

# 基于主动学习的社交网络恶意用户检测方法



张人之 朱焱

西南交通大学信息科学与技术学院 成都 611756

(zrz59@qq.com)

**摘要** 社交网络恶意用户检测作为分类任务,需要标注训练样本。但社交网络规模通常较大,标注全部样本的花费巨大。为了能在标注预算有限的情况下找出更值得标注的样本,同时充分利用未标注样本,以此提高对恶意用户的检测表现,提出了一种基于图神经网络 GraphSAGE 和主动学习的检测方法。该方法分为检测模块和主动学习模块两部分。受 Transformer 的启发,检测模块改进了 GraphSAGE,扁平化其聚合节点各阶次邻居信息的过程,使高阶邻居能直接聚合到中心节点,减少了高阶邻居的信息损失;然后通过集成学习,从不同角度利用提取得到的表征,完成检测任务。主动学习模块根据集成分类的结果衡量未标注样本的价值,在样本标注阶段交替使用检测模块和主动学习模块,指导为样本标注的过程,从而更有助于模型分类的样本标注。实验阶段使用 AUROC 和 AUPR 作为评价指标,在真实的大规模社交网络数据集上验证了改进的检测模块的有效性,并分析了改进有效的原因;然后将所提方法与现有的两种同类主动学习方法进行比较,实验结果表明在标注相同数量的训练样本的情况下,所提方法挑选标注的训练样本有更好的分类表现。

**关键词:** 恶意用户检测;主动学习;图神经网络;社交网络;不平衡数据

中图法分类号 TP183

## Malicious User Detection Method for Social Network Based on Active Learning

ZHANG Ren-zhi and ZHU Yan

School of Information Science and Technology, Southwest Jiaotong University, Chengdu 611756, China

**Abstract** As a classification task, malicious user detection needs to label training samples. However, the scale of social networks is usually large, and it costs a lot to label all samples. In order to find out the more worthy samples in the case of limited labeled budget, and make full use of unlabeled samples to improve the detection performance of malicious users, a detection method based on graph neural network and active learning is proposed. The method is divided into two parts: detection module and active learning module. Inspired by Transformer, the detection module improves the graph neural network GraphSAGE, flattens the aggregation process of each order neighbors of its nodes, so that higher-order neighbors can directly aggregate to the central node and reduce the information loss of high-order neighbors. Then, through ensemble learning, the extracted representations are used from different perspectives to complete the detection task. The active learning module measures the value of unlabeled samples according to the results of ensemble classification, and alternately uses detection module and active learning module in the sample labeling stage to guide the process of labeling sample, which is more conducive to the model classification. In the experimental stage, AUROC and AUPR are used as evaluation indexes to verify the effectiveness of the improved detection module on a real large-scale social network data set, and the reasons for the improvement are analyzed. Then, compared with the existing two similar active learning methods, the experimental results show that the proposed method has better classification performance in the case of labeling the same number of training samples.

**Keywords** Malicious user detection, Active learning, Graph neural network, Social network, Imbalanced data

## 1 引言

恶意用户指在社交网络中向其他用户散播有害信息的用户,如传播垃圾广告、欺诈等有害信息的用户。识别这类节点

对维持健康的社交网络环境有重要意义。社交网络恶意用户检测的挑战有两方面:数据本身规模较大导致标注成本大;数据分布不平衡(正常用户数量远多于恶意用户)导致分类难度大。

收稿日期:2020-07-24 返修日期:2020-09-16 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:四川省科技计划项目(2019YFSY0032)

This work was supported by Sichuan Science and Technology Project(2019YFSY0032).

通信作者:朱焱(yzhu@swjtu.edu.cn)

(1)数据规模大。社交网络数据集的规模通常很大,标注全部数据的成本巨大。为了减轻标注压力,可以将只需要标注部分样本的半监督模型作为检测方法;而将主动学习与半监督学习相结合,可以对更有价值的样本进行标注,进一步提高检测的表现。通过结合半监督检测方法和主动学习,Li等<sup>[1]</sup>提出的方法在少量标注的异常检测问题上,达到了优于其他异常检测方法的表现;Das等<sup>[2]</sup>提出的方法在社交网络恶意内容检测问题上,将达到相同表现所需的标注量降低了1~2个数量级。对于图结构的数据,还可以使用图神经网络作为检测模型。图神经网络属于面向图数据的半监督学习模型,能同时利用节点的结构信息和属性信息,并且在多个节点的分类任务上达到了当前最好表现,适用于恶意用户检测任务。将图神经网络与主动学习相结合在图数据上有很好的应用前景,近年来,有不少研究将主动学习与图神经网络相结合来解决样本标注困难时的边流学习<sup>[3]</sup>、节点属性预测<sup>[4-5]</sup>和图分类<sup>[6]</sup>等问题,但很少有研究考虑到大规模图数据的情况。大规模图数据存在内存开销较大的问题,目前能在大规模图数据上训练的图神经网络<sup>[7-9]</sup>都以某种方式对图数据进行了采样,以此降低内存和计算的开销。将主动学习与这类图神经网络结合时也需要注意这一问题。

(2)数据不平衡。针对恶意用户的识别必然伴随数据不平衡的问题。不平衡数据导致分类困难的一大原因在于少数类的数量不足,导致模型无法学到足够的有关少数类的信息,而标注预算不足更加剧了这一困难。为了使标注的样本更有助于分类,应当增加少数类在标注数据中的比例。不考虑后续分类任务的主动学习方法<sup>[10]</sup>,直接在整个样本空间中选择标注样本,虽然灵活高效但不能保证选出更多的少数类样本。与后续分类算法相结合的主动学习方法<sup>[11]</sup>在分类边界附近寻找样本进行标注,所选样本更适合后续相应的分类算法,能找出更多的少数类样本,因而更适合不平衡数据集。

针对以上问题,本文提出了一种基于图神经网络和主动学习的检测方法用于社交网络恶意用户检测。首先改进基于节点采样的图神经网络 GraphSAGE<sup>[12]</sup>,从图数据中学习节点不同阶次邻居的表征;其次以集成学习的方式对各阶次的表征及其组合进行分类;最后使用分类结果计算样本的不确定性,并将其作为样本标注价值的度量。本文方法通过主动学习最大化每次标注的价值,提高了模型的表现。本文的主要贡献包括:1)改进 GraphSAGE,得到一个适用于社交网络恶意用户检测问题的图神经网络;2)对改进得到的图神经网络应用了基于不确定性的主动学习方法,使其能指导为样本标注的过程,提高每次标注的价值。

## 2 相关工作

### 2.1 图神经网络

为了让图神经网络在大规模图上运行,现有的解决方案是通过采样降低数据量。基于采样的图神经网络主要分为两类:节点级的采样和子图级的采样。

节点级的采样最早由 GraphSAGE 在 2017 年提出。其通过每个节点的采样邻居,将图神经网络应用于大规模图结

构数据。采样方式为将每个节点的邻居采样到一个固定的数量。如此便可将每个节点及其采样的邻居作为一个独立的样本,使其可以分批次训练,而不需要将整个图放在内存。节点级采样的缺点在于随着图神经网络层数的加深,需要采样的邻居总数呈指数增加。

子图级的采样随后被提出。这类方法在原图中采样出较小的子图,在子图上训练图神经网络。Chen等<sup>[13]</sup>提出的 fastGCN 和 Zeng等<sup>[14]</sup>提出的 GraphSAINT 都属于子图级的采样。两者的不同之处在于 fastGCN 在图神经网络的每一层都会采样一个新的子图,因此也有研究把 fastGCN 的采样方式称为层级采样;而 GraphSAINT 的每层都使用同一个子图。基于子图级采样方式的图神经网络能复用邻居的表征,因此在空间和时间复杂度上都优于基于节点级采样方式的图神经网络。但子图级采样对子图的连通性等特性有较高的要求,因此这类方法不适用于主动学习,主动学习标注的节点可能连通性不高。

### 2.2 主动学习

主动学习通过各种策略为样本打分,挑选更值得标注的样本。基于池的主动学习流程:维持一个未标注样本的池,初始时有极小一部分已标注的样本,通过已标注样本计算池中未标注样本的标注价值,选出价值最大的未标注样本进行人工标注,如此迭代直到模型的表现达到预期或已标注样本数量达到标注预算上限。

主动学习对未标注样本打分的策略有很多,常见的方法是使用样本的不确定性打分。Gal等<sup>[15]</sup>展示了如何通过 dropout 机制来度量神经网络预测结果的不确定性。首先,在一个样本预测时不关闭 dropout 机制(通常 dropout 只在训练时使用)并预测多次,这相当于使用不同架构模型的集成对一个样本进行预测;然后,对比这些预测结果得到样本的不确定性。此方法的缺点在于对 dropout 的超参数设置敏感,需要多次调参以达到最优。Lakshminarayanan等<sup>[16]</sup>同样使用集成学习的预测结果以度量样本的不确定性。其使用相同的数据训练多个相同架构的神经网络,而神经网络初始参数的不同和每轮训练数据的顺序不同将造成最终模型间的差异;最后通过不同模型的预测结果计算样本的不确定性。此方法的缺点在于要训练多个相同的模型,增加了计算量。

## 3 基于主动学习的社交网络恶意用户检测方法

针对社交网络恶意用户检测问题,本文提出了一种结合图神经网络和主动学习的检测方法,主要由恶意用户检测模块和主动学习模块组成。检测模块使用图神经网络分别提取节点不同阶次邻居的表征,然后对节点在不同阶次的表征使用集成分类器分类;主动学习模块对比不同分类器的预测结果以计算样本的不确定性,并将其作为标注价值的评估指标,选出标注价值最大的样本交由专家标注,然后用新标注的样本更新检测模块中的模型参数。交替使用检测模块和主动学习模块,直到已标注样本数量达到预先设定的上限,最后将集成分类器中表现最好的分类器的预测结果作为最终的分类结果。图 1 给出了使用一阶和二阶邻居检测时本文算法的总体框架。

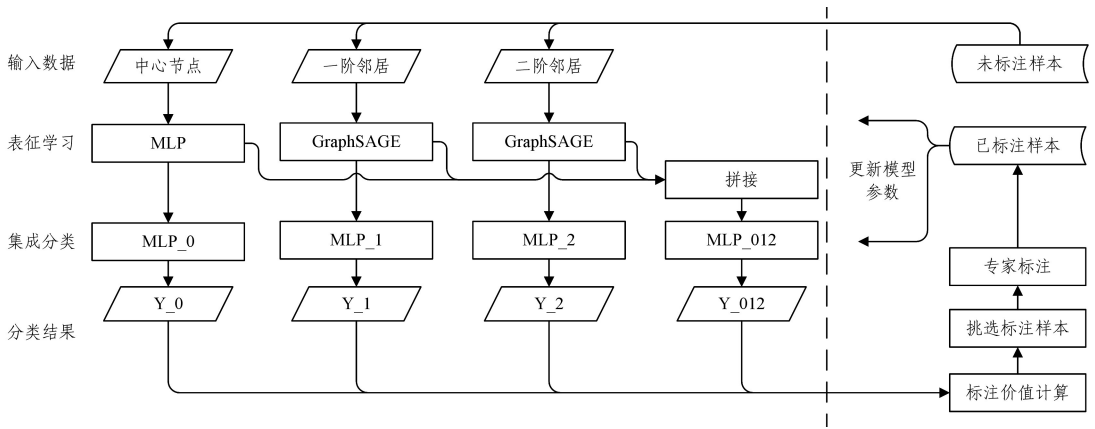


图 1 本文算法的总体框架

Fig.1 Framework of our algorithm

### 3.1 恶意用户检测模块

#### 3.1.1 表征学习

本文算法使用 GraphSAGE 作为节点表征的基础框架,其原因主要有:1)对于大规模数据集,需要基于采样的图神经网络;2)主动学习挑选标注的节点可能分散在图的各个位置,需要节点级采样的灵活性来应对。GraphSAGE 每层对数据的处理可以分为聚合与拼接两步,如式(1)和式(2)所示:

$$h_{N_i}^{l+1} = aggregate(\{h_j^l | j \in N_i\}) \quad (1)$$

$$h_i^{l+1} = \sigma(concat(h_{N_i}^{l+1}, h_i^l) \cdot W^{l+1} + b) \quad (2)$$

其中,  $h_j^l$  代表节点  $j$  在第  $l$  层的表征,  $N_i$  是节点  $i$  采样后的邻居集合,  $W^{l+1}$  是线性变换的权重矩阵,  $b$  是线性变换的 bias 向量,  $\sigma, aggregate$  和  $concat$  代表聚合操作和拼接操作。本文使用平均值作为邻居表征的具体聚合方式。

考虑到恶意用户检测问题中不同类别节点的邻居分布相似(都是大量正常用户加少量恶意用户),邻居表征对分类提供的帮助通常较低,本文改进了 GraphSAGE 聚合高阶邻居的方式。以二阶邻居的聚合为例,图 2 给出了不同邻居表征聚合方式下二阶邻居信息流动的路径。原本二阶邻居信息会首先聚合到一阶邻居,再聚合到中心节点。但由于一阶邻居表征在恶意用户检测中的帮助较低,为了更有效地利用二阶邻居信息,本文方法添加了跨层连接,直接将二阶邻居的表征拼接到中心节点的表征之后,避免了一阶邻居信息对二阶邻居信息的干扰。




图 2 邻居信息聚合路径的改进

Fig.2 Improvement of neighbor information aggregation paths

节点级采样的缺点在于采样的邻居数会随着网络层数的加深呈指数增加,加大内存和计算的负担。本文方法改进了邻居采样方式,图 3 为改进前后二阶邻居采样结构示意图。原本采样的二阶邻居和一阶邻居是节点与节点的对应关系。

为了进一步减少采样的邻居所占空间,我们将中心节点各阶次的所有邻居看作整体,并把对邻居的聚合提前到邻居采样阶段。本文方法使用平均值作为聚合方式,这样做的好处是减少了采样邻居占用的空间,同时能聚合全部的邻居信息。

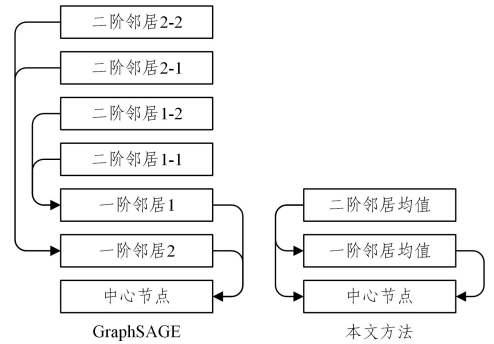


图 3 邻居采样方式的改进

Fig.3 Improvement of neighbor sampling method

综上,可以得到改进后的提取节点各阶次邻居表征的方法。首先计算节点  $i$  的  $k$  阶邻居  $N_i^k$  的属性  $x_j$  的平均值  $x_i^k$ , 作为  $k$  阶邻居的总体属性;然后使用多层感知器(Multilayer Perceptron, MLP)变换  $x_i^k$  得到节点  $i$  的  $k$  阶邻居表征  $z_i^k$ 。其中  $k \geq 0$ , 且  $x_i^0 = x_i, z_i^0$  代表节点  $i$  自身属性转换得到的表征。此方法的具体操作如式(3)和式(4)所示,改进前后的时空复杂度对比如表 1 所列。

$$x_i^k = \frac{1}{|N_i^k|} \sum x_j, j \in N_i^k \quad (3)$$

$$z_i^k = MLP(x_i^k) \quad (4)$$

表 1 时空复杂度的对比

Table 1 Comparison of time and memory complexity

Complexity	GraphSAGE	本文方法
Time	$O(s^k n d^2)$	$O(k o n d^2)$
Memory	$O(b s^k d + k d^2)$	$O(b k o d + k d^2)$

表 1 中,  $s$  代表每个节点采样的邻居数量,  $k$  代表神经网络的层数,  $n$  代表节点数量,  $b$  代表分批训练的批次大小,  $d$  代表神经网络隐含层的维数(为简化计算,假设每层的维数相同),  $o$  代表最高阶邻居的阶数。可以看出,本文方法在神经网络层数  $k$  上的复杂度,从指数级降低到了线性级。

### 3.1.2 集成分类

集成分类部分对提取得到的各个表征  $\mathbf{z}^k$  进行拼接得到拼接表征  $\mathbf{c}^k$ , 拼接规则如式(5)所示:

$$\mathbf{c}^k = \text{concat}(\mathbf{z}^k, \mathbf{z}^{k+1}, \dots, \mathbf{z}^K) \quad (5)$$

其中,  $K$  代表在表征学习阶段设置的最高邻居阶次。

集成分类使用多个 MLP 对全部表征  $\mathbf{z}$  和  $\mathbf{c}$  分类, 每个表征对应一个分类器。对单独表征  $\mathbf{z}$  的分类是为了更直接地优化该表征的学习过程, 对拼接表征  $\mathbf{c}$  的分类是为了模拟 GraphSAGE 依次聚合各阶次邻居表征再分类的过程。集成分类部分与表征学习部分共同训练, 使用表现最好的分类器的结果作为最终分类结果, 通常  $\mathbf{c}^0$  对应的分类器有最好的分类表现。

此外, 针对数据不平衡问题, 本文方法使用了 Lin 等<sup>[17]</sup> 在目标检测任务中为解决不平衡分类问题而提出的损失函数 Focal loss。其核心思想是在交叉熵(Cross Entropy, CE)的基础上做出调整, 降低易分类样本的权重, 并通过参数  $\gamma$  来调整降低的幅度, 其具体公式如式(6)所示:

$$\text{Focal\_loss} = |y - \hat{y}|^\gamma \cdot \text{CE}(y, \hat{y}) \quad (6)$$

### 3.2 主动学习模块

主动学习模块使用样本的不确定性来衡量样本的标注价值, 标注预测结果不确定性更大的样本, 对模型分类的帮助更大。同时, 预测结果不确定性大的样本通常也在分类边界附近, 对于不平衡数据, 标注分类边界附近的样本能找到更多的少数类, 对模型检测恶意用户有更大的帮助。

主动学习模块使用集成分类中全部分类器的预测结果  $\mathbf{r}$  作为输入。具体计算样本不确定性的方法主要受文献[16]的启发, 使用集成学习分类结果的方差作为预测结果不确定性  $u$ 。与文献[16]的方法 Deep-Ensemble 不同, 本文集成学习方法中每个分类器的输入不相同, 而 Deep-Ensemble 中每个分类器的输入是相同的。

$$u = \text{var}(\mathbf{r}) \quad (7)$$

计算得到每个样本的不确定性后, 即可据此选出最值得标注的样本交由专家标注。然后重新训练恶意用户检测模块, 继续挑选新的样本进行标注。但出于实际计算效率的考虑, 本文在实验阶段的每次迭代会选出多个高不确定性的样本进行标注, 而非逐个挑选。

## 4 实验与结果分析

### 4.1 实验数据介绍

实验所用数据集<sup>[18]</sup>来自 Tagged.com 社交网站。数据集的节点数为 5607447, 边的数量为 858247099, 每个节点被标注是否是垃圾用户(spammer)。垃圾用户在总用户中的占比为 6%。节点拥有 3 个用户属性: 性别、年龄和已注册时间; 边共有 7 种类型。本文在数据预处理阶段, 提取节点在 7 种边上的出度和入度作为节点属性, 然后将边的类型合并为 1 种。

### 4.2 分类表现的评估指标

对于恶意用户检测任务, 恶意用户的分类表现更受关注, 但恶意用户为少数类, 其分类表现通常远低于多数类。因此, 评估指标除了要反映总体的分类表现外, 还应该反映出少数

类上的分类表现。ROC (Receiver Operating Characteristic Curve) 曲线是被广泛应用的二分类评估指标, 但其在不平衡数据集上不能很好地评估少数类的分类表现<sup>[18]</sup>。ROC 本质上评估的是模型在两个类别上的综合分类表现, 因而难以反映模型在少数类的表现。为了准确地评估少数类的分类效果, 需要同时考虑少数类的精确率 (precision) 和召回率 (recall)。PR 曲线 (Precision-Recall Curve, PR) 能反映不同阈值下的精确率和召回率。而 PR 曲线下的面积 (Area Under PR Curve, AUPR) 能作为模型对少数类的分类表现的评估指标。

综上, 本文使用模型的 AUROC (Area Under ROC) 和恶意用户的 AUPR 作为评估指标, 分别反映模型的总体分类表现和在少数类上的分类表现。

### 4.3 实验设计与结果

为验证本文所提方法的有效性, 进行两组对比实验。第一组实验不进行主动学习, 只比较分类表现, 以验证检测算法改进的有效性; 第二组实验对比本文所提出的主动学习模块与其他类似主动学习方法在标注预算相同时的分类表现。

实验所用编程语言为 Python3.6, 所用深度学习框架为 TensorFlow2.0, 计算机内存为 16GB, 所用显卡为 GTX1050ti。所有模型均训练 10 次后取其评价指标的平均值和标准差作为最终结果, 以降低随机初始模型参数带来的影响。

#### 4.3.1 检测模块的对比实验

实验设置: 在整个图上随机选择 400000 个节点, 其中一半作为已标注节点用于训练, 另一半用于测试模型分类的表现。以下为每个方法的具体配置。

GraphSAGE: 使用两层架构, 每个节点采样 10 个一阶邻居和  $10 \times 10$  个二阶邻居。

本文方法: 使用一阶邻居和二阶邻居以及样本自身的表征集成分类, 用表征  $\mathbf{c}^0$  对应的分类器的输出作为最终分类结果。

非集成- $\mathbf{z}^0$ : 表征学习阶段与本文方法相同, 但在分类部分只使用表征  $\mathbf{z}^0$  训练一个分类器, 不使用其他表征训练分类器。同理扩展到非集成的  $\mathbf{c}^1$  和  $\mathbf{c}^0$  的情况。

每个方法重复训练 10 次, 并计算各评估指标的平均值和标准差, 具体的分类表现如表 2 所列。

表 2 分类表现的对比

Model	AUPR	AUROC
GraphSAGE	0.6196 ± 0.002	0.8715 ± 0.0007
本文方法	<b>0.6323 ± 0.004</b>	<b>0.8747 ± 0.0010</b>
非集成- $\mathbf{z}^0$	0.5816 ± 0.002	0.8643 ± 0.0005
非集成- $\mathbf{c}^1$	0.5112 ± 0.004	0.8323 ± 0.0011
非集成- $\mathbf{c}^0$	0.6278 ± 0.002	0.8733 ± 0.0013

#### 4.3.2 主动学习模块的对比实验

实验设置: 在整个图上随机选择 400000 个节点, 其中一半加入未标注样本池, 另一半用于测试模型分类表现。初始时随机选择未标注样本池中的 1000 个节点获取类标, 之后每轮迭代由主动学习方法从未标注样本池中选出 1000 个样本获取类标, 直到已标注样本数达到 20000 个 (未标注样本池数量的 10%)。以下为各方法的具体配置。

Random: 使用本文的检测模型, 配置与 4.3.1 节中相同; 每次迭代随机挑选样本, 作为不使用主动学习情况下的对比方法。

MC-Dropout<sup>[15]</sup>: 使用 GraphSAGE 作为检测模型, 配置与 4.3.1 节中相同; dropout 层加在模型输出层之前, 神经元失活概率为 0.25。

Deep-Ensemble<sup>[16]</sup>: 检测模型及其配置同 MC-Dropout; 集成学习训练的模型数为 3。

本文方法: 使用本文的检测模型, 配置与 4.3.1 节中相同。

表 3 列示了使用各主动学习方法所选的 20000 个标注样本训练的检测模型分类表现。图 4 给出了在主动学习每轮迭代中各方法所选样本训练的检测模型的 AUPR 变化过程。

表 3 主动学习表现对比

Table 3 Comparison of active learning performance

Model	AUPR	AUROC
Random	0.5770±0.0023	0.8597±0.0020
MC-Dropout	0.5940±0.0017	0.8462±0.0017
Deep-Ensemble	0.6018±0.0025	0.8565±0.0022
本文方法	0.6109±0.0020	0.8611±0.0036




图 4 主动学习过程的对比

Fig. 4 Comparison of active learning process

#### 4.3.3 实验结果分析

在检测模块的实验结果中, 从本文方法与 GraphSAGE 的对比可以看出, 在恶意用户检测方面, 本文方法所做的改进总体有效, 分类表现明显提高。非集成的方法中:  $z^0$  代表从节点自身属性学到的表征,  $c^1$  代表节点所有阶次邻居表征的拼接, 而  $c^0$  则是  $z^0$  和  $c^1$  的拼接。从非集成方法  $z^0$ ,  $c^1$  和  $c^0$  的对比可以看出, 此数据集中节点自身信息对分类的帮助大于邻居信息的帮助, 而两者的拼接则可以进一步提高分类表现。非集成方法  $c^0$  与 GraphSAGE 的对比说明本文在表征学习方面的改进是有效的; 跨层连接可以保留更多高阶邻居的信息, 而采样邻居时, 提前聚合邻居可以聚合更多邻居的信息。 $c^0$  与本文方法的对比则说明: 虽然都是使用  $c^0$  作为分类表征, 但在集成学习中使用单个的表征  $z$  分类, 能显式地优化单个表征, 从而提高拼接表征  $c^0$  的分类表现。

从主动学习模块的实验结果中可以看出, 相比随机选择样本进行标注, 使用主动学习方法指导样本标注过程能明显提高只标注少量样本时的分类表现。本文的主动学习方法与同类的 MC-Dropout 和 Deep-Ensemble 方法相比也有更好的表现。本文方法与 Deep-Ensemble 计算样本不确定性的方法相同, 区别在于本文方法的集成学习中每个分类器的输入是不同的, 而 Deep-Ensemble 中每个分类器的输入是相同的。

使用不同方面的表征训练分类器可以使模型从不同方面考虑样本的不确定性, 更契合本文的检测方法, 因而能提高最终分类表现。

**结束语** 针对社交网络恶意用户检测任务中因数据规模大带来的标注成本高的问题, 本文提出一种基于图神经网络 GraphSAGE 和主动学习的检测方法。该方法通过改进 GraphSAGE 学习节点及其邻居的表征, 充分利用未标注节点的信息; 然后通过主动学习, 提高在少量标注下所选择标注的样本的质量。本文在实验阶段验证了所提方法改进的有效性, 同时与其他同类主动学习方法进行对比, 结果证明所提方法能够取得更好的表现。但本文方法在对节点邻居聚合时, 只进行了简单平均, 没有考虑到不同邻居的价值不同, 我们在未来的工作中将对此方面加以改进。

#### 参考文献

- [1] LI Y, WANG Y, MA X, et al. A Graph-Based Method for Active Outlier Detection With Limited Expert Feedback [J]. IEEE Access, 2019, 7: 152267-152277.
- [2] DAS B, TOLONE W, PARANJAPE V. Identifying malicious social media contents using multi-view Context-Aware active learning [J]. Future Generation Computer Systems-the International Journal of Esience, 2019, 100: 365-379.
- [3] JIA J T, MICHAEL T S, SANTIAGO S. Graph-based Semi-Supervised & Active Learning for Edge Flows [C] // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2019: 761-771.
- [4] DONG Z, ZHANG R, SHAO X. Automatic Annotation and Segmentation of Object Instances With Deep Active Curve Network [J]. IEEE Access, 2019, 7: 147501-147512.
- [5] CHENG Y, NICOLÒ C, RICARDO S. Bayesian Semi-Supervised Learning with Graph Gaussian Processes [C] // Advances in Neural Information Processing Systems. 2018: 1683-1694.
- [6] LI J, RONG Y, CHENG H, et al. Semi-Supervised Graph Classification: A Hierarchical Graph Perspective [C] // Proceedings of International Conference on World Wide Web. ACM, 2019: 972-982.
- [7] HOU Y F, CHEN H Z, LI C J. A Representation Learning Framework for Property Graphs [C] // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2019: 65-73.
- [8] HUANG W B, ZHANG T, RONG Y. Adaptive Sampling Towards Fast Graph Representation Learning [C] // Advances in Neural Information Processing Systems. 2018: 4558-4567.
- [9] CHIANG W L, LIU X Q, SI S, et al. Cluster-GCN: An Efficient Algorithm for Training Deep and Large Graph Convolutional Networks [C] // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2019: 257-266.
- [10] OZAN S, SILVIO S. Active Learning for Convolutional Neural Networks: A Core-Set Approach [C] // Proceedings of International Conference on Learning Representations. 2018.
- [11] PENG P, ZHANG W, ZHANG Y, et al. Cost sensitive active learning using bidirectional gated recurrent neural networks for

- imbalanced fault diagnosis[J]. *Neurocomputing*, 2020, 407: 232-245.
- [12] HAMILTON W, YING Z, LESKOVEC J. Inductive Representation Learning on Large Graphs[C]// *Advances in Neural Information Processing Systems*. 2017: 1024-1034.
- [13] CHEN J, MA T F, XIAO C. FastGCN: Fast Learning with Graph Convolutional Networks via Importance Sampling[C]// *Proceedings of International Conference on Learning Representations*. 2018.
- [14] ZENG H Q, ZHOU H K, AJITESH S, et al. GraphSAINT: Graph Sampling Based Inductive Learning Method[C]// *Proceedings of International Conference on Learning Representations*. 2020.
- [15] GAL Y, GHAHRAMANI Z. Dropout as A Bayesian Approximation: Representing Model Uncertainty in Deep Learning [C]// *Proceedings of International Conference on Machine Learning*. 2016: 1050-1059.
- [16] LAKSHMINARAYANAN B, PRITZEL A, BLUNDELL C. Simple and Scalable Predictive Uncertainty Estimation using Deep Ensembles[C]// *Advances in Neural Information Processing Systems*. 2017: 6402-6413.
- [17] LIN T Y, PRIYA G, HE K M, et al. Focal Loss for Dense Object Detection[C]// *Proceedings of IEEE International Conference on Computer Vision*. 2017: 2999-3007.
- [18] SHOBEIR F, JAMES F, MADHUSUDANA S, et al. Collective Spammer Detection in Evolving Multi-Relational Social Networks[C]// *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, 2015: 1769-1778.



**ZHANG Ren-zhi**, born in 1996, post-graduate. His main research interests include Web spam detection and graph neural network.



**ZHU Yan**, born in 1965, Ph.D, professor, Ph.D supervisor, is a member of China Computer Federation. Her main research interests include data mining, Web anomaly detection, big data management and intelligent analysis.