

面向半监督节点分类的能量引导鲁棒图表示学习方法

张虎, 王泰文, 范越, 苏雅

山西大学计算机与信息技术学院, 山西 太原 030006

摘要

半监督节点分类是利用有限的已标记节点和大量的未标记节点预测未标记节点标签的任务。但在真实世界中, 图数据中往往存在图噪声和标签噪声, 现有方法大多只针对单一噪声设计, 难以有效应对两种噪声共存的情况, 降低了模型对噪声的鲁棒性。同时, 它们对全局与局部信息的聚合缺乏噪声鲁棒的协同机制, 导致局部特征语义失真与全局拓扑关系偏移。为了解决上述问题, 提出能量引导鲁棒图表示学习方法。首先对节点进行分组, 利用层次化多头自注意力机制聚合组内与组间信息, 有效捕获全局与局部特征。然后, 设计了能量引导对比学习策略, 通过能量函数有效区分节点间真实相似性关系, 并结合朗之万动力学动态优化节点间关系, 以增强节点表示的鲁棒性, 降低图噪声带来的影响。同时, 为了减轻标签噪声的影响, 引入伪标签机制筛选高质量标签, 进一步减少错误标签的干扰。在 Cora、Citeseer 和 Pubmed 这 3 个数据集上的实验结果表明, 该方法相比现有的基线模型取得了更好的性能。

关键词

图表示学习; 半监督节点分类; 对比学习; 能量模型

中图分类号: TP391

文献标志码: A

doi:10.11959/j.issn.2096-0271.2026022

Energy-guided robust graph representation learning for semi-supervised node classification

Zhang Hu, Wang Taiwen, Fan Yue, Su Ya

School of Computer and Information Technology, Shanxi University, Taiyuan 030006, China

Abstract

Semi-supervised node classification is a task that predicts the labels of unlabeled nodes using a limited number of labeled nodes and a large number of unlabeled nodes. However, in real-world scenarios, graph data often contains both graph noise and label noise. Existing methods are mostly designed only for a single type of noise, making it difficult to effectively handle the coexistence of both types of noise, which reduces the model's robustness. Meanwhile, they lack a noise-robust collaborative mechanism for aggregating global and local information, leading to semantic distortion of local features and deviation of global topological relationships. To solve the above problems, this paper proposed an energy-guided robust graph representation learning method. First, nodes were grouped, and a hierarchical multi-head self-attention mechanism was used to aggregate intra-group and inter-group information, effectively capturing global and local features. Then, an energy-guided contrastive learning method was designed, which effectively distinguished

the true similarity relationships between nodes through an energy function and dynamically optimized the relationships between nodes by combining Langevin dynamics, so as to enhance the robustness of node representations and reduce the impact of graph noise. Meanwhile, to mitigate the influence of label noise, a pseudo-labels mechanism was introduced to filter high-quality labels, further reducing the interference of incorrect labels. Experimental results on three datasets (Cora, Citeseer, and Pubmed) showed that this method achieved better performance compared with existing baseline models.

Key words

graph representation learning, semi-supervised node classification, contrastive learning, energy-based model

0 引言

节点分类是图数据中的一项重要任务，已被广泛应用于引文网络、交通网络、社交网络等^[1-2]实际场景，并在这些领域发挥着关键作用。但实际上，在多数真实场景中，为网络中所有节点逐一标记类别标签往往需要投入大量人力与时间成本，这一过程的高昂代价导致实际操作中通常仅能获取少量已标记节点。面对这一现实挑战，半监督节点分类凭借独特优势成为研究焦点。它无须依赖全量标记数据，而是以少量已标记节点为基础，结合未标记节点的结构关联与属性特征，完成对未标记节点的高效分类，大幅降低对标记资源的依赖。但是，目前许多半监督节点分类方法通过聚合邻居节点信息来学习节点表征，并且大多假设图结构和节点标签是干净的。然而在真实场景下，图数据中往往同时存在图噪声和标签噪声，导致这些方法容易受到噪声干扰，表现出较差的鲁棒性。

图噪声指的是图中缺边或加边，使模型错误地聚合节点信息，从而导致预测性能下降甚至失效。现有方法主要通过结构学习^[3]和权重学习^[4]来降低图噪声带来的影响。这些方法本质上都是对局部图结构添加约束以识别噪声边，并在后续训练过程

中将其去除。但它们很少关注全局图结构信息并且难以识别和挖掘图中潜在的深层次信息，导致模型可能错失一些潜在的有用信息。标签噪声指的是节点标签被错误地分配至其他类别，这会严重影响学习过程。现有方法通过设计鲁棒的损失函数^[5-6]或标签修正策略^[7-8]来应对标签噪声，但标签噪声仍可能通过反向传播影响其他节点的表示学习。这些方法只对单一图噪声或标签噪声有较好的鲁棒性，但当两种噪声同时存在时，模型鲁棒性迅速下降，无法有效解决图噪声和标签噪声共存的问题。最近，Zhu 等^[9]提出的 RNCGLN 方法虽然可以解决两种噪声带来的问题，但其采用的普通对比学习机制难以在两种噪声共同干扰下有效捕获关键信息，降低了模型的鲁棒性与泛化能力。

为了有效应对噪声干扰，现有研究探索了基于能量的模型（energy-based model, EBM，简称能量模型）^[10]在噪声环境中的可行性。EBM 通过学习一个能量函数来定义底层数据分布的未归一化概率密度，从而解决这些问题。给定图数据，EBM 可以直接计算其未归一化的可能性，接着使用马尔可夫链蒙特卡洛（Markov chain Monte Carlo, MCMC）^[11]方法对 EBM 中难以精确计算的归一化常数进行近似估计，获得接近数据真实分布的样本。通过对图数据的整体分布进行建模，并利用能量函数及

其梯度信息捕捉高阶依赖和潜在模式，同时引导系统向低能量状态移动，有效抑制噪声干扰，提升模型鲁棒性与泛化能力。

在此基础上，本文进一步提出了能量引导鲁棒图表示学习（energy-guided robust graph representation learning, EGRGRL）方法，以解决图噪声和标签噪声共存的问题。具体来说，首先对节点进行分组，接着利用层次化多头自注意力机制^[12]逐层聚合组内与组间信息，不仅能充分学习节点自身局部邻域的细粒度特征，还能有效捕获图结构的全局特征，该过程通过计算任意节点间的相似性，有效抑制图噪声的干扰，自适应地捕捉节点间的重要性差异。然后，在此基础上引入能量引导对比学习，通过能量函数量化节点表征的相似性差异，并结合朗之万动力学（Langevin dynamics, LD）优化节点间关系，以优化后的节点间相似性和多跳邻居关系为依据构造正负样本对进行对比学习。该机制促使节点相似性分布逐步收敛至能量函数隐式定义的目标分布，进而而在对比学习阶段高效聚合特征相似节点，使模型学到更鲁棒的节点表示，以此驱动图结构更新并减少图噪声带来的影响。最后，模型根据当前学到的节点表示来预测未标记节点的标签，通过过滤低置信度的标签信息，减少标签噪声带来的影响。

本文的主要贡献如下。

（1）与传统使用图神经网络（graph neural network, GNN）进行节点分类任务的方法不同，EGRGRL方法采用层次化多头自注意力机制，同时捕获全局和局部信息，获得更精准的节点表征。

（2）提出了一种能量引导对比学习方法，通过能量函数度量正负样本之间的差异，并利用LD优化节点间关系，使模型学到更具判别性和鲁棒性的节点表征，进

一步有效地更新图结构。

（3）在Cora、Citeseer和Pubmed这3个数据集上的结果证明了所提方法的有效性。

1 相关工作

1.1 带噪声的半监督节点分类

带噪声的半监督节点分类利用图结构信息与少量标签信息，在噪声环境下可以有效提升节点分类性能。Chen等^[13]通过调整图的拓扑结构和节点的嵌入表示，有效地减少了图噪声对分类任务的影响。通过这种迭代优化过程，模型能够动态地识别和修复图中的噪声部分，从而增强了节点表示的质量和鲁棒性。Tang等^[14]在图卷积网络（graph convolutional network, GCN）中动态学习不同层中节点特征结构的图并使用马氏距离度量学习来优化底层图核，提升了模型在图噪声环境下的鲁棒性。Dai等^[15]在标签噪声情况下，通过边预测和伪标签生成减少噪声影响，增强图结构的准确性，并补充更多监督信息，从而提升了节点分类性能。Ding等^[16]将GNN解耦为特征转换与传播，并结合邻居信息，有效减少了标签噪声对模型的负面影响，从而提升了节点分类的鲁棒性和准确性。

最近，Zhu等^[9]结合图对比损失和多头自注意力机制同时处理图噪声和标签噪声，增强节点表示的判别能力，提高在噪声环境下的分类性能。因此，探索基于注意力机制与对比学习的噪声鲁棒学习方法有助于减轻噪声影响，能够提升模型的鲁棒性和分类性能。

1.2 能量模型

EBM^[10]是一种生成模型，旨在建模未

经规范化的数据。它通过概率密度函数来描述数据的底层分布,捕捉数据的潜在结构和分布特征。Lee等^[17]通过将对学习得到的潜在变量作为真实潜在变量指导能量模型理解数据结构,并设计新型潜在变量模型学习数据与对比潜在变量的联合密度,从而提升EBM训练效率、生成质量及条件生成能力。Liu等^[18]使用能量模型生成分子图并应用朗之万动力学,通过近似最大化似然来训练能量函数,生成低能样本。Zeng等^[19]在图结构精化任务中将能量模型与对比学习相结合,成功地提高了模型在图噪声影响下的鲁棒性。受此启发,为抑制噪声对对比监督的错误引导并减少错误对比对的引入,从而提升节点表示的鲁棒性并稳定带噪声图结构的优化过程,设计能量引导对比学习方法来解决带噪声的半监督节点分类问题。

2 能量引导的鲁棒图表示学习模型

2.1 任务描述与模型架构

给定一个图 $G=(V,E)$,其中 V 是 n 个节点的集合, E 是边集合。一个图被描述为一个邻接矩阵 $A \in [0,1]^{n \times n}$,其中 $a_{ij}=1$ 表示两个节点 i 和 j 之间有连接边。节点标签集合 Y 分为干净标签集合 Y_{clear} 和无标签集合 Y_{unlabel} ,节点特征矩阵为 D 。首先,在图中加入图噪声以生成扰动后的邻接矩阵 A^* ,接着,向 Y_{clear} 中加入标签噪声,生成噪声标签集合 Y'_{noise} ,而 $Y_{\text{clear}} = Y'_{\text{clear}} + Y'_{\text{noise}}$,其中 Y'_{clear} 是一小部分节点的干净标签集合。带噪声的节点分类任务的目标是使用扰动信息和大量未标记节点信息来训练模型 $G(x)$,使其最小化 $\mathcal{L}(G(D,A^*),Y_{\text{clear}})$,以准确预测 Y_{unlabel} 。

EGRGRL模型架构如图1所示。模型由3部分组成,分别是层次化多头自注意力模块、能量引导对比学习模块、标签更新模块。具体流程如下:①将输入节点表示输入多层感知器(MLP),输出节点表示被送到层次化多头自注意力模块中,以捕获全局与局部信息;②通过能量引导对比学习为图的动态更新提供指导信息,以过滤图噪声;③更新标签信息以过滤标签噪声。




图1 EGRGRL模型架构

2.2 EGRGRL 方法

2.2.1 层次化多头自注意力模块

为有效聚合全局与局部信息，设计了层次化多头自注意力模块，包括局部和全局信息聚合机制。

(1) 局部信息聚合机制

首先使用 MLP 来学习 D 的新表示，如式 (1) 所示。

$$U = \text{Dropout}(\text{MLP}(D)) \quad (1)$$

然后通过 3 个可学习的权重矩阵 W_K 、 W_Q 、 W_V 进行线性变换获得式 (2) 中的对应的键 (key)、查询 (query) 和值 (value)。

$$K = \phi(UW_K), Q = \phi(UW_Q), V = UW_V \quad (2)$$

其中， ϕ 是 ReLU 激活函数。接着，将全体节点按照节点数均匀划分为若干个子组，每个子组的大小为 $B = \frac{N}{M}$ 。 N 为节点数， M 为预先设定的分组数量，每个子组对应一个局部图。

对于每个分组 g ，通过式 (3) 获取对应的键、查询和值。

$$K_g = K[\text{start}_g:\text{end}_g], Q_g = Q[\text{start}_g:\text{end}_g], V_g = V[\text{start}_g:\text{end}_g] \quad (3)$$

其中， $\text{start}_g = g \left\lfloor \frac{N}{M} \right\rfloor$ ， $\text{end}_g = (g+1) \left\lfloor \frac{N}{M} \right\rfloor$ (对于最后一组， $\text{end}_g = N$)。

对于每个注意力头 $i \in \{1, 2, 3, \dots, R\}$ ， R 为注意力头数，首先计算该头对应的局部注意力权重，利用查询向量和键向量计算相似度，并通过 softmax 函数进行归一化，得到式 (4) 中的局部注意力权重矩阵 W_g^i 。

$$W_g^i = \text{softmax}(Q_g^i (K_g^i)^T) \quad (4)$$

其中， Q_g^i 和 K_g^i 分别为第 i 个头的查询向量

和键向量。使用 W_g^i 对对应的值向量 V_g^i 进行加权求和，从而得到式 (5) 中每个头的输出。

$$Z_g^i = W_g^i V_g^i \quad (5)$$

然后，将所有头的输出拼接在一起，得到式 (6) 中每个组的局部聚合结果 Z_g 。

$$Z_g = \text{concat}(Z_g^1, Z_g^2, Z_g^3, \dots, Z_g^R) \quad (6)$$

最后，得到式 (7) 中所有组的结果。

$$Z = \text{concat}(Z_0, Z_1, Z_2, \dots, Z_{M-1}) \quad (7)$$

(2) 全局信息聚合机制

在得到局部聚合后的特征矩阵 Z 的基础上，进行全局注意力计算。首先，通过线性变换得到式 (8) 中的全局键、查询和值张量。

$$K_{\text{global}} = \phi(ZW_K), Q_{\text{global}} = \phi(ZW_Q), V_{\text{global}} = ZW_V \quad (8)$$

接着，通过式 (9) 计算全局注意力矩阵 W_{global} 。

$$W_{\text{global}} = \text{softmax}(Q_{\text{global}} (K_{\text{global}})^T) \quad (9)$$

最终，基于全局权重矩阵对全局值向量进行加权求和，得到最终的输出。

$$Y = W_{\text{global}} V_{\text{global}} \quad (10)$$

虽然层次化多头自注意力模块通过计算节点间的相似性在一定程度上抵抗了图噪声，但原始图中包含的图噪声仍会影响未知节点的预测，因此需要过滤图噪声。

2.2.2 能量引导对比学习模块

为减少错误对比对的引入并增强节点间关系的区分性，同时充分挖掘图中的潜在信息。引入能量函数并获取其对应的隐

式分布,接着使用LD方法进行采样优化,使相似度矩阵中的数据所反映的相似性分布逐渐趋于预先设定的隐式目标分布。

具体来说,首先根据 D 的新表示 U ,通过式(11)获取对应的相似度矩阵 S 。

$$S = \begin{cases} \frac{u(i) \times u(j)}{\sqrt{\sum_{k=1}^{n_{\text{hid}}} u_{ik}^2} \times \sqrt{\sum_{k=1}^{n_{\text{hid}}} u_{jk}^2}}, & i \neq j \\ 0, & i = j \end{cases} \quad (11)$$

其中, U 为节点表示, $u(i)$ 为第 i 个节点表示, n_{hid} 是每个节点的特征维度。接着定义式(12)所示的多跳图 K_{ij} 。

$$K_{ij} = \begin{cases} a_{ij} & \text{如果 } i \text{ 和 } j \text{ 是多跳邻居} \\ 0 & \text{如果 } i \text{ 和 } j \text{ 不是多跳邻居} \end{cases} \quad (12)$$

其中, a_{ij} 是归一化关联权值,对应的归一化邻接矩阵为 A_r^* 。随后利用多跳图 K_{ij} 与相似度矩阵 S 进行对比学习。在此之前,显式定义能量函数如式(13)所示。

$$E(S) = (1 - A_r^*) \times S^2 + A_r^* \times (1 - S)^2 \quad (13)$$

其中,低能量值对应高概率样本,高能量值对应低概率样本。

在这个过程中,隐式定义了一个概率分布^[10]。

$$p(s) \propto e^{-E(S)} \quad (14)$$

其中, s 指的是单个节点对的相似度取值。将上述得到的隐式概率分布记为 X 。虽然当前的多跳图结构带有噪声,但所得到的分布依旧优于原始仅通过余弦相似度计算所得到的分布,这为图的动态更新提供更精确的指导,使图结构更加接近真实的图结构。最后,为避免硬约束在噪声干扰下导致的分布截断,采用软边界方法,通过在能量函数中添加噪声鲁棒性边界惩罚项,约束相似度分布的同时抑制噪声引起的过度置信或异常波动。

$$E_{\text{boundary}}(S) = -\beta \sum_{i,j} [\log(S) + \log(1-S)] \quad (15)$$

其中, β 控制边界惩罚强度。然后使用能量函数来引导相似度矩阵的调整,得到能量矩阵 Q 和当前的相似度矩阵中数据对应的分布 X' 。

接着使用LD对定义在相似度矩阵空间上的能量函数进行优化,帮助跳出噪声造成的局部极小值以使相似度矩阵中的数据所反映的相似性分布逐渐趋于预先设定的隐式目标概率分布,即 $X' \rightarrow X$ 。

具体来说,LD源于统计物理学中的朗之万方程,通过在确定性梯度更新中注入尺度匹配的高斯噪声以实现目标分布的高效采样优化^[11]。

$$x_{k+1} = x_k - \frac{\lambda}{2} \nabla_x E_\theta(x_k) + \omega_k \quad (16)$$

其中, x_k 为第 k 步的相似度矩阵, $\nabla_x E_\theta(x_k)$ 为能量函数 $E_\theta(x_k)$ 对 x 的梯度, λ 为步长参数, ω_k 为注入的高斯噪声。

在本方法中,采用多项式退火策略。

$$\lambda_k = a(b+k)^{-\gamma} \quad (17)$$

其中, $\gamma \in (0.5, 1]$ 。此策略确保系统从初始探索阶段逐步过渡到精确后验采样阶段。

接着,设计噪声项 $\omega_k \sim N(0, \sqrt{\epsilon_k})$ 。其中, ϵ_k 为第 k 步的步长。这保证注入的噪声项与步长所匹配,确保算法不会失效。

最后,进行对比学习(InfoNCE)^[20]使模型学到更具判别性和鲁棒性的节点表示来抵抗噪声干扰。

$$\mathcal{L}_{\text{gcl}} = -\frac{1}{N} \sum_{i=1}^N \log \left(\frac{\sum_{j=1, j \neq i}^N \exp(\frac{S_{ij}^*}{\tau}) \times K_{ij} + \epsilon}{\sum_{j=1, j \neq i}^N \exp(\frac{S_{ij}^*}{\tau}) + \epsilon} \right) \quad (18)$$

其中, $\mathcal{L}_{\text{gcl}}$ 指的是能量引导的对比学习损失, S^* 是优化后的相似度矩阵, τ 是温度超

参数，控制相似度的分布平滑程度， $\varepsilon=1 \times 10^{-8}$ 是防止数值不稳定的平滑项。

经过一定轮次的训练后，模型学到的节点表示优于先前的表示，此时更新多跳图 $\mathbf{K}_{ij}$ 以自适应地过滤并移除图中的部分噪声连接，更新方式见式 (19)。

$$g_{ij} = \begin{cases} 1 & , \text{sim}(\mathbf{U}_i, \mathbf{U}_j) \geq \sigma \\ \text{sim}(\mathbf{U}_i, \mathbf{U}_j) & , \gamma \leq \text{sim}(\mathbf{U}_i, \mathbf{U}_j) < \sigma \\ 0 & , \text{其他} \end{cases} \quad (19)$$

其中， σ 与 γ 是两个超参数， $\mathbf{U}_i$ 与 $\mathbf{U}_j$ 是当前模型学习到的节点表示。相似度高于 σ 的节点对被视为高可信度的连接；相似度介于 γ 与 σ 之间的节点对，则保留其相似度作为边权重；而低于 γ 的连接则视为噪声边丢弃。

2.2.3 标签更新模块

为了利用许多无标签节点的信息，伪标签通常被引入作为补充监督信号，以扩展训练样本集^[21-22]。根据先前相关研究成果^[23-24]，通过设定较高的置信度阈值进行筛选，能提高伪标签质量，增强模型在半监督节点分类任务中的泛化能力与对噪声的鲁棒性。

在经过层次化多头自注意力模块与能量引导对比学习模块的处理后，需要对当前节点进行筛选，从而过滤标签噪声。

$$y_{ij} = \begin{cases} 1 & , U_{ij}^* \geq \mu \\ U_{ij}^* & , \alpha \leq U_{ij}^* \leq \mu \\ 0 & , \text{其他} \end{cases} \quad (20)$$

其中， $\mathbf{U}_{ij}^*$ 是概率预测矩阵中的预测概率值， μ 、 α 是可调节超参数。当节点预测的置信度超过预先设定的阈值时，将这些节点视为高可信度的伪标签候选，并在接下来的训练迭代中作为真实标签使用。

2.3 损失函数

EGRGRL 方法采用自训练的迭代优化策略。首先，在预热阶段进行初步训练，然后进入迭代过程。在每次迭代中，系统通过标签更新模块生成高置信度的伪标签，并通过能量引导对比学习模块来优化图结构。生成的伪标签和更新后的图结构将在下一轮迭代中替换原有版本并用于后续的训练，在这一训练过程中使用交叉熵损失函数来指导节点分类任务的优化，其中 C 表示标签的数量， Y_{ij} 为初始标签信息或进行标签更新后的伪标签。同时，为使模型学习到更鲁棒的节点表示，以更有效地更新图结构并抵抗噪声干扰，引入了能量引导的图对比学习，以优化后的图结构构建对比学习损失。

$$\mathcal{L}_{cc} = - \sum_{i \in Y_L} \sum_{j=1}^C y_{ij} \log U_{ij}^* \quad (21)$$

$$\mathcal{L} = \mathcal{L}_{cc} + \varphi \mathcal{L}_{gel} \quad (22)$$

其中， L 为带标签节点集合， $\mathcal{L}_{cc}$ 是交叉熵损失， $\mathcal{L}_{gel}$ (式 (18)) 是能量引导对比学习损失， $\mathcal{L}$ 是总损失， φ 是用于调节 $\mathcal{L}_{gel}$ 对总损失 $\mathcal{L}$ 的贡献大小的超参数。

3 实验

3.1 数据集和对比方法

为了评估所提出的方法，本文在 3 个常用的节点分类数据集上进行了实验。数据集具体介绍见表 1。

对比基线方法包括经典的 GCN 方法 (GCN^[25]、GAT^[26])、图噪声鲁棒方法 (JLGCN^[14]、IDGL^[13])、标签噪声鲁棒方法 (NRGNN^[15]、LAFAK^[27])，以及同时

表1 数据集介绍

数据集	节点数	边数	类别	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

兼顾图噪声和标签噪声鲁棒性的方法 (RNCGLN^[9])。

3.2 实验设置

实验所使用的训练平台操作系统版本是 Ubuntu 20.04；GPU 型号及显存是 NVIDIA A800 80GB；PyTorch 版本是

1.12.1。我们借鉴 Sohn 等^[23]的工作，将标签更新模块中的超参数 μ 和 α 分别设定为 0.95 与 0.9，同时我们也试验了其他取值，发现当 μ 和 α 分别设定为 0.95 与 0.9 时，效果最好；实验使用 Adam 优化器，权重衰减系数为 5×10^{-4} ，Dropout 率为 0.4。

3.3 分类结果讨论

所提方法及对比基线方法在图噪声 (graph noise, gr) 和标签噪声 (label noise, lr) 不同比例下的节点分类结果见表 2，其中加粗的是此次实验中最优的模型实验结果。实验设置遵循 Zhu 等^[9]的实验设置，将 gr 和 lr 比例设置为 {0, 0}、{0.1, 0.3}、{0.3, 0.1}。

表2 gr和lr不同比例下的节点分类准确率ACC

数据集	{gr,lr}	GCN	GAT	JLGCN	IDGL	NRGNN	LAFAK	RNCGLN	所提方法 (EGRGRL)
Cora	{0,0}	82.72%	83.20%	83.83%	83.85%	82.30%	81.58%	84.46%	84.53%
		± 0.78%	± 0.31%	± 0.16%	± 0.25%	± 0.22%	± 0.92%	± 0.35%	± 1.24%
	{0.1,0.3}	70.58%	74.48%	69.01%	76.83%	70.90%	79.34%	81.73%	82.15%
		± 1.21%	± 1.00%	± 0.30%	± 2.57%	± 3.88%	± 0.54%	± 0.33%	± 0.60%
Citeseer	{0.3,0.1}	72.94%	73.70%	72.40%	80.53%	72.43%	74.34%	80.60%	80.63%
		± 1.58%	± 1.29%	± 1.70%	± 1.70%	± 1.98%	± 1.34%	± 1.06%	± 2.20%
	{0,0}	71.18%	71.76%	73.60%	72.10%	70.78%	71.08%	73.96%	73.70%
		± 1.06%	± 0.58%	± 0.28%	± 0.20%	± 0.39%	± 0.34%	± 0.30%	± 0.52%
Pubmed	{0.1,0.3}	61.70%	64.28%	64.65%	68.03%	66.88%	69.14%	71.83%	72.00%
		± 0.89%	± 0.76%	± 3.79%	± 3.65%	± 2.31%	± 1.28%	± 0.33%	± 1.34%
	{0.3,0.1}	65.30%	67.74%	63.21%	69.71%	64.46%	66.42%	70.20%	71.65%
		± 1.21%	± 1.24%	± 1.54%	± 1.30%	± 3.23%	± 1.04%	± 1.41%	± 0.97%
Citeseer	{0,0}	79.04%	79.16%	79.50%	80.80%	79.58%	78.28%	81.16%	80.85%
		± 0.30%	± 0.28%	± 0.29%	± 0.39%	± 0.41%	± 0.46%	± 0.64%	± 0.95%
	{0.1,0.3}	68.60%	67.88%	67.81%	77.12%	75.67%	76.74%	77.60%	77.95%
		± 1.63%	± 1.72%	± 2.81%	± 1.61%	± 2.05%	± 0.39%	± 1.20%	± 1.56%
Pubmed	{0.3,0.1}	70.76%	71.74%	75.61%	74.61%	71.05%	73.61%	79.23%	79.45%
		± 1.91%	± 1.54%	± 1.54%	± 1.66%	± 2.84%	± 1.63%	± 1.03%	± 1.95%

EGRGRL通过分组聚合全局与局部信息，接着通过LD进行优化。组内与组间复杂度分别为 $O(\frac{N^2d}{G})$ 、 $O(G^2d)$ ，总时间复杂度为 $O(Td(\frac{N^2}{G} + G^2))$ 。其中 T 为LD迭代次数， G 为分组数目， N 为节点总数， d 为节点特征维度。

首先，EGRGRL在有噪声环境下实现了最佳性能；在无噪声环境下，在Cora数据集上实现了最佳性能，在其他两个数据集上接近最佳水平（RNCGLN）。具体来说，在有噪声情况下，EGRGRL比性能突出的方法（LAFAK）平均提高了4.04%；相比传统的GCN、GAT平均提高了8.99%、7.34%。这是因为这些方法只考虑一种噪声（图噪声或标签噪声）或不考虑噪声，而EGRGRL同时考虑两种噪声。

其次，EGRGRL可以更好地处理单一类型噪声。相较于最佳标签噪声鲁棒方法（LAFAK）在 $\{gr, lr\}$ 为 $\{0.1, 0.3\}$ 时候，平均提高了2.29%；与最佳图噪声鲁棒方法（IDGL）在 $\{gr, lr\}$ 为 $\{0.3, 0.1\}$ 的情况相比，平均提高了2.29%。这证明了在进行鲁棒节点分类时需要同时考虑两种噪声的必要性，当存在严重的图噪声时，EGRGRL更多考虑标签信息；当存在严重的标签噪声时，EGRGRL更多考虑图结构

信息。

最后，相较于RNCGLN，EGRGRL也有一定的提升，特别是在Citeseer上的 $\{gr, lr\}$ 为 $\{0.3, 0.1\}$ 的情况下提高了1.45%。这是因为经过能量引导对比学习与LD优化后，排除了部分错误对比对，模型学习到更准确的节点表示，为图的动态更新提供更有效的指导。

3.4 消融实验

为了验证所提方法的有效性，在3个数据集上进行了消融实验，实验结果见表3，其中加粗的是此次实验中最优的模型实验结果。表中HA是层次化多头自注意力模块，ECL是能量引导对比学习模块，PL是标签更新模块，√表示包含对应模块。

表3的消融实验结果表明，去掉HA后，结果平均下降1.45%，说明此模块成功捕获到了全局与局部信息；去掉ECL后，结果平均下降了2.79%，说明通过能量引导对比学习排除了错误对比对并增强了节点表示的区分性；去掉PL后，结果平均下降2.98%，说明标签更新模块引入了更多的监督信息，能帮助模型更好地捕捉类别特征、提升分类效果；去掉HA、

表3 消融实验结果

模块			Cora		Citeseer		Pubmed	
			{gr,lr}		{gr,lr}		{gr,lr}	
HA	ECL	PL	{0.1,0.3}	{0.3,0.1}	{0.1,0.3}	{0.3,0.1}	{0.1,0.3}	{0.3,0.1}
			76.23%±0.41%	77.04%±1.29%	66.10%±0.89%	69.23%±1.67%	71.68%±1.54%	75.23%±1.45%
✓	✓		79.69%±1.21%	77.57%±0.69%	66.78%±0.43%	70.23%±0.79%	73.53%±0.79%	78.15%±1.75%
✓		✓	80.03%±1.76%	78.13%±1.07%	66.33%±2.72%	69.95%±2.39%	74.17%±2.25%	78.49%±1.05%
	✓	✓	81.25%±0.51%	79.23%±1.62%	69.83%±3.90%	70.55%±1.14%	75.35%±2.27%	78.90%±1.67%
✓	✓	✓	82.15%±0.60%	80.63%±2.20%	72.00%±1.34%	71.65%±0.97%	77.95%±1.56%	79.45%±1.95%

ECL和PL后,结果平均下降4.72%,说明在不同噪声水平下,3个模块的协同作用依然确保了模型的稳定性,表明了所提方法在提升分类准确性和抗噪能力方面的关键作用。

3.5 噪声鲁棒性分析

为评估所提方法在两种噪声共同作用下的鲁棒性,实验通过设计噪声组合,分别将图噪声与标签噪声比率中的一种固定为30%,另一种噪声比率从0%开始以5%为增幅逐步增至30%,以此分析所提方法在不同噪声比率组合下的鲁棒性,实验结果如图2所示。其中,图2(a)、图2(b)、图2(c)表示图噪声比率固定为30%,分类准确率(ACC)随标签噪声比率变化的趋势;图2(d)、图2(e)、图2(f)表示标签噪声比率固定为30%,分类准确率随图噪声比率变化的趋势。其中,Atten+ECL表示基于层次化多头自注意力

机制与能量引导对比学习的方法;Atten+CL表示基于层次化多头自注意力机制与普通对比学习的方法;Atten表示层次化多头自注意力机制方法。

如图2所示,在Cora和Citeseer数据集上,Atten+ECL表现最佳,Atten效果最差。这归因于通过能量引导对比学习,Atten+ECL学到了更鲁棒的节点表示,能有效捕获更准确的图结构信息来缓解噪声影响,从而提升模型性能;Atten+CL无特殊去噪机制,难以抵御噪声干扰,学到的节点表示鲁棒性不足,进而降低性能。同时,实验结果表明仅依赖层次化多头自注意力机制的Atten在面对标签噪声比率增加时性能持续下降,而在面对图噪声比率增加时性能却保持稳定。这是因为注意力机制仅通过计算节点间的相似性来预测节点标签,并不依赖图结构中边的具体存在,因此无法抵抗标签噪声。

在Pubmed数据集上的实验结果表明Atten+ECL在某些噪声比率下效果不如




图2 所提方法在不同比率的图噪声和标签噪声共同作用下的分类准确率变化

Atten+CL。这是因为在低噪声条件下，图数据中噪声较少，Atten+CL方法借助普通对比学习高效利用数据，而Atten+ECL的能量函数和LD引入的额外复杂性显得多余，限制其性能，导致表现不佳。然而，由于Atten+CL方法完全依赖图结构进行建模，当图结构中的噪声过多时，其性能会明显下降；而Atten+ECL通过能量函数挖掘潜在的图结构信息，使模型逐步去噪并学习到更鲁棒的表示，最终使学到的图结构更接近真实结构，从而在效果上超过Atten+CL。

3.6 LD 迭代次数超参数分析

为探究LD迭代次数 K 对模型准确率的影响，实验设定0~10次的迭代次数，分析

了LD在不同迭代次数下对模型预测精度的具体影响，实验结果如图3所示。在Cora和Citeseer数据集上，迭代2~5次即可达到最优。当达到最优迭代次数时，LD通过梯度和噪声的平衡，使相似度矩阵中的元素在能量表面上接近了目标分布 $p(s) \propto e^{-E(s)}$ 的低能量区域，此时优化后的相似度矩阵较好地反映了数据间的真实相似性关系。然而，随着迭代次数的增加，噪声的累积效应主导了相似度矩阵元素的变化，使其在能量景观中持续受到扰动，逐渐偏离已经收敛到的高性能区域，导致模型准确率下降并出现震荡。这表明存在一个关键的“早停”点，超过该点后，数据间的相似性关系会过度拟合由算法自身引入的噪声，从而损害模型对数据的泛化能力。




图3 模型预测精度随LD迭代次数变化

3.7 可视化实验

为了进一步验证模型在不同噪声配置下的学习效果，通过 t-SNE 方法对模型输出的节点表征进行了可视化分析。如图 4 所示，在 Cora 和 Citeseer 两个数据集的不同噪声比率条件下，模型均成功捕捉到了数据的内在结构。其中，在图噪声比率较低（0.1）、标签噪声比率较高（0.3）时，不同类别的节点表示在低维空间中形成的类簇相对清晰；而在标签噪声比率较低（0.1）、图噪声比率较高（0.3）的情形下，模型表现出了更明显的聚类效果，节点之

间的簇边界更加清晰。这表明，模型通过能量函数与 LD 采样有效地学习到了节点的高质量表示，并能灵活应对不同类型的噪声干扰，提升节点分类任务的鲁棒性与泛化能力。

4 结束语

本文提出了 EGRGRL 方法，旨在解决图噪声和标签噪声共存的问题。EGRGRL 首先使用层次化多头自注意力机制捕获全局与局部信息，随后结合能量函数与朗之




图4 可视化图

万动力学来引导图结构的更新以降低图噪声影响，最后使用伪标签技术来降低标签噪声的影响。在3个数据集上进行的实验表明，EGRGRL能更好地处理图噪声和标签噪声共存的情况。目前的研究和实验主要集中在带噪声的同构图上，下一步将探索在异构图上以能量的视角来提升噪声环境下的图表示性能。

参考文献：

[1] 张旭龙, 瞿晓阳, 肖春光等. 深度图表示学习: 方法、应用与挑战[J]. 大数据, 2025, 11(06): 143-165.

Zhang X L, Qu X Y, Xiao C G, et al. Deep graph representation learning: methods, applications, and challenges[J]. Big Data Research, 2025, 11(06): 143-165.

[2] 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, 2020, 32(1):4-24.

[3] Dai E, Jin W, Liu H, et al. Towards robust graph neural networks for noisy graphs with sparse labels[C]//Proceedings of the 15th ACM International Conference on Web Search and Data Mining. New York: ACM, 2022: 181-191.

[4] Ye Y, Ji S H. Sparse graph attention networks[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(1): 905-916.

[5] Ghosh A, Kumar H, Sastry P S. Robust loss functions under label noise for deep neural networks[C]//Proceedings of the 31st AAAI Conference on Artificial Intelligence. Palo Alto, CA: AAAI Press, 2017: 1919-1925.

[6] Wei H X, Zhuang H P, Xie R C, et al. Mitigating memorization of noisy labels by clipping the model prediction[C]//Proceedings of the 40th International Conference on Machine Learning. New York: ACM, 2023: 36868-36886.

[7] Zheng S Z, Wu P X, Goswami A, et al. Error-bounded correction of noisy labels [C]//Proceedings of the 37rd International Conference on Machine Learning, New York: ACM, 2020: 11447-11457.

[8] Zheng G Q, Awadallah A H, Dumais S. Meta label correction for noisy label learning[C]//Proceedings of the 35th AAAI Conference on Artificial Intelligence, New York: AAAI, 2021: 11053-11061.

[9] Zhu Y, Feng L, Deng Z, et al. Robust node classification on graph data with graph and label noise[C]//Proceedings of the 38th AAAI Conference on Artificial Intelligence, New York: AAAI, 2024: 17220-17227.

[10] Grathwohl W, Wang K C, Jacobsen J H, et al. Your classifier is secretly an energy based model and you should treat it like one[EB]. arXiv preprint, 2019, arXiv: 1912.03263.

[11] Welling M, Teh Y W. Bayesian learning via stochastic gradient Langevin dynamics[C]//Proceedings of the 28th international conference on machine learning, New York: ACM, 2011: 681-688.

[12] Liu Y, Wu Y H, Sun G, et al. Vision transformers with hierarchical attention[J]. Machine Intelligence Research, 2024, 21 (4): 670-683.

[13] Chen Y, Wu L, Zaki M. Iterative deep graph learning for graph neural networks: better and robust node embeddings[C]//Proceedings of the 35th An-

- nual Conference on Neural Information Processing Systems, New York: MIT Press, 2021: 19314–19326.
- [14] Tang J X, Hu W, Gao Z M, et al. Joint learning of graph representation and node features in graph convolutional neural networks[EB]. arXiv preprint, 2019, arXiv: 1909.04931.
- [15] Dai E, Aggarwal C, Wang S H. Nrgnn: Learning a label noise resistant graph neural network on sparsely and noisily labeled graphs[C]//Proceedings of the 27th ACM SIGKDD conference on knowledge discovery and data mining, New York: ACM, 2021: 227–236.
- [16] Ding K Z, Ma X X, Liu Y X, et al. Divide and denoise: empowering simple models for robust graph semi-supervised learning against label noise [C]//Proceedings of the 30th ACM SIGKDD conference on knowledge discovery and data mining, New York: ACM, 2024: 574–584.
- [17] Lee H, Jeong J H, Park S J, et al. Guiding energy-based models via contrastive latent variables[EB]. arXiv preprint, 2023, arXiv: 2303.03023.
- [18] Liu M, Yan K, Oztekin B, et al. Graphebm: molecular graph generation with energy-based models[EB]. arXiv preprint, 2021, arXiv: 2102.00546.
- [19] Zeng X L, Wang Y F, Sun Y Q, et al. Graph structure refinement with energy-based contrastive learning[C]//Proceedings of the 39th AAAI Conference on Artificial Intelligence, New York: AAAI, 2025: 22326–22335.
- [20] Oord A V D, Li Y, Vinyals O. Representation learning with contrastive predictive coding[EB]. arXiv preprint, 2018, arXiv: 1807.03748.
- [21] Lee D H. Pseudo-label: The simple and efficient semi-supervised learning method for deep neural networks[C]//Proceedings of the 30th International Conference on Machine Learning, New York: ACM, 2013: 896–902.
- [22] Arazo E, Ortego D, Albert P, et al. Pseudo-labeling and confirmation bias in deep semi-supervised learning[C]//Proceedings of the 2020 International Joint Conference on Neural Networks, Piscataway: IEEE Press, 2020: 1–8.
- [23] Sohn K, Berthelot D, Carlini N, et al. Fixmatch: simplifying semi-supervised learning with consistency and confidence [C]//Proceedings of the 34th Conference on Neural Information Processing Systems, New York: MIT Press, 2020: 596–608.
- [24] Xie Q, Luong M T, Hovy E, et al. Self-training with noisy student improves imagenet classification[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, Piscataway: IEEE Press, 2020: 10687–10698.
- [25] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks[EB]. arXiv preprint, 2016, arXiv: 1609.02907.
- [26] VelićKović P, Cucurull G, Casanova A, et al. Graph attention networks[EB]. arXiv preprint, 2017, arXiv: 1710.10903.
- [27] Zhang M M, Hu L M, Shi C, et al. Adversarial label-flipping attack and defense for graph neural networks[C]//Proceedings of the IEEE International Conference on Data Mining, Piscataway: IEEE Press, 2020: 791–800.

作者简介



张虎（1979-），男，博士，山西大学计算机与信息技术学院教授，山西大学计算机与信息技术学院（大数据学院）副院长，主要研究方向为自然语言处理、大数据挖掘与分析。



王泰文（2000-），男，山西大学计算机与信息技术学院硕士生，主要研究方向为自然语言处理。



范越（1997-），男，山西大学计算机与信息技术学院博士生，主要研究方向为自然语言处理。



苏雅（1994-），女，山西大学计算机与信息技术学院博士生，主要研究方向为自然语言处理。

收稿日期: 2025-09-23
通信作者: 张虎, zhanghu@sxu.edu.cn
基金项目: 国家自然科学基金项目(No.62476161, No.62176145)
Foundation Items: The National Natural Science Foundation of China(No.62476161, No.62176145)