

文章编号:1671-6833(2023)02-0068-07

基于双重注意力机制的符号网络节点嵌入

逯泽锟^{1,2}, 于千城^{1,2}, 王晓峰¹, 李霞^{1,2}, 王金云³

(1. 北方民族大学 计算机科学与工程学院, 宁夏 银川 750021; 2. 北方民族大学 图形图像国家民委重点实验室, 宁夏 银川 750021; 3. 北方民族大学 商学院, 宁夏 银川 750021)

摘要: 网络节点嵌入是将网络中的节点映射为低维的向量表示, 从而可以直接应用基于向量空间的学习方法来处理链路预测等下游任务。现有的网络节点嵌入模型大多针对无符号网络, 不能直接用于处理符号网络(通常需将符号网络转换成无符号网络进行处理, 因而丢弃了边上的正负号所蕴含着的大量有价值的信息)。基于图神经网络(GNNs)提出了一种可以直接处理符号网络的节点嵌入模型, 即基于双重注意力机制的符号网络节点嵌入(SNEDA)。依据结构平衡理论和地位理论, 将节点间的路径按照方向和边上的正负信息划分成20种不同的模体(motif)结构。设计了包含2层注意力机制的网络传播模型, 当汇聚节点*i*的直接邻居信息时, 通过节点级注意力机制捕获不同邻居节点对节点*i*的向量表示的贡献和影响; 当汇聚节点*i*的二阶及二阶以上各阶邻居信息时, 用路径级注意力捕获不同 motif 对节点*i*的向量表示。通过引入两层注意力机制综合考虑节点层面和路径层面的不同贡献和影响, 不仅提高了算法的时间效率, 而且使得最终得到节点*i*的向量表示更有利于提高下游链路预测任务的预测准确性。在4个真实的社交网络数据集上进行实验, 与基准模型相比, SNEDA模型在AUC和F1指标上分别提高了约3.1%和1.1%。结果表明该模型得到的网络表示有助于提高链路预测的准确性。

关键词: 符号网络; 图神经网络; 图注意力网络; 网络嵌入; 链路预测**中图分类号:** TP181**文献标志码:** A**doi:** 10.13705/j.issn.1671-6833.2023.02.012

真实世界中存在着大量的网络结构, 如社交网络、生物蛋白质网络、引文网络、交通网络、化学分子网络等^[1-2]。采用复杂网络分析方法对这些网络结构进行研究有助于人们更好地挖掘隐藏在网络数据中的规律^[3]。而网络结构具有数据规模较大、结构稀疏等特性, 无法直接用网络分析方法进行分析。网络表示学习将深度学习拓展到了网络数据分析, 旨在学习网络节点低维向量表示的方法, 并保留网络拓扑结构和节点属性^[4]。将节点表示成低维、实值、稠密的向量形式, 使得到的向量表示在向量空间中具有表示以及推理的能力^[5]。得到的向量表示可以运用到下游任务中, 如链路预测、节点分类、社区发现、个性化推荐等^[6-7]。

符号网络是一种包含正、负对立关系的二维网络, 正关系包括朋友、支持、喜欢等积极关系; 负关系包括敌人、反对、讨厌等消极关系^[8]。在符号网络

学习节点嵌入过程中, 正向边、负向边以及边的方向都会对学习节点嵌入造成很大的挑战^[9]。对此, 研究者们利用符号网络中的社会学理论(结构平衡理论和地位理论)对网络结构进行建模来正确区分正负边, 并结合图神经网络或深度学习来学习节点嵌入, 这些方法在符号网络嵌入领域也取得了最优性能^[10-11]。但上述方法都是从节点层面关注节点邻居的影响, 忽视了路径信息这一特征。在路径层面, 节点与邻居之间链路不同方向和符号构成复杂的路径, 这些不同的路径也会对节点嵌入造成影响。

本文提出了SNEDA方法(signed network embedding via dual attention mechanism), 通过划分不同的 motif 来捕捉路径信息(链路不同方向和符号), 用节点级注意力学习每个 motif 下节点之间的影响, 用路径级注意力学习不同 motif 之间的权重, 基于重要 motif 选择性的聚合邻居信息, 得到节点的向量表

收稿日期: 2022-10-13; **修订日期:** 2022-11-26**基金项目:** 国家自然科学基金资助项目(62062001); 北方民族大学博士科研启动金项目(2020KYQD48); 2022年校级科研平台数字化农业赋能宁夏乡村振兴创新团队(2022PT_S10)**通信作者:** 于千城(1976—), 男, 宁夏银川人, 北方民族大学副教授, 博士, 主要从事社会感知计算、社交网络分析的研究, E-mail: 1999019@nmu.edu.cn。**引用本文:** 逯泽锟, 于千城, 王晓峰, 等. 基于双重注意力机制的符号网络节点嵌入[J]. 郑州大学学报(工学版), 2023, 44(2): 68-74. (LU Z K, YU Q C, WANG X F, et al. Learning signed network node embedding via dual attention mechanism[J]. Journal of Zhengzhou University (Engineering Science), 2023, 44(2): 68-74.)

示。得到的向量表示不仅融合了节点邻居的信息,同时也融合了网络结构信息,实验证明 SNEDA 模型可以提升节点嵌入的质量。

1 理论知识

定义 1 度中心性 (degree centrality, DC)。DC 是在网络中刻画节点中心性最直接的度量指标。一个节点的度越大,就意味着这个节点的度中心性越高,说明在网络中这个节点越重要。节点的度中心性为

$$DC(i) = \frac{N_{\text{degree}}}{n - 1}.$$
 (1)

式中: N_{degree} 表示节点的度; n 表示节点的个数。

1.1 结构平衡理论

(1) 结构平衡三角形。通过三角形 3 条边的符号之积来判定三角形是否结构平衡。若为正,则该三角形结构平衡;否则不平衡^[12]。研究表明,在真实社交网络结构中平衡三角形的数目远大于结构不平衡的三角形数量,且不平衡网络结构随着时间推移逐渐向平衡网络结构演化^[13]。

(2) 结构平衡环。如果一个 L -环 ($L \geq 3$) 包含偶数条负边,则该 L -环结构是平衡的,否则结构是不平衡的^[14]。图 1 为结构平衡理论示意图。




图 1 结构平衡理论示意图

Figure 1 Schematic diagram of structural balance theory

1.2 社会地位理论

Leskovec 等^[15]提出适用于有符号网络的社会地位理论。该理论认为如果有一条正的边从节点 i 指向节点 j ,则节点 i 比 j 社会地位高,若有一条节点

i 指向节点 j 的负向边,则 j 比 i 社会地位高,且这种地位高低具有传递性。图 2 为地位平衡理论示意图。




图 2 地位平衡理论示意图

Figure 2 Schematic diagram of status balance theory

1.3 网络模体 (network motif)

在真实的社交网络中,用户节点的链接行为受邻居节点影响,且不同的邻居会造成不同的影响。依据链路不同的方向和符号,将节点与邻居之间不同的路径划分不同的 motif,如图 3 所示。节点 j 是节点 i 的一阶邻居,共有 4 种不同的 motif,节点 k 是节点 i 的二阶邻居,共有 16 种不同的 motif。




图 3 符号网络中 20 种不同的模体

Figure 3 20 different motifs in the signed network

2 SNEDA 模型

SNEDA 模型的框架如图 4 所示,由 5 部分组成。首先,通过节点邻居采样得到节点的一阶和二阶邻居信息;其次,依据不同的 motif 划分得到不同的邻居集合;再次,在每个 motif 下用节点级注意力




图 4 SNEDA 模型图

Figure 4 Illustration of SNEDA model

来学习节点之间的权重,得到特定的节点嵌入;从次,使用路径级注意力来学习不同 motif 的重要性,基于重要 motif 汇聚节点邻居信息得到最终的向量表示;最后,通过链路预测实验来检测模型节点嵌入的质量。

2.1 产生节点在不同 motif 下的向量表示

为了消除链路方向和链路符号不同造成节点不同的影响,将节点与邻居之间相同的链路划分为一种 motif,每一种 motif 都独立使用自注意力机制学习节点之间的权重。节点 i 和节点 j 经过路径 ϕ 连接,节点 j 在 ϕ 模式下对节点 i 的影响力为

$$e_{ij}^{\phi} = att_{node}(h_i, h_j; \phi). \quad (2)$$

式中: att_{node} 表示执行节点级注意力的深度神经网络; ϕ 表示不同 motif 的集合; h_i 和 h_j 表示节点 i 和 j 的特征向量;注意力系数 e_{ij}^{ϕ} 表示在某个 motif 下节点 j 对节点 i 的重要性, e_{ij}^{ϕ} 是非对称的,即 $e_{ij}^{\phi} \neq e_{ji}^{\phi}$,这表明节点 i 对节点 j 的重要性与节点 j 对节点 i 的重要性是不对等的。

在得到节点对之间的重要性后,用 softmax 函数对其权重进行归一化处理:

$$a_{ij}^{\phi} = \frac{\exp(\sigma(c_{\phi}^T \cdot [h_i \| h_j]))}{\sum_{k \in N_i^{\phi}} \exp(\sigma(a_{\phi}^T \cdot [h_i \| h_k]))}. \quad (3)$$

式中: σ 表示激活函数; a_{ij}^{ϕ} 表示在某个 motif 下节点对的注意力系数; N_i^{ϕ} 表示在某个 motif 下节点 i 的邻居集合; a_{ϕ}^T 表示在某个 motif 下节点的注意力向量; $[\]$ 和 $\|$ 都表示连接操作 (concatenation)。

通过汇聚节点的邻居信息及其相关系数得到节点 V_i 新的向量表示:

$$h_i^{\phi} = \sigma(\sum_{j \in N_i^{\phi}} a_{ij}^{\phi} h_j). \quad (4)$$

式中: h_i^{ϕ} 表示在某个 motif 下节点 i 的向量表示; a_{ij}^{ϕ} 表示在某个 motif 下节点对的注意力系数。在给定的 20 种 motif 下分别进行学习,得到节点 i 不同 motif 下的特征向量集合 $\{h_i^{\phi_1}, h_i^{\phi_2}, \dots, h_i^{\phi_{20}}\}$ 。

2.2 融合不同的 motif

节点级注意力学习得到的节点嵌入只反映节点层面信息。为了学习更加全面的节点嵌入,需要融合更加丰富的路径信息,将路径按照方向和正负信息划分不同的 motif,通过路径级注意力学习不同 motif 的重要性,基于重要 motif 汇聚节点邻居信息得到节点的向量表示,如图 4(路径级注意力部分)所示。

节点级注意力学习到的节点嵌入作为输入,每个 motif 学习权重为

$$B_{\phi_1}, B_{\phi_2}, \dots, B_{\phi_{20}} = att_{path}(h_{\phi_1}, h_{\phi_2}, \dots, h_{\phi_{20}}). \quad (5)$$

式中: att_{path} 表示执行路径注意力的深度神经网络,在每个 motif 下的 att_{path} 参数是共享的; B_{ϕ_m} 表示学习得到不同 motif 的权重。

将节点级注意力学习到的节点嵌入进行非线性变化,利用节点层面注意力机制学习到的特定向量和路径层面注意力向量 q 计算相似度,以此衡量不同语义向量的重要性,每个 motif 的重要性由 w_{ϕ_i} 表示:

$$w_{\phi_i} = \sum_{i \in V} q^T \cdot \tanh(W \cdot h_i^{\phi_m} + b). \quad (6)$$

式中: W 和 b 分别为可训练参数矩阵和偏差向量; q 为路径向量;所有 motif 的嵌入都共享以上参数。在得到各 motif 的重要性后,用 softmax 函数对其进行归一化处理:

$$B_{\phi_i} = \frac{\exp(\sigma(w_{\phi_i}))}{\sum_{i=1}^m \exp(\sigma(w_{\phi_i}))}. \quad (7)$$

式中: B_{ϕ_i} 表示 motif 的权重, B_{ϕ_i} 越高,表示该 motif 越重要,对于不同的 motif,可能有着不同的权重。通过学习得到不同 motif 的权重系数,得到最终的目标节点嵌入:

$$Z_i = \sum_{i=1}^m B_{\phi_i} \cdot h_i^{\phi_i}. \quad (8)$$

式中: B_{ϕ_i} 表示学习得到的 motif 权重系数; $h_i^{\phi_i}$ 表示在某个 motif 下节点 i 的向量表示。

2.3 链路预测

通过链路预测实验来验证模型学习节点嵌入的质量,经过 SNEDA 模型学习得到每个节点的向量表示,将训练集中的节点向量表示作为节点特征输入到二分类模型中进行链路预测的实验。为了更好地学习模型参数,SNEDA 模型采用交叉熵作为损失函数,定义如下:

$$loss = \sum_{v^+ \in N_{(u)}^+} \lg(\sigma(Z_u^T Z_{v^+})) - C \sum_{v^- \in N_{(u)}^-} \lg(\sigma(-Z_u^T Z_{v^-})). \quad (9)$$

式中: C 为用来调节正向连接和负向连接数量的比例; $N_{(u)}^+$ 为节点 u 正链接的所有邻居集合; $N_{(u)}^-$ 为节点 u 负链接的所有邻居集合。该函数反映朋友的嵌入是相似的,而敌人的嵌入是不相似,通过不断减少交叉熵损失 $loss$ 来更新模型参数,经过多次优化,当 $loss$ 趋于稳定时得到节点的最终向量表示。算法 1 是 SNEDA 模型算法。

算法 1 SNEDA 算法流程。

输入:符号网络图 G 、节点特征 \mathbf{h}_i 、节点集合 V ;

输出:节点向量最终表示 \mathbf{Z}_i 。

- ① procedure begin;
- ② for each $V_i \in V$:

得到节点 i 的邻居集合 $\{\phi_0, \phi_1, \dots, \phi_m\}$;
for each $\phi_i \in \{\phi_0, \phi_1, \dots, \phi_m\}$ do :
用式(3)计算权重系数 a_{ij}^ϕ ;
用式(4)计算节点的嵌入 \mathbf{h}_i^ϕ ;
end for
end for

③ 得到每个 motif 下的节点嵌入: $\{\mathbf{h}_i^{\phi_1}, \mathbf{h}_i^{\phi_2}, \dots, \mathbf{h}_i^{\phi_{20}}\}$;

④ 用式(6)和(7)计算权重系数 motif 的重要性;

⑤ 学习到不同 motif 的重要性后,汇聚这些信息得到节点 i 的最终向量表示 : $\mathbf{Z}_i = \sum_{i=1}^m B_{\phi_i} \cdot \mathbf{h}_i^{\phi_m}$;

⑥ 通过式(9)来计算损失值;

⑦ 通过反向传播计算梯度来更新模型参数;

⑧ end procedure.
- 3 实验
- 实验中所有代码使用 Pytorch 编程语言编写,电脑配置为 cpu i7-6700 六核十二线程,内存 12 GB,显卡 AMD R7 2 GB。
- 3.1 数据集描述
- 在实验中采用 4 个真实的社交网络数据集 Bitcoin-Alphs、Bitcoin-Otc、Slashdot 和 Epinions,表 1 是对数据集的统计信息,这些数据都可以从 Stanford Large Network Dataset 网站中下载。
- 表 1 4 个数据集统计信息
Table 1 Statistics of four datasets
- | 数据集 | 节点数量 | 正边数量 | 负边数量 | 正边占比 |
|---------------|--------|---------|---------|-------|
| Bitcoin-Alphs | 3 783 | 22 490 | 1 696 | 0. 93 |
| Bitcoin-Otc | 5 881 | 35 592 | 3 529 | 0. 83 |
| Slashdot | 37 626 | 313 543 | 105 529 | 0. 74 |
| Epinions | 45 003 | 513 851 | 102 180 | 0. 85 |
- Bitcoin-Alphs 和 Bitcoin-Otc 是在 Alpha 和 Otc 的平台上使用比特币进行交易的人际关系网络。
- Slashdot 是一个科技新闻的网站。新闻可以由网站所有的用户提供,用户在这里可以选择自己的朋友和敌人,将朋友看作是正关系,敌人看作是负关系。
- Epinions 是一个消费者评论网站。用户可以通过另外一个用户提供评价产品的质量来决定是否信任该用户。将信任的关系看作正关系,将不信任的关系看作是负关系。
- 3.2 基准方法
- (1)DeepWalk^[16]:针对无符号网络设计了一种基于随机游动的网络嵌入方法。这里将网络中的负向链接当成正向链接处理,将整个符号网络看成无符号网络。

(2)SiNE^[17]:利用符号网络的特性用随机游走的方法对节点采样建模来获得节点嵌入。

(3)SiGAT^[18]:提供了特定的结构模式,利用 GAT 对每个模式下的节点进行学习。

(4)SGCN^[19]:利用结构平衡理论通过图卷积层聚合和传播信息,生成节点嵌入。

(5)SNEA^[20]:利用自注意机制学习节点之间的权重系数,用平衡理论聚合高阶信息对节点进行嵌入。

(6)SDGNN^[21]:基于社会学中的结构平衡理论设计了一种新的信息传播和聚合机制,并且利用了一种平均采样的理论来学习节点嵌入。
- 3.3 链路预测实验
- 通过链路预测实验来验证 SNEDA 模型学习节点嵌入的质量。随机选取 80%的连边作为训练集,这些连边经过 SNEDA 模型会产生节点的向量表示;剩余的 20%的连边作为测试集。将训练集中的节点向量表示作为节点特征,输入到二分类逻辑回归模型中进行实验。将 Accuracy、Macro-F1、F1、AUC 作为评估指标对连边符号预测结果进行验证。这些指标数值越高,表示连边符号预测结果越准确。
- SNEDA 方法与基线方法实验对比结果如表 2 所示,SNEDA 在 4 个数据集上的各项评价指标大多优于基准方法。忽视负链接直接用于表示学习的 DeepWalk 方法性能表现最差,说明负向链接在很大程度上影响符号网络表示的质量;SiNE 首次用社会学理论对符号网络进行建模,取得了不错的实验效果,表明基于社会学理论对符号网络建模的可行性;SiGAT 方法用多头注意力通过聚合一阶邻居的信息学习得到目标节点嵌入;SNEA 基于平衡理论聚合节点的高阶邻居信息,用注意力机制学习节点对之间不同的权重;相较于之前的方法,SNEDA 方法考虑节点之间不同路径的影响,并用双重注意力层捕捉节点和路径的影响。从表 2 实验结果看,链路预测准确率有了明显的提升,实验结果表明基于重要 motif 选性地聚合邻居信息能够提升链路预测的准确率。

表 2 SNEDA 和其他算法在 4 个数据集上的实验结果

算法	Bitcoin-Alpha				Bitcoin-OTC			
	Accuracy	F1	Macro-F1	AUC	Accuracy	F1	Macro-F1	AUC
DeepWalk	0.926 5	0.958 6	0.495 7	0.646 6	0.736 8	0.821 3	0.418 4	0.568 5
SiNE	0.925 8	0.968 9	0.624 9	0.862 8	0.895 6	0.920 4	0.687 9	0.857 1
SGCN	0.810 6	0.899 4	0.663 5	0.848 9	0.901 6	0.930 8	0.703 1	0.860 0
SNEA	0.925 0	0.971 2	0.679 2	0.880 0	0.806 8	0.948 8	0.762 8	0.874 9
SiGAT	0.945 5	0.971 4	0.68 0	0.878 8	0.912 6	0.956 8	0.715 8	0.864 4
SDGNN	0.939 5	0.96 8	0.615 5	0.856 6	0.886 1	0.935 7	0.739 4	0.850 7
SNEDA	0.954 6	0.975 8	0.737 6	0.911 5	0.907 2	0.951 8	0.768 9	0.881 5

算法	Slashdot				Epinions			
	Accuracy	F1	Macro-F1	AUC	Accuracy	F1	Macro-F1	AUC
DeepWalk	0.711 8	0.821 1	0.425 6	0.536 0	0.814 9	0.889 1	0.455 6	0.528 8
SiNE	0.754 8	0.857 9	0.681 7	0.709 9	0.845 1	0.915 6	0.545 5	0.732 8
SGCN	0.807 5	0.876 1	0.732 5	0.841 9	0.873 4	0.926 5	0.731 6	0.858 7
SNEA	0.818 7	0.881 8	0.747 8	0.860 9	0.892 4	0.93 7	0.783 1	0.896 2
SiGAT	0.827 3	0.888 9	0.750 7	0.867 5	0.903 5	0.943 5	0.807 4	0.911 0
SDGNN	0.832 4	0.892 5	0.756 0	0.873 7	0.911 2	0.947 5	0.824 1	0.921 4
SNEDA	0.832 8	0.892 6	0.757 8	0.871 0	0.918 3	0.952 0	0.838 7	0.930 6

3.4 模型超参数分析

SNEDA 模型有 2 个重要参数控制实验的效果,分别是节点向量 d 和路径向量 q 。本节将通过实验分析超参数对 SNEDA 模型性能的影响。选取 Bitcoin-Alpha 作为实验数据集,在分析特定的超参数时,其他参数值设置为默认值。图 5 给出了 SNEDA 模型在不同参数下符号链路预测性能 AUC 值。图 5 (a) 和 5(b) 表示随着训练轮次的增加, $loss$ 值逐渐

减小, AUC 增大, 然后逐渐收敛, 最后趋于稳定。图 5(c) 显示节点向量 d 对实验结果的影响, 可以看到向量维度在 20 时效果达到最优, 随着维度的增加, 实验效果反而有所降低, 这可能由于过拟合导致的。图 5(d) 展示了路径向量 q 对实验性能的影响, 当向量 $q=64$ 时, 效果达到最佳, 随着向量维度的增加, 效果反而降低。




图 5 SNEDA 模型超参数分析

Figure 5 SNEDA model hyperparametric analysis

4 结论

(1) SNEDA 模型由 2 层注意力机制组成, 节点级注意力关注节点层面的信息, 学习节点与邻居之间不同的权重; 路径级注意力捕捉路径层面的信息, 学习不同 motif 之间的重要性。基于重要 motif 选择性地聚合邻居信息, 学习得到节点的低维向量表示。

(2) 通过 SNEDA 模型的学习, 节点的特征信息同时包含邻居信息和路径信息, 使得节点的向量表示更加完整、丰富。与基准方法相比, SNEDA 在链路预测任务中取得了更好的效果, 说明结合路径层

面的信息有助于提高节点嵌入的质量。

在未来工作中, 将考虑采样更高阶的邻居, 比如用随机游走的方式或者用 GraphSAGE 的采样方式, 以此来补全节点向量表示的完整性。

参考文献:

[1] 任磊, 杜一, 马帅, 等. 大数据可视分析综述[J]. 软件学报, 2014, 25(9): 1909-1936.

REN L, DU Y, MA S, et al. Visual analytics towards big data[J]. Journal of Software, 2014, 25(9): 1909-1936.

[2] BORSBOOM D, DESERNO M K, RHEMTULLA M, et al. Network analysis of multivariate data in psychological

- science[EB/OL]. (2021-08-19)[2022-03-16]. <https://doi.org/10.1038/s43586-021-00055-w>.
- [3] ZHOU J Y, LIU L, WEI W Q, et al. Network representation learning: from preprocessing, feature extraction to node embedding[J]. *ACM Computing Surveys*, 2023, 55(2): 1-35.
- [4] CUI P, WANG X, PEI J, et al. A survey on network embedding[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2019, 31(5): 833-852.
- [5] 涂存超, 杨成, 刘知远, 等. 网络表示学习综述[J]. *中国科学: 信息科学*, 2017, 47(8): 980-996.
- TU C C, YANG C, LIU Z Y, et al. Network representation learning: an overview[J]. *Scientia Sinica Informationis*, 2017, 47(8): 980-996.
- [6] 高岳林, 杨钦文, 王晓峰, 等. 新型群体智能优化算法综述[J]. *郑州大学学报(工学版)*, 2022, 43(3): 21-30.
- GAO Y L, YANG Q W, WANG X F, et al. Overview of new swarm intelligent optimization algorithms[J]. *Journal of Zhengzhou University (Engineering Science)*, 2022, 43(3): 21-30.
- [7] 郑建兴, 郭彤彤, 申利华, 等. 基于评论文本情感注意力的推荐方法研究[J]. *郑州大学学报(工学版)*, 2022, 43(2): 44-50, 57.
- ZHENG J X, GUO T T, SHEN L H, et al. Research on recommendation method based on sentimental attention of review text[J]. *Journal of Zhengzhou University (Engineering Science)*, 2022, 43(2): 44-50, 57.
- [8] 程苏琦, 沈华伟, 张国清, 等. 符号网络研究综述[J]. *软件学报*, 2014, 25(1): 1-15.
- CHENG S Q, SHEN H W, ZHANG G Q, et al. Survey of signed network research[J]. *Journal of Software*, 2014, 25(1): 1-15.
- [9] CHEN J, ZHONG M, LI J, et al. Effective deep attributed network representation learning with topology adapted smoothing[J]. *IEEE Transactions on Cybernetics*, 2022, 52(7): 5935-5946.
- [10] 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*, 2021, 32(1): 4-24.
- [11] ZHANG Z W, CUI P, ZHU W W. Deep learning on graphs: a survey[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(1): 249-270.
- [12] HEIDER F. Attitudes and cognitive organization[J]. *The Journal of Psychology*, 1946, 21(1): 107-112.
- [13] 刘苗苗, 扈庆翠, 郭景峰, 等. 符号网络链接预测算法研究综述[J]. *计算机科学*, 2020, 47(2): 21-30.
- LIU M M, HU Q C, GUO J F, et al. Survey of link prediction algorithms in signed networks[J]. *Computer Science*, 2020, 47(2): 21-30.
- [14] ANCHURI P, MAGDON-ISMAIL M. Communities and balance in signed networks: a spectral approach[C]//2012 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining. Piscataway: IEEE, 2012: 235-242.
- [15] LESKOVEC J, HUTTENLOCHER D, KLEINBERG J. Predicting positive and negative links in online social networks[C]//Proceedings of the 19th International Conference on World Wide Web. New York: ACM, 2010: 641-650.
- [16] PEROZZI B, AL-RFOU R, SKIENA S. DeepWalk: online learning of social representations[C]//Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2014: 701-710.
- [17] WANG S H, TANG J L, AGGARWAL C, et al. Signed network embedding in social media[C]//Proceedings of the 2017 SIAM International Conference on Data Mining. Philadelphia: Society for Industrial and Applied Mathematics, 2017: 327-335.
- [18] DERR T, MA Y, TANG J L. Signed graph convolutional networks[C]//2018 IEEE International Conference on Data Mining. Piscataway: IEEE, 2018: 929-934.
- [19] LI Y, TIAN Y, ZHANG J W, et al. Learning signed network embedding via graph attention[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(4): 4772-4779.
- [20] HUANG J J, SHEN H W, HOU L, et al. Signed graph attention networks[C]//Artificial Neural Networks and Machine Learning-ICANN 2019: Workshop and Special Sessions. Cham: Springer, 2019: 566-577.
- [21] HUANG J J, SHEN H W, HOU L, et al. SDGNN: learning node representation for signed directed networks[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(1): 196-203.

Learning Signed Network Node Embedding Via Dual Attention Mechanism

LU Zekun^{1,2}, YU Qiancheng^{1,2}, WANG Xiaofeng¹, LI Xia^{1,2}, WANG Jinyun³

(1. School of Computer Science and Engineering, North Minzu University, Yinchuan 750021, China; 2. Laboratory of Graphics and Images of the State Ethnic Affairs Commission, North Minzu University, Yinchuan 750021, China; 3. School of Business, North Minzu

University, Yinchuan 750021, China)

Abstract: Network node embedding is mapping nodes in a network to a low-dimensional vector representation, so that vector space-based learning methods can be directly applied to handle downstream tasks such as link prediction. Most of the existing network node embedding models were for unsigned networks and could not be directly used to deal with signed networks (usually need to be converted into unsigned networks for processing, thus discarding a lot of valuable information embedded in the positive and negative signs on the edges). A node embedding model (SNEDA) based on graphical neural networks was proposed that could directly deal with symbolic networks. Based on structural balance theory and status theory, the paths between nodes were divided into 20 different motif structures according to the direction and the positive and negative information on the edges. A network propagation model was designed with two levels of attention mechanism, which could capture the contribution and influence of different neighboring nodes to the vector representation of node i by node-level attention mechanism when aggregating the direct neighboring information of node i , and captured the vector representation of different motif to node i by path-level attention when aggregating the second-order and higher-order neighboring information of node i . A two-level attention mechanism was introduced to integrate different contributions and influences at the node level and path level, which could it not only improve the time efficiency of the algorithm but also make the final vector representation of node i more beneficial to improve the prediction accuracy of the downstream link prediction task. Through experiments conducted on four real social network datasets, the SNEDA model improved the AUC and $F1$ metrics by about 3.1% and 1.1%, respectively, compared with the benchmark model, and the results showed that the network representation obtained by the model could improve the accuracy of link prediction.

Keywords: signed network; graph neural network; graph attention networks; network embedding; link prediction

(上接第 21 页)

Urban Flood Disaster Control Based on Green-gray-blue Infrastructure Integration

HUANG Guoru^{1,2}, YANG Ge¹, ZENG Bowei¹, LYU Yongpeng³, REN Xinxin⁴

(1. School of Civil Engineering and Transportation, South China University of Technology, Guangzhou 510640, China; 2. State Key Laboratory of Subtropical Building Science, South China University of Technology, Guangzhou 510640, China; 3. Shanghai Municipal Engineering Design Institute (Group) Co., Ltd., Shanghai 200092, China; 4. Urban Planning & Design Institute of Shenzhen, Shenzhen 518049, China)

Abstract: With the increasingly severe urban waterlogging situation, It was difficult for rainwater management with rainwater pipe network and other grey infrastructures for terminal rapid drainage to solve the problem of urban waterlogging fundamentally. And combining the green, grey and blue infrastructure organically could besides on ensuring that urban floods were effectively solved, systematically solve multi-scale problems such as water pollution and water shortage. Based on the concept of green-grey-blue infrastructure integration, this study reviewed the comprehensive evaluation of urban stormwater system status, the optimization of urban stormwater system, and urban flood control and drainage scheduling. In terms of urban stormwater system assessment, the performance assessment of low impact development system with green infrastructure as the main body and the performance assessment of urban stormwater pipe network system with gray infrastructure as the main body were reviewed. In terms of urban stormwater system optimization, the optimization of design parameters and layout of green infrastructure and the optimization of plan layout and pipe diameter depth of gray infrastructure such as pipe network was reviewed; in terms of urban flood prevention and drainage scheduling, the study of urban flood prevention and drainage was reviewed. In urban flood control and drainage scheduling, the research on urban flood control and drainage scheduling methods and urban flood control and drainage scheduling systems were also reviewed.

Keywords: green-grey-blue infrastructure; layout optimization; surrogate model; flood control and drainage operation