



注意力感知的边-节点交换图神经网络模型

王瑞琴¹, 黄熠旻¹, 纪其顺¹, 万超艺¹, 周志峰²

(1. 湖州师范学院信息工程学院, 浙江 湖州 313000;

2. 温州大学图书馆, 浙江 温州 325035)

摘要: 提出了一种注意力感知的边-节点交换图神经网络 (attention aware edge-node exchange graph neural network, AENN) 模型, 在图结构化数据表示框架下, 使用边-节点切换卷积的图神经网络算法进行图编码, 用于半监督分类和回归分析。AENN 是一种通用的图编码框架, 用于将图节点和边嵌入一个统一的潜在特征空间。具体地, 基于原始无向图, 不断切换边与节点的卷积, 并在卷积过程中通过注意力机制分配不同邻居的权重, 从而实现特征传播。在 3 个数据集上的实验研究表明, 所提方法较已有方法在半监督分类和回归分析中具有明显的性能提升。

关键词: 图神经网络; 消息传递; 注意力机制; 超图; 边图

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024017

Attention aware edge-node exchange graph neural network

WANG Ruiqin¹, HUANG Yimin¹, JI Qishun¹, WAN Chaoyi¹, ZHOU Zhifeng²

1. School of Information Engineering, Huzhou University, Huzhou 313000, China

2. Library of Wenzhou University, Wenzhou 325035, China

Abstract: An attention aware edge-node exchange graph neural network (AENN) model was proposed, which used edge-node switched convolutional graph neural network method for graph encoding in a graph structured data representation framework for semi supervised classification and regression analysis. AENN is an universal graph encoding framework for embedding graph nodes and edges into a unified latent feature space. Specifically, based on the original undirected graph, the convolution between edges and nodes was continuously switched, and during the convolution process, attention mechanisms were used to assign weights to different neighbors, thereby achieving feature propagation. Experimental studies on three datasets show that the proposed method has significant performance improvements in semi-supervised classification and regression analysis compared to existing methods.

Key words: graph neural network, message passing, attention mechanism, hypergraph, line graph

收稿日期: 2023-06-01; 修回日期: 2024-01-15

通信作者: 周志峰, zhouzf@wzu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62277016)

Foundation Item: The National Natural Science Foundation of China (No.62277016)

0 引言

深度学习模型^[1]在计算机视觉、自然语言处理、信号处理等许多领域都取得了巨大的成功,其中卷积神经网络(convolutional neural network, CNN)^[2]以端到端的方式训练,能够提取多尺度局部空间特征,常用于建模特定输入特征之间的高阶交互信息。CNN 中的卷积运算^[3]明确定义在具有欧几里得结构的数据上(如图像),不能直接推广到非欧数据中(如图结构),然而图结构化数据无处不在,从社交网络平台到电商数据,再到化学分子结构,图作为一种描述点与边关系的数据结构非常有效。图神经网络(graph neural network, GNN)^[4]由于其表达力强及灵活多变,近年来引起广泛关注。基于节点邻接矩阵, GNN 模型通过在空间结构图上定义卷积操作,在相关任务中取得了突出表现。但 GNN 方法主要关注如何获得有效的节点嵌入,忽略了对许多任务有益的边相关信息。

近年来,图学习方法取得了巨大进展,以图卷积神经网络(graph convolution neural network, GCN)^[5]为代表的一系列 GNN 模型在节点分类、图分类、链接预测等图领域任务中取得成功,其中大部分模型基于消息传递^[6-7]的方式进行建模,即通过聚合邻居信息更新节点自身状态。在该类范式中,节点特征得到充分学习。但是,在许多图结构中,边上存在丰富的信息,这类信息在当前大多数 GNN 模型中未被充分利用。总的来说,现有 GNN 模型对边信息的利用方式包括以下几种情形。

(1) 隐式利用:每个节点只聚合其邻边的信息,这一聚合方式基于节点间的边实现。此情况下将各个边视作布尔特征,只有“有边”和“无边”的区别,此类模型有 GCN、采样聚合图神经网络(graph sample and aggregate, GraphSAGE)^[8]、图注意力网络(graph attention network, GAT)^[9]等。

(2) 简易利用:对于边上特征为标量的情况,最简单直接的方式是使用带权邻接矩阵进行描述,在模型学习中加入边权重,此类模型有权重邻接矩阵^[10]、权重图卷积神经网络(a weighted GCN with logical adjacency matrix, WeightGCN)^[11]等。

(3) 聚合不同类型的边:在许多场景中,边特征为类别标签,例如,在社交网络中,边上可以标注两个人的关系为同事、家人等。对于存在多类型边的图,常见的处理方法是依照边的类型进行聚合。

(4) 多维边特征聚合:面对多维边特征,常见手段也是在聚合阶段将边特征、邻居节点特征通过某种函数结合在一起,再传给目标节点,此类模型有主邻域聚合图神经网络(principal neighborhood aggregation for graph nets, PNA Conv)^[12]等。

受图论中边图的启发,本文提出一种用于学习节点和边嵌入的新型超图卷积模型,即注意力感知的边-节点交换卷积神经网络(attention aware edge-node exchange graph neural network, AENN),并在卷积过程中加入注意力机制以更好地分配邻居权重,其中的核心问题在于边图的构造,用于表示图中边之间的邻接关系。在该模型框架中,节点和边的卷积不断切换,通过消息传递规则实现节点和边嵌入的相互学习。

本文目标是同时学习图的节点嵌入和边嵌入。现实中的图通常同时包含节点和边特征,在社交网络中,节点特征可以是人口统计信息或用户行为,而边缘特征可能是关系的类型。在引文网络中,节点特征可以是论文的文档级别,边特征可能表明两篇文章共同的关键词或合著者。本文模型充分利用了图结构以及节点和边的特征信息,将节点和边统一编码到潜在特征空间:首先,利用卷积网络聚合周围节点的信息,并进行信息传递;然后,引入边图的概念,保留节点卷积的结果,对边图进行相同操作;接着,



将边图卷积的结果保留, 进行下一轮次的节点卷积, 如此交替循环。此外, 在卷积过程中引入注意力机制, 为邻域内不同的节点和边指定不同的权值。

本文工作的主要贡献包括以下方面。

(1) 利用图结构以及节点和边的特征, 将节点和边同时嵌入潜在特征空间中, 实现了节点嵌入和边嵌入的相互增强。

(2) 在图卷积过程中, 将节点和边的作用依次进行交换, 并基于原始图构造了边图, 实现了基于两种图结构的卷积运算。

(3) 在图嵌入模型中引入了注意力机制, 实现信息聚合过程中的权重分配, 使得图嵌入的学习效果得到进一步改善。

1 理论基础

1.1 参数符号

(1) 一个具有节点集 V 和边集 E 的无向图 G , 其中 $V_v = |V|$ 和 $N_e = |E|$ 分别表示 G 的节点数和边数。

(2) A_v 是 G 的邻接矩阵, 其中的每个元素 $A_v(i, j)$ 表示节点之间的连通性, 即节点 i 和节点 j 相邻, A_v 是一个二值 (布尔) 矩阵。

(3) $X_v \in \mathbf{R}^{N_v \times d_v}$ 是节点特征矩阵, 其中的每个节点与一个 d_v 维的特征向量相关联。

(4) A_e 是 G 的二值边邻接矩阵, 其中的每个元素 $A_e(i, j)$ 表示边之间的连通性。

1.2 图卷积

给定一个无向图 G , 基于图卷积的图嵌入编码过程如下。

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

其中, $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ 是具有自连接的邻接矩阵, $\tilde{\mathbf{D}}$ 是度矩阵, $\mathbf{H}^{(l)}$ 和 $\mathbf{W}^{(l)}$ 是第 l 层的隐藏特征矩阵和可学习权重矩阵。

在节点域上定义空间图卷积, 可以整合其邻居节点之间的协同信号, 例如, GraphSAGE^[8] 就是一个基于聚合的表示学习模型。

1.3 构造边图

超图是图论中的一个概念, 它允许边连接多个节点, 而不仅仅是两个节点之间的连接。超图中的边可以将任意数量的节点组合起来, 这就使得超图能够更好地描述复杂的关系和依赖结构。相比于传统的图, 超图能够更好地刻画多对多的关联关系, 适用于更复杂的数据场景, 超图示例如图 1 所示。




图 1 超图示例

边图是超图中超边的一种特殊情况, 反映图中各边邻接性, 记作 $L(G)$ 。 $L(G)$ 将 G 中每条边抽象成一个顶点, 若原图中两条边相邻, 那么就给边图中对应顶点之间连接一条边。因为边图将原图的边化作了顶点, 所以也可以将其视作原图的一种对偶。

形式化地, 图 G 的边图 $L(G)$ 定义如下。

(1) $L(G)$ 的一个顶点对应 G 的一条边。

(2) $L(G)$ 的顶点相邻当且仅当它们在 G 对应的边相邻 (有公共顶点)。

用图论语言描述如下: 设 $G=(V, E)$, 那么 $L(G)=(E, \tilde{E})$, 且 $(e_1, e_2) \in \tilde{E} \leftrightarrow e_1 \cap e_2 \neq \emptyset$, 若原图是连通的, 其边图也是。若两个图同构, 则它们的边图也同构, 令 G 的顶点数和边数分别为 n 和 m , 则 $L(G)$ 的顶点数和边数分别是 m 和 $\sum_v (\deg(v) / 2)$ 。

边图的构造过程如图 2 所示。




图 2 边图的构造过程

1.4 节点嵌入

目前只有少数研究在图卷积过程中同时考虑节点特征和边特征,采用的方法主要分为两大类。

第一类方法为每种关系或维度定义不同的权重矩阵特征,然后聚合不同关系的嵌入传播,使用的前向更新规则如下。

$$h_i^{l+1} = \sigma \left(\sum_{r \in \mathbf{R}} \sum_{j \in N_i^r} \frac{1}{c_{i,r}} \mathbf{W}_r^{(l)} h_j^{(l)} + \mathbf{W}_0^{(l)} h_i^{(l)} \right) \quad (2)$$

其中, N_i^r 表示关系 r 下的邻居节点集合; $c_{i,r}$ 是归一化常数,可以提前学习或者选择,如 $c_{i,r} = |N_i^r|$; 每个关系 $r \in \mathbf{R}$ 都有其对应的权重矩阵 $\mathbf{W}_r$ 。

第二类方法引入基于关系的变换,取决于边的类型和方向。为了确保第 $l+1$ 层节点的表示蕴含第 l 层的节点表示,还添加了特殊关系类型,即节点的自连接。

以上简单的聚合在计算上很有效,但无法捕获不同节点和边特征之间的关系和相互作用。本文引入注意力机制,通过为不同的关系指定不同的可学习权重实现图卷积。与现有的图卷积与嵌

入方法不同,本文提出的 AENN 模型是一个通用的框架,可以应用于任何图卷积神经网络模型。更为重要的是,本文方法由相互加强的特征传播规则驱动,可以处理离散或连续的节点和边特征。

2 注意力感知的 AENN 模型

AENN 模型整体架构如图 3 所示,输入层包括一个图的节点邻接矩阵和相应的节点特征,以及该图对应边图的边邻接矩阵和边特征,图 3 用 3 种颜色表示对应关系,将原图中 3 种颜色的边 Y_1 、 Y_2 和 Y_3 转化到图中 3 个对应颜色的节点 Y_1 、 Y_2 和 Y_3 。将模型的整个过程定义为两种类型的卷积层:节点层和边层。在节点层使用原始图,基于边特征信息更新节点嵌入,保持边邻接矩阵和边特征不变;在边层使用边图,保持节点邻接矩阵和节点特征不变,用更新后的节点嵌入更新边嵌入;如此迭代,节点与边进行交叉卷积,用上一层的节点/边嵌入更新当前层的边/节点嵌入,直到收敛为止。

2.1 传播规则

设节点和边的特征矩阵分别用 $\mathbf{H}_v$ 和 $\mathbf{H}_e$ 表




图 3 AENN 模型整体架构



示, 则 $\mathbf{H}_v^{(l)}$ 和 $\mathbf{H}_e^{(l)}$ 分别表示节点和边在第 l 层的特征矩阵。

(1) 节点层的传播规则

定义具有自连接的归一化邻接矩阵 (拉普拉斯矩阵) 为:

$$\tilde{\mathbf{A}}_v = \mathbf{D}_v^{-\frac{1}{2}} (\mathbf{A}_v + \mathbf{I}_{N_v}) \mathbf{D}_v^{-\frac{1}{2}} \quad (3)$$

其中, $\mathbf{D}_v$ 是 $\mathbf{A}_v + \mathbf{I}$ 的对角矩阵, $\mathbf{I}$ 是单位矩阵, 表示自连接。

节点特征的传播规则为:

$$\mathbf{H}_v^{(l+1)} = \sigma(\mathbf{T} \Phi(\mathbf{H}_e^{(l)} \mathbf{P}_e) \mathbf{T}^T \odot \tilde{\mathbf{A}}_v \mathbf{H}_v^{(l)} \mathbf{W}_v) \quad (4)$$

其中, 矩阵 $\mathbf{T} \in \mathbf{R}^{N_v \times N_e}$ 是二元变换矩阵, 用于表示节点之间是否有边连通; 鉴于每条边有两个节点, 矩阵 $\mathbf{T}$ 的每一列都有两个元素为 1, 其他均为 0; $\mathbf{P}_e$ 为边特征向量的线性转换矩阵; Φ 表示对角化操作, 它将一维向量放置到方阵的对角线上, 即将对应元素通过 $\mathbf{T} \Phi(\mathbf{H}_e^{(l)} \mathbf{P}_e) \mathbf{T}^T$ 映射到归一化节点邻接矩阵上; $\odot$ 表示 Hadamard 积, $\tilde{\mathbf{A}}_v$ 表示利用节点邻接矩阵, 将来自邻边的特征信息传递到目标节点嵌入中; $\mathbf{W}_v$ 为节点特征向量的线性转换矩阵。

(2) 边层的传播规则

在边图中, 定义具有自连接的归一化邻接矩阵 (拉普拉斯矩阵) 为:

$$\tilde{\mathbf{A}}_e = \mathbf{D}_e^{-\frac{1}{2}} (\mathbf{A}_e + \mathbf{I}_{N_e}) \mathbf{D}_e^{-\frac{1}{2}} \quad (5)$$

其中, $\mathbf{D}_e$ 是 $\mathbf{A}_e + \mathbf{I}_{N_e}$ 的对角矩阵。

边特征的传播规则如下。

$$\mathbf{H}_e^{(l+1)} = \sigma(\mathbf{T}^T \Phi(\mathbf{H}_v^{(l)} \mathbf{P}_v) \mathbf{T} \odot \tilde{\mathbf{A}}_e \mathbf{H}_e^{(l)} \mathbf{W}_e) \quad (6)$$

其中, $\mathbf{P}_v$ 表示节点向量的线性变换权重, $\mathbf{W}_e$ 为节点特征向量的线性转换矩阵。边特征传播规则与节点特征传播规则类似, 使用节点特征和邻接矩阵 $\mathbf{A}_e$ 更新边嵌入。

2.2 注意力机制的引入

对于节点嵌入来说, 需要计算其所有邻居 ($j \in N_i$) 在该节点嵌入学习过程中的重要性权重,

表达式如下。

$$e_{ij} = a([\mathbf{W} \mathbf{h}_i \| \mathbf{W} \mathbf{h}_j]) \quad (7)$$

以上表达式表达的计算过程可以概括为: 首先通过一个共享的线性映射矩阵 $\mathbf{W}$ 对顶点特征进行维度转化, 然后利用向量拼接操作 $[\cdot]$ 对顶点 i 和 j 变换后的特征进行组合, 最后通过非线性激活函数 $a(\cdot)$ 将拼接后的高维特征映射到一个实数上。

计算出当前节点所有邻居的重要性权重之后, 通过 softmax 操作实现重要性权重的归一化, 得到每个邻居的注意力权重, 如式 (8) 所示。

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(e_{ij}))}{\sum_{k \in N_i} \exp(\text{LeakyReLU}(e_{ik}))} \quad (8)$$

将所有邻居节点的特征进行聚合, 得到当前节点的更新嵌入表示:

$$\mathbf{h}_i' = \sigma \left(\sum_{j \in N_i} \alpha_{ij} \mathbf{W} \mathbf{h}_j \right) \quad (9)$$

其中, $\mathbf{h}_i'$ 表示节点 i 的新嵌入, $\sigma(\cdot)$ 是使用的激活函数。实际上就是根据注意力权重, 对节点邻居的嵌入进行加权求和。

边特征的嵌入过程与节点嵌入类似, 同样使用了注意力机制实现边邻居的信息传递与聚合。

2.3 节点分类

节点和边特征交替更新, 直到模型收敛或到达指定的迭代次数为止。

对于半监督节点分类任务, 输出层的损失函数定义如下。

$$L(\Theta) = - \sum_{l \in Y_L} \sum_{f=1}^F Y_{lf} \lg M_{lf} \quad (10)$$

其中, Y 是一组带有标签的节点, M 是模型最后一层的输出结果, 这里假设最终的节点特征有 F 维; Y_L 是训练样本集; $\theta = (\mathbf{W}_v, \mathbf{W}_e, \mathbf{P}_v, \mathbf{P}_e)$ 是模型的超参数。

3 实验结果与分析

本节将本文方法 AENN 与 GCN、Graph SAGE、

GAT、自监督超图卷积网络 (self-supervised hypergraph convolutional network, DHCN) [13] 等方法进行对比分析, 采用的评价指标为分类准确率。

3.1 数据集

本文采用的实验数据集包括 3 个引文数据集 Cora、Citeeaser 和 PubMed。Cora 有 2 708 个节点 (论文) 和 5 429 个边 (引文链接), 每个节点有 1 433 个特征, 论文分为 7 个不同的研究领域。Citeeaser 有 3 327 个节点、4 732 个边、3 703 个节点特征, 论文分为 6 个研究领域。PubMed 包含 19 717 个节点和 44 338 个边, 每个节点有 500 个特征, 论文分为 3 个研究领域。

数据预处理过程中创建了两个简单的边特征: 对应节点特征之间的余弦相似度; 一个二维向量表示的边方向, 如果论文 A 引用了论文 B, 那么该向量为 (1,0), 否则为 (0,1)。对于所有的数据集, 随机选择 20% 的数据用于测试, 其余用于训练。

3.2 实验设置

半监督节点分类是图学习和统计学习社区中的一个经典任务, 最广泛使用的 benchmark 数据集是 3 个引文网络: Cora、Citeeaser 和 PubMed。采用的是小样本学习策略, 只在训练集中保留少量带标签的数据, 而将其余的数据分开进行验证和测试。在使用不同百分比的标记数据时, 将本模型与 GCN、GAT、GraphSAGE 等有代表性的图卷积神经网络对比。

所有实验均在相同的环境下实现: Windows11 操作系统, 11th GenIntel®Corei7 11800H CPU, NVIDIA GeForce RTX 3070 GPU, 算法实现采用 pytorch 框架。

3.3 实验结果

(1) 对比实验

本文分别在具有 3%、1% 和 0.5% 标记的 Cora 数据集, 具有 1%、0.5% 和 0.3% 标记的 Citeeaser 数据集, 以及具有 0.1%、0.05% 和 0.03% 标记的 PubMed 数据集上, 测试了本文方法与现有方法的分类性能。将没有加入边信息的网络与加入了边信息的网络进行对比可能引起不公平的争议, 因此实验中新创建的边特征均来自原始数据, 没有额外的信号被引入。

节点分类任务中不同模型的准确率比较见表 1, 所有的方法使用低标签率训练集都存在显著的过拟合问题, 原因可能来自图卷积网络本身的过拟合属性, 使得在消息传递后期过于疲软。经典的 GCN 模型在大多数情况下均取得不错的结果, GAT 在加入了注意力机制后有较明显的提升, GraphSAGE 模型由于没有采用边信息, 故表现较差, AENN 模型加入了边信息和注意力机制, 在 3 个数据集上表现最好。

(2) 与超图的比较

为了验证本文模型的优势所在, 特将其与目前最新的 DHCN 模型进行对比, 与 DHCN 模型的准确率对比如图 4 所示, 从左至右分别为 DHCN、AENN 和 GAT 的分类准确率, 3 个模型

表 1 节点分类任务中不同模型的准确率比较

数据集	标签比例	GCN	GAT	GraphSAGE	AENN
Cora	3%	74.0%±2.8%	74.8%±7.9%	64.2%±4.0%	76.4%±1.1%
	1%	61.0%±7.2%	68.6%±8.0%	49.0%±5.8%	64.1%±0.9%
	0.5%	52.9%±7.4%	54.4%±6.9%	37.5%±5.4%	54.7%±2.9%
Citeeaser	1%	58.3%±4.0%	59.5%±4.3%	51.0%±5.7%	63.5%±1.5%
	0.5%	47.7%±4.4%	48.2%±4.1%	33.8%±7.0%	50.6%±3.0%
	0.3%	39.2%±6.3%	40.9%±6.9%	25.7%±6.1%	45.4%±3.6%
PubMed	0.1%	63.0%±5.5%	65.6%±5.5%	65.4%±6.2%	70.0%±2.1%
	0.05%	64.6%±7.5%	65.4%±9.7%	53.0%±8.0%	66.7%±1.2%
	0.03%	57.9%±8.1%	60.9%±8.8%	45.4%±5.5%	62.4%±2.4%



都是在 Cora 数据集上采用 3% 的标签数据、学习率为 0.005、batch_size 大小为 32、模型层数为 4 层、迭代 1 000 次得到的结果。从图 4 可以看出, AENN 的表现与 DHCN 效果十分接近, 这一结果表明本文模型采用的节点和边交替卷积方法是有效的。




图 4 与 DHCN 模型的准确率对比

(3) 消融实验

为了验证本文模型采用的关键技术(边图、注意力机制(Attention))的优势所在, 本节进行了消融实验, 不同模型的表现见表 2。从表 2 可以看出, 与基准模型 GCN 相比, 增加注意力机制使基准模型在 Cora、Citeseer、PubMed 3 个数据集上的性能分别增长了 7.1%、2.9%、4%; 增加边图使基准模型在 3 个数据集上的性能分别增长了 8.8%、4%、2.7%; 结合注意力机制和边图机制的 AENN 模型相比基准模型在 3 个数据集上分别增长了 11.7%、7.1%、5.7%, 由此可见本文采用的关键技术是有效的。

表 2 不同模型的性能表现

数据集	基准模型	+Attention	+边图	AENN
Cora	65.7%±2.1%	70.4%±2.8%	71.5%±2.1%	73.4%±1.1%
Citeseer	57.4%±3.3%	60.3%±2.1%	59.7%±2.4%	61.5%±1.5%
PubMed	66.2%±4.6%	68.8%±3.7%	68.0%±3.4%	70.0%±2.1%

(4) 参数敏感性分析

本节对模型的超参数进行了敏感性分析, 比较不同的超参设置对模型性能的影响, 本实验使用的数据集为 Facebook 社交数据集, 标签比率为 90%, 即数据集中有 90% 的数据带有标签(如同事、朋友、家人)。

标签比率对分类准确率的影响如图 5 所示, 为不同标签占比(60%、70%、80%、90%)在 0.005 的学习率、batch_size 为 32、模型层数为 4 层、迭代 1 000 次时的分类准确率。从图 5 中可以看出, 随着标签比例的增加, 准确率逐步升高, 分别为 71.4%、74.5%、76.3%和 78.8%, 标签越多, 准确率越高, 这与常识是相符的。




图 5 标签比率对分类准确率的影响

学习率对分类准确率的影响如图 6 所示, 图 6 分别采用 0.000 5、0.001、0.005、0.01 的学习率在 batch_size 为 32、层数为 4 层、执行 1 000 次迭代的条件下得出对应的分类准确率。从图 6 可以看出, 学习率为 0.005 时模型训练的效果最佳, 所以本文模型设置了 0.005 的学习率。




图 6 学习率对分类准确率的影响

批处理大小对分类准确率的影响如图 7 所示, 为批处理大小分别采用 32/64/128/256、学习率为

0.005、网络层数为 4 层、执行 1 000 次迭代得出对应的训练损失值。从图 7 可以看出, 在批处理大小分别为 32、64、128 和 256 的情况下, 对应的训练损失分别为 0.171、0.241、0.25 和 0.332, 批处理大小为 32 时, 模型收敛效果最佳, 所以本文模型设置批处理的大小为 32。




图 7 批处理大小对分类准确率的影响

4 结束语

GCN 模型为研究者们非欧几里得空间中学习深度表示提供了新的途径。随着 GCN 模型最近的成功应用, 它在推荐领域也取得了显著的性能提升。GCN 的核心在于其消息聚合和邻域信息传递的机制。已有图卷积方法, 如 GAT、轻量级图卷积网络 (simplifying and powering graph convolution network, LightGCN) 等, 采用不同的方式改进图神经网络和消息传递的过程。本文的目标是同时学习图的节点嵌入和边嵌入。实际应用中的图通常同时包含节点和边的特征信息, 以社交网络为例, 节点特征可以包括人口统计信息或用户行为, 而边的特征可能涉及各种关系类型。在引文网络中, 节点特征可以是论文的文档级嵌入, 而边的特征则可能反映共同的关键词或合著两篇文章的情况。联合学习节点和边嵌入具有以下优势: 节点和边可以提供互补的特征信息, 有助于

更好地进行图嵌入; 学习边嵌入对于处理与边相关的任务至关重要。

本文提出的新框架为联合学习节点和边嵌入特征提供了一种新方法, 实验结果表明了本文方法的有效性。此外, 扩展模型以整合边的特征或者从边的特征角度来表达或聚合节点的特征, 这是一种新的思路, 可以用来处理更多类型的问题。笔者正在研究其他图卷积方法和更有效的训练算法, 以将边-节点交换图神经网络方法扩展到更广泛的应用领域和更复杂的数据集。

参考文献:

- [1] CHEN C, ZHANG M, ZHANG Y F, et al. Efficient neural matrix factorization without sampling for recommendation[J]. ACM Transactions on Information Systems, 2020, 38(2): 1-28.
- [2] CHEN L, WU L, HONG R C, et al. Revisiting graph based collaborative filtering: a linear residual graph convolutional network approach[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(1): 27-34.
- [3] CHEN M, WEI Z W, HUANG Z F, et al. Simple and deep graph convolutional networks[J]. arXiv preprint, 2020, arXiv: 2007.02133.
- [4] XIA X, YIN H, YU J, et al. Self-supervised hypergraph convolutional networks for session-based recommendation[C]// Proceedings of the AAAI conference on artificial intelligence. 2021, 35(5): 4503-4511.
- [5] WU J C, WANG X, FENG F L, et al. Self-supervised graph learning for recommendation[C]// Proceedings of the Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM Press, 2021: 726-735.
- [6] YU W H, QIN Z. Graph convolutional network for recommendation with low-pass collaborative filters[C]// Proceedings of the Proceedings of the 37th International Conference on Machine Learning. New York: ACM Press, 2020: 10936-10945.
- [7] YU W H, QIN Z. Sampler design for implicit feedback data by noisy-label robust learning[C]// Proceedings of the Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM Press, 2020: 861-870.
- [8] SUN J N, GUO W, ZHANG D C, et al. A framework for recommending accurate and diverse items using Bayesian graph convolutional neural networks[C]// Proceedings of the Proceed-



- ings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2020: 2030-2039.
- [9] JI S Y, FENG Y F, JI R R, et al. Dual channel hypergraph collaborative filtering[C]//Proceedings of the Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2020: 2020-2029.
- [10] WANG M H, LIN Y J, LIN G L, et al. M2GRL: a multi-task multi-view graph representation learning framework for web-scale recommender systems[C]//Proceedings of the Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2020: 2349-2358.
- [11] ZHANG H, LIU Q, LIU Z. Simplification of graph convolutional networks: a matrix factorization-based perspective[J]. arXiv preprint, 2020, arXiv: 2007.09036.
- [12] MAO K, ZHU J, XIAO X, et al. UltraGCN: ultra simplification of graph convolutional networks for recommendation[J]. arXiv preprint, 2021, arXiv: 2110.15114.

[作者简介]



王瑞琴（1979—），女，博士，湖州师范学院信息工程学院教授，主要研究方向为自然语言处理、社交网络分析、个性化推荐。



黄熠旻（1998—），男，湖州师范学院信息工程学院硕士生，主要研究方向为机器学习、数据挖掘、个性化推荐。



纪其顺（1996—），男，湖州师范学院信息工程学院硕士生，主要研究方向为自然语言处理、数据挖掘。



万超艺（1997—），女，湖州师范学院信息工程学院硕士生，主要研究方向为自然语言处理、数据挖掘。



周志峰（1978—），男，博士，温州大学图书馆副研究员，主要研究方向为信息检索、数据挖掘。