{E}_r^+)$, 其中 $f_\phi^{\text{low}}(\cdot, \cdot)$ 是具有参数 $\phi = \{W_l \mid l \in \{0, \dots, L-1\}\}$ 的低通编码器。

4.2.2 高通图谱滤波器. 为了增强不同节点之间异种连接的表示, 我们使用高通滤波器来多样化节点表示。此过程可以定义如下:

$$Z_l^{\text{heter}} = (I - \alpha \tilde{\mathcal{E}}_r^-) Z_{l-1}^{\text{heter}} W_{l-1}^{\text{high}}, \quad \text{and } Z_0^{\text{heter}} = X, \quad (8)$$

表 1: 数据集的统计。

数据集	亚马逊		
#节点 (异常百分比)	11944 (6.87%)		
边关系	U-P-U	U-S-U	U-V-U
#数关系	351216	7132958	2073474
Class	Positive	Negative	Unlabeled
#数字-类别	821	7818	3305

这里, $\tilde{\mathcal{E}}_r^{CF}$ 表示归一化的 $\mathcal{E}_r^-$, 参数 α 作为控制过滤强度的超参数。由高通编码器生成的异种表示被记为 $Z^{heter} = f_{\psi}^{high}(X, \mathcal{E}_r^-)$ 。节点嵌入 Z 用于下游任务是来自两个分支的连接, 即 $z_i = [z_i^{homo}, z_i^{heter}]$ 。这一结论基于之前的观察结果, 即使对于异质边, 邻域也可能表现出比其他情况更高的标签同质性。在这种情况下, 比较来自低通滤波器和高通滤波器的表示变得生成高质量结果至关重要。相反, 在处理同质边时, 使用高通滤波器可以帮助缓解过度平滑相关的问题。

4.3 异常检测

我们在异常检测的背景下使用交叉熵损失。对于给定的训练节点集表示为 $\mathcal{V}_{train}$, 其中节点 v 的最终嵌入是 z_v , 其标签是 y_v , 损失函数被定义为:

$$\mathcal{L}_N = - \sum_{v \in \mathcal{V}_{train}} [y_v \log(p_v) + (1 - y_v) \log(1 - p_v)], \quad (9)$$

p_v 是节点 v 的嵌入向量的 softmax 值。

5 实验

5.1 实验设置

5.1.1 数据集. 我们使用真实场景中的异常检测数据集来评估 CES2-GAD 的有效性, 尤其是在 Amazon 数据集 [19] 上。该数据集包含乐器类别的产品评论。您可以在表 1 中找到数据集的详细统计信息。

5.1.2 基线. 我们对 CES2-GAD 与各种前沿的基于 GNN 的方法进行了比较分析, 以确认其在异常检测中的有效性。第一组方法包括**基于特征的方法**: 如 SVM 和 MLP。第二组包括**基于同音性 GNN**的方法: 包括 GCN[18]、

GraphSAGE[20]、GAT[21]、GIN[22] 和 ChebyNet[23]; 第三组包括**基于 GNN 的异常检测 (GAD 算法)**的方法: 包括 GraphCon-sis[5]、CARE-GNN[4]、PC-GNN[15] 和 GAGA[16]; 最后一组基于**异质性 GNN**的方法: 包括 ACM[24]、H²-FDetector[25]、BW-GNN[8] 和 GDN[26]。

5.1.3 评估协议. 我们选择了两个常用的指标, F1-macro 和 AUC, 来评估所有方法的性能。F1-macro 代表所有类别的平均 F1 分数, 不考虑正常标签和异常标签之间的不平衡, 而 AUC 表示 ROC 曲线下的面积。

5.1.4 模型超参数和实现细节. 在我们的实验设置中, 我们使用 PyTorch 和 Nvidia 3090 GPU 进行所有实验, 以保持计算环境的一致性。基线方法的学习率根据原论文中的指定值确定。我们将数据集划分为训练集、验证集和测试集, 比例为 0.4/0.2/0.4, 适用于所有比较的方法。我们的方法是通过利用 PyTorch 框架内的 DGL 和 PYG 库创建的, 而替代方案则使用公开可用的原材料进行编码。

5.2 实验结果

我们对我们的方法与基于特征的方法、传统的同质性 GNN 模型、最先进的图基异常检测模型以及用于异质性的新型 GNN 进行了全面比较。相应结果如图 2 所示。

- **基于特征与同质性 GNN 方法**: 与基于特征的方法 (SVM 和 MLP) 相比, 遵循同音假设 (GCN、GraphSAGE、GAT 和 GIN) 的 GNN 显示出相对较差的表现, 表明异质性问题阻碍了这些通用的 GNN。从根本上讲, 这些模型可以被视为低通滤波器, 仅关注低频信息。
- **GAD 算法**: 与最先进的基于图的异常检测方法相比, 这些方法在性能上仍与我们的提案存在显著差距。其中, GraphConsis 表现出了最差的整体性能。它结合节点特征和周围环境来学习注意力权重之间的关系, 本质上起到了低通滤波器的作用。CARE-GNN 和 PC-GNN 在性能上显示出一些改进, 因为它们能够识别异质边和“伪装”问题, 并设计了相应




图 2: 真实世界数据集上的异常检测性能, 以 F1 宏平均和 AUC 值表示。

的邻居选择模块。GAGA 引入了一个组聚合模块来生成可区分的多跳邻域信息。尽管整体表现有了显著提升, 但仍与我们的提案方法存在明显差距。

- **异质性 GNN**: 相比于基于特征相似性研究异质性的新型异质性 GNNs, ACM 研究, H²-FDetector 识别同质性和异质性连接并应用不同的聚合策略, BWGNN 设计带通滤波器在多个频率带上传递信息, 而 GDN 将节点特征分离为异常模式和邻域模式。CES2-GAD 的优越性能证明了所提出的基于因果关系和混合图谱滤波器模块的图边缘分离的有效性。

6 结论

本文探讨了在异质图中捕捉隐藏异常的方法。我们首先分析空间域中的异常异质性与频谱域中的高频信号之间的关系。观察到更高的异质性导致频谱能量从低频向高频转移后, 我们进一步提出使用因果干预来分离异质图并获得更为实质性的表示, 通过混合融合滤波器捕捉异质图中的异常。在真实世界异常检测数据集上的广泛实验展示了 CES2-GAD 的有效性。

ACKNOWLEDGMENTS

此项工作得到国家自然科学基金 (编号: 62272338) 和国家重点研发计划 (资助编号: 2022YFC2602305) 的支持。

REFERENCES

- [1] Ge Zhang, Zhao Li, Jiaming Huang, Jia Wu, Chuan Zhou, Jian Yang, and Jianliang Gao. 2022. e-fraudcom: An e-commerce fraud detection system via competitive graph neural networks. *ACM Transactions on Information Systems (TOIS)* 40, 3 (2022), 1–29.
- [2] Leyan Deng, Chenwang Wu, Defu Lian, Yongji Wu, and Enhong Chen. 2022. Markov-driven graph convolutional networks for social spammer detection. *IEEE Transactions on Knowledge and Data Engineering* (2022).
- [3] Hyunsoo Cho, Jinseok Seol, and Sang-goo Lee. 2021. Masked contrastive learning for anomaly detection. *arXiv preprint arXiv:2105.08793* (2021).
- [4] Yingdong Dou, Zhiwei Liu, Li Sun, Yutong Deng, Hao Peng, and Philip S Yu. 2020. Enhancing graph neural network-based fraud detectors against camouflaged fraudsters. In *Proceedings of the 29th ACM international conference on information & knowledge management*. 315–324.
- [5] Zhiwei Liu, Yingdong Dou, Philip S Yu, Yutong Deng, and Hao Peng. 2020. Alleviating the inconsistency problem of applying graph neural network to fraud detection. In *Proceedings of the 43rd international ACM SIGIR conference on research and development in information retrieval*. 1569–1572.
- [6] Zengyi Wo, Minglai Shao, Wenjun Wang, Xuan Guo, and Lu Lin. 2024. Graph Contrastive Learning via Interventional View Generation. In *Proceedings of the ACM on Web Conference 2024*. 1024–1034.
- [7] Limeng Cui, Haeseung Seo, Maryam Tabar, Fenglong Ma, Suhang Wang, and Dongwon Lee. 2020. Deterrent: Knowledge guided graph attention network for detecting healthcare misinformation. In *Proceedings of the*

- 26th ACM SIGKDD international conference on knowledge discovery & data mining. 492–502.
- [8] Jianheng Tang, Jiajin Li, Ziqi Gao, and Jia Li. 2022. Rethinking graph neural networks for anomaly detection. In *International Conference on Machine Learning*. PMLR, 21076–21089.
 - [9] Hongbin Pei, Bingzhe Wei, Kevin Chen-Chuan Chang, Yu Lei, and Bo Yang. 2020. Geom-gcn: Geometric graph convolutional networks. *arXiv preprint arXiv:2002.05287* (2020).
 - [10] Jiong Zhu, Yujun Yan, Lingxiao Zhao, Mark Heimann, Leman Akoglu, and Danai Koutra. 2020. Beyond homophily in graph neural networks: Current limitations and effective designs. *Advances in neural information processing systems* 33 (2020), 7793–7804.
 - [11] Sami Abu-El-Haija, Bryan Perozzi, Amol Kapoor, Nazanin Alipourfard, Kristina Lerman, Hrayr Harutyunyan, Greg Ver Steeg, and Aram Galstyan. 2019. Mixhop: Higher-order graph convolutional architectures via sparsified neighborhood mixing. In *international conference on machine learning*. PMLR, 21–29.
 - [12] Meng Liu, Zhengyang Wang, and Shuiwang Ji. 2021. Non-local graph neural networks. *IEEE transactions on pattern analysis and machine intelligence* 44, 12 (2021), 10270–10276.
 - [13] Wei Jin, Tyler Derr, Yiqi Wang, Yao Ma, Zitao Liu, and Jiliang Tang. 2021. Node similarity preserving graph convolutional networks. In *Proceedings of the 14th ACM international conference on web search and data mining*. 148–156.
 - [14] Sitao Luan, Chenqing Hua, Qincheng Lu, Jiaqi Zhu, Mingde Zhao, Shuyuan Zhang, Xiao-Wen Chang, and Doina Precup. 2021. Is heterophily a real nightmare for graph neural networks to do node classification? *arXiv preprint arXiv:2109.05641* (2021).
 - [15] Yang Liu, Xiang Ao, Zidi Qin, Jianfeng Chi, Jinghua Feng, Hao Yang, and Qing He. 2021. Pick and choose: a GNN-based imbalanced learning approach for fraud detection. In *Proceedings of the web conference 2021*. 3168–3177.
 - [16] Yuchen Wang, Jinghui Zhang, Zhengjie Huang, Weibin Li, Shikun Feng, Ziheng Ma, Yu Sun, Dianhai Yu, Fang Dong, Jiahui Jin, et al. 2023. Label information enhanced fraud detection against low homophily in graphs. In *Proceedings of the ACM Web Conference 2023*. 406–416.
 - [17] Can Liu, Li Sun, Xiang Ao, Jinghua Feng, Qing He, and Hao Yang. 2021. Intention-aware heterogeneous graph attention networks for fraud transactions detection. In *Proceedings of the 27th ACM SIGKDD conference on knowledge discovery & data mining*. 3280–3288.
 - [18] Thomas N Kipf and Max Welling. 2016. Semi-supervised classification with graph convolutional networks. *arXiv preprint arXiv:1609.02907* (2016).
 - [19] Julian John McAuley and Jure Leskovec. 2013. From amateurs to connoisseurs: modeling the evolution of user expertise through online reviews. In *Proceedings of the 22nd international conference on World Wide Web*. 897–908.
 - [20] Will Hamilton, Zitao Ying, and Jure Leskovec. 2017. Inductive representation learning on large graphs. *Advances in neural information processing systems* 30 (2017).
 - [21] Petar Velickovic, Guillem Cucurull, Arantxa Casanova, Adriana Romero, Pietro Lio, Yoshua Bengio, et al. 2017. Graph attention networks. *stat* 1050, 20 (2017), 10–48550.
 - [22] Keyulu Xu, Weihua Hu, Jure Leskovec, and Stefanie Jegelka. 2018. How powerful are graph neural networks? *arXiv preprint arXiv:1810.00826* (2018).
 - [23] Michaël Defferrard, Xavier Bresson, and Pierre Vandergheynst. 2016. Convolutional neural networks on graphs with fast localized spectral filtering. *Advances in neural information processing systems* 29 (2016).
 - [24] Sitao Luan, Chenqing Hua, Qincheng Lu, Jiaqi Zhu, Mingde Zhao, Shuyuan Zhang, Xiao-Wen Chang, and Doina Precup. 2022. Revisiting heterophily for graph neural networks. *Advances in neural information processing systems* 35 (2022), 1362–1375.
 - [25] Fengzhao Shi, Yanan Cao, Yanmin Shang, Yuchen Zhou, Chuan Zhou, and Jia Wu. 2022. H2-fdetector: A gnn-based fraud detector with homophilic and heterophilic connections. In *Proceedings of the ACM Web Conference 2022*. 1486–1494.
 - [26] Yuan Gao, Xiang Wang, Xiangnan He, Zhengguang Liu, Huamin Feng, and Yongdong Zhang. 2023. Alleviating structural distribution shift in graph anomaly detection. In *Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining*. 357–365.