

基于深度学习的异质信息网络表示学习方法综述

王慧妍, 于明鹤, 于戈

引用本文

王慧妍, 于明鹤, 于戈. [基于深度学习的异质信息网络表示学习方法综述](#)[J]. 计算机科学, 2023, 50(5): 103-114.

WANG Huiyan, YU Minghe, YU Ge. [Deep Learning-based Heterogeneous Information Network Representation: A Survey](#) [J]. Computer Science, 2023, 50(5): 103-114.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于多事件语义增强的情感分析](#)

Sentiment Analysis Based on Multi-event Semantic Enhancement

计算机科学, 2023, 50(5): 238-247. <https://doi.org/10.11896/jsjcx.220400256>

[残差学习与循环注意力下的SSD目标检测算法](#)

SSD Object Detection Algorithm with Residual Learning and Cyclic Attention

计算机科学, 2023, 50(5): 170-176. <https://doi.org/10.11896/jsjcx.220400085>

[基于深度学习的智能设备故障诊断研究综述](#)

Review of Intelligent Device Fault Diagnosis Based on Deep Learning

计算机科学, 2023, 50(5): 93-102. <https://doi.org/10.11896/jsjcx.220500197>

[深度学习可解释性综述](#)

Review on Interpretability of Deep Learning

计算机科学, 2023, 50(5): 52-63. <https://doi.org/10.11896/jsjcx.221000044>

[基于异构溯源图学习的APT攻击检测方法](#)

Heterogeneous Provenance Graph Learning Model Based APT Detection

计算机科学, 2023, 50(4): 359-368. <https://doi.org/10.11896/jsjcx.220300040>

基于深度学习的异质信息网络表示学习方法综述

王慧妍¹ 于明鹤² 于戈¹

1 东北大学计算机科学与工程学院 沈阳 110169

2 东北大学软件学院 沈阳 110169

(2001815@stu.neu.edu.cn)

摘要 万物依存而在,现实世界中的实体之间存在着各种不同的关联关系,如人与人之间的关系可以构成社交网络,学者通过共同发表论文、引用文献构成引文网络。同质网络将节点和边抽象为单一类型,但是这会造成大量的信息丢失。为了更程度地保证信息的完整性和丰富性,有研究者提出了异质信息网络的概念,即包含多种类型节点和边的网络模式。将异质信息网络中的拓扑结构和语义信息嵌入到低维向量空间中,下游任务能够利用异质信息网络中的丰富信息进行机器学习或数据挖掘任务。文中总结了近年来基于深度学习模型的异质信息网络表示学习方法的研究成果,同时聚焦两类关键问题——异质信息网络语义自动提取和动态异质信息网络的表示学习方法,列举了异质信息网络表示学习新的应用场景,并展望了异质信息网络的未来发展趋势。

关键词: 异质信息网络;深度学习;表示学习;图神经网络;元路径

中图法分类号 TP391.3

Deep Learning-based Heterogeneous Information Network Representation: A Survey

WANG Huiyan¹, YU Minghe² and YU Ge¹

1 School of Computer Science and Engineering, Northeastern University, Shenyang 110169, China

2 Software College, Northeastern University, Shenyang 110169, China

Abstract Things in the nature connect mutually. There are various associations between them in the real world. For example, social networks can be constructed by the user-user relationships. The article-author relationship can be used to construct a citation network. In homogeneous networks, nodes or edges are all in the same type, resulting in a lot of information loss. In order to ensure the integrity and richness of information to a greater extent, researchers have proposed heterogeneous information network (HIN), a network model containing multiple types of nodes or edges. By embedding the topological structure and semantic information of HIN into a low-dimensional vector space, downstream tasks can utilize the rich information in the HIN for machine learning or data mining. This paper focuses on the HIN-based representation learning tasks, and summarizes the recent representation learning methods of HIN which are based on deep learning models. We focus on two main issues: semantics extraction of HIN and information preserving of dynamic HIN. We also illustrate some new applications of HIN-based representation learning, and propose the future development trend of heterogeneous information networks.

Keywords Heterogeneous information networks, Deep learning, Representation learning, Graph neural network, Meta-path

1 引言

数据和特征决定机器学习的上限,好的数据和特征是算法和模型发挥更大作用的前提条件。早期的机器学习算法中采用特征工程对数据进行人为的特征提取,结果往往是低效且经验主义的。为了解决这个问题,学者们提出了从数据中自动抽取特征的表示学习(Representation Learning),又称为

表征学习、特征嵌入。它通过端到端的模式将数据转换为能更好地表示潜在问题的特征,并实现了特征提取的自动化,减轻了人工提取特征的工作量。表示学习在自然语言处理任务中已经得到大规模的应用,例如,针对不同粒度的文本将表示学习分为了以 Word2Vec^[1] 为代表的词嵌入、句级嵌入和段落级嵌入,不同粒度的文本嵌入可应用于不同的任务。

近年来,异质信息网络(Heterogeneous Information Net-

到稿日期:2022-08-11 返修日期:2022-12-10

基金项目:国家自然科学基金联合基金重点项目(U1811261);国家自然科学基金重点项目(62137001);国家自然科学基金青年科学基金(61902055);中央高校基本科研业务费专项资金(N2117001)

This work was supported by the Key Program of Joint Funds of the National Natural Science Foundation of China(U1811261), Key Program of the National Natural Science Foundation of China(62137001), Young Scientists Fund of the National Natural Science Foundation of China(61902055) and Fundamental Research Funds for the Central Universities of Ministry of Education of China(N2117001).

通信作者:于戈(yuge@mail.neu.edu.cn)

work, HIN)是人工智能领域研究的热点问题之一,在许多场景下都有应用,如社交媒体网络^[2-3]、生物分子模型^[4-6]、网络攻防^[7-8]、计算机视觉^[9]等。相比同质网络,异质信息网络包含多种类型的节点和边,其信息承载量要远远大于包含单一节点和边类型的同构信息网络。然而,如何高效精准地捕捉网络中不同类型的节点与节点、节点与边、边与边之间的内在联系,是一个重要的研究课题。

因为异质信息网络表示学习具有巨大的实际应用价值,所以研究者们各个方向展开了积极的探索,利用学习到的嵌入向量完成推荐^[10-13]、分类^[14-15]、链路预测^[16-18]等下游任务。许多学者从多个侧面对异质信息网络相关的成果进行了总结,如 Shi 等^[19]和 Zhou 等^[20]全面总结了 2020 年以前的异质信息网络嵌入方法,WANG 等^[21]关注基于元路径的异质信息表示学习方法和应用。LIU 等^[22]对异质信息网络在推荐系统中的应用做了全面的综述。

近年来,基于深度学习的机器学习方法取得了突飞猛进的进展,出现了大量基于深度学习的 HIN 表示学习方法。鉴于此,本文重点关注 2020 年以来在各个应用场景下基于深度学习模型的异质信息网络表示学习的新方法和技巧,主要包括横向对比各个模型,充分论述各种方法的优势以及不足;阐述模型在捕捉不同类型的异质信息网络中的方法;论述不同应用场景中异质信息网络的区别和联系。另外,本文关注两个关键问题:异质信息网络中语义信息的自动提取;动态异质

信息网络的表示学习方法。

本文第 2 节介绍了异质信息网络的一些基本定义;第 3 节为本文的重点内容,阐述了几个具有代表性的基于深度学习的异质信息网络表示学习模型;第 4 节阐述了异质信息网络表示学习中两个关键问题的现有解决方案;第 5 节列举了异质信息网络表示学习的新应用;最后总结全文并展望未来。

2 问题概述

早期的网络表示学习用于学习拓扑结构,并使用邻接矩阵的方法建模网络,其中矩阵的行/列代表网络中的节点,矩阵中的元素 0/1 表示节点对之间不存在/存在连接关系。这种方式仅能表示系统中简单的拓扑结构关系,难以表示网络隐含的语义信息。随着对表示精确度要求的提升,能够区分节点、边的类型,包含丰富语义信息的异质信息网络应运而生。异质信息网络表示学习是一种图结构向量化的方法,它将不同类型的节点和边表示为低维空间中的实值向量形式,学习得到的向量可以作为机器学习和深度学习模型的输入。图 1 以引文网络为例,给出了异质信息网络表示学习的过程。首先,构造包含教师(T)、学生(S)和文献(P)3 种节点类型的信息网络,通过师生(T-S)、引用(P-P)和写作(T-P/S-P)连接不同类型的对象。然后,通过基于元路径的随机游走、网络结构分解或深度学习模型将不同类型的节点映射到同一个表示空间中,为下游任务提供节点向量表示。




图 1 异质信息网络表示学习框架

Fig. 1 HIN representation learning framework

2.1 定义


定义 1(异质信息网络) 异质信息网络^[23]可以表示为有向图 $G = \{V, E, D_V, D_E\}$, 其中 V 为节点集合、 E 为边集合、 D_V 为节点类型集合、 D_E 为边类型集合, 节点类型映射为 $V \rightarrow D_V$, 边类型映射为 $E \rightarrow D_E$, 并且满足 $|D_V| + |D_E| > 2$ 。表 1 列出了异质信息网络中常用的符号。

定义 2(网络模式, Network Schema) 将异质信息网络 G 中的节点和边映射为相应的类别, 以节点类型集合为新的图顶点集, 将关系集合作为边集合, 形成了网络模式^[24], 记为 $S = (D_V, D_E)$ 。网络模式定义了节点类型约束以及节点间允许定义的边类型。图 2(a)给出了一个电影异质信息网络, 包含 4 种类型的节点 Actor(A), Director(D), Movie(M) 和

Genres(G), 以及它们之间的连接关系。图 2(b)给出了图 2(a)对应的网络模式。

表 1 异质信息网络表示学习常用符号
Table 1 Common symbols in HIN representation learning

符号	意义
G	异质信息网络
V	网络中节点集合
E	网络中边集合
D_V	节点类型集合
D_E	边类型集合
P	元路径
W	权重矩阵
x_v^A	类型为 A 的节点 $v \in V$ 的初始特征
N_v^P	元路径 P 的节点 $v \in V$ 的邻居集合
h_v	节点 $v \in V$ 的嵌入向量



(a) A movie HIN

(b) Network schema of movie HIN

图 2 电影异质信息网络

Fig. 2 MovieHIN

定义 3(元路径) 元路径^[24]是定义在两个给定节点之间,用于表示其语义关系的节点类型和边类型的序列,表示为 $P = D_{V_1} \xrightarrow{D_{E_1}} D_{V_2} \xrightarrow{D_{E_2}} \dots \xrightarrow{D_{E_{l-1}}} D_{V_l}$ 。图 3 定义了电影网络上的 3 条元路径,如 AA 路径反映了两个演员之间的合作关系,AMA 表示两个演员共同出演同一部作品,AMDMA 表示两个演员参与过同一导演的电影。




图 3 元路径

Fig. 3 Meta-path

定义 4(元图) 给定一个网络模式 $S = (D_V, D_E)$,对应的元图^[24]定义为一个有向无环图 $M_G = (N, M, n_s, n_t)$, N 和 M 分别代表元图中包含的节点和边类型子集, $N \subseteq D_V, M \subseteq D_E, n_s$ 代表源节点(入度为 0), n_t 代表目标节点(出度为 0)。元图表示源节点和目标节点之间的复杂语义关系,元路径是元图的特例。图 4 给出了一个电影异质信息网络中的元图。




图 4 元图

Fig. 4 Meta-graph

定义 5(复合元图) 复合元图^[25]是一种可扩展的语义结构,不需要用户预先定义,可以有效地提取和整合不同类型的元路径和元图,学习到保留复杂多样语义关系的网络嵌入向量。给定一个异质信息网络 $G = (V, E, D_V, D_E)$,其网络模式 $S = (D_V, D_E)$,选择源节点和目标节点类型后,异质信息网络的复合元图 C_G 可以按如下方式构造。 C_G 的高度定义为 H ,源节点类型放置在第一层。 $h = 2, 3, \dots, H$ 层的节点类型由第 $h-1$ 层的网络模式 S 生成,相邻两层之间由有向链接(Directed Links)关联。重复这个过程即可生成 G 的复合元图 C_G 。图 5 给出了电影异质信息网络中的复合元图。




图 5 复合元图

Fig. 5 Composite meta-graph

2.2 HIN 表示学习的分类

异质信息网络表示学习方法可以分为 3 类。

- (1) 基于随机游走的方法,以 DeepWalk^[26] 为代表的基于随机游走的方法依据专家指定的元路径或元图^[27]在异质信息网络中随机游走采样获得节点序列^[28],优化节点相似度。
- (2) 基于分解的方法^[29],将异质信息网络分解为多个同质网络,可以利用 n-hop 邻居关系^[30],或者采用丢弃与源节点类型不同的节点的方式。这样既保留了 HIN 中的节点关联信息,又降低了节点映射到统一特征空间的难度。
- (3) 基于深度学习模型的方法,利用深度学习模型学习从网络到低维空间的非线性映射函数。

本文重点研究的是基于深度学习模型的异质信息网络表示学习方法。基于端到端的深度学习模型的异质信息网络表示学习方法不再局限于利用元路径保留语义信息,能够高效汇聚节点邻域信息,从而学习到更准确的表示。图 6 给出了本文所涉及到的异质信息网络表示方法。

3 基于深度学习模型的 HIN 表示学习

本节总结了 HIN 表示学习的深度学习方法。将现有基于深度学习模型的 HIN 表示学习方法划分为三大类:基于图神经网络(Graph Neural Network, GNN)的 HIN 表示学习、基于生成式对抗网络(Generative Adversarial Networks, GAN)的 HIN 表示学习和基于图自编码器(Graph Auto-Encoders, GAE)的 HIN 表示学习。一般来说, GNN 是半监督的,因为它们利用节点属性和标签为特定任务端到端地训练模型参数,而 GAN 和 GAE 是无监督方法。




Fig. 6 Comparison of HIN representation methods

3.1 基于图神经网络的 HIN 表示学习

近年来,图神经网络^[31]方法被广泛应用于图表示学习任务中,但大多数模型都被应用于同质网络中。它的主要思想是通过聚合局部邻域信息来更新中心节点的特征,如图 7 所示。传统的基于 GNN 的方法不能直接应用于异质图,因为它们忽略了异质图的两个基本特征——异质性和语义关系复杂性,因此基于图神经网络的异质信息网络表示学习得到了越来越多的关注,并在一系列应用上取得了优越的效果。




图 7 GNN 节点嵌入更新

Fig. 7 Node embedding update in GNN

3.1.1 异质信息网络的子网络划分

由于异质信息网络中的不同类型的节点和边增加了表示学习的复杂性,最直接的方法是将网络拆解为几个有相似主题的子图。也就是说将整个异质信息网络划分为几个只存在一种节点或边类型的子网络,再对每一个子网络应用高效灵活的图卷积。下文介绍了几种此类方法。

GAHNE 模型^[32]在子图获得节点表示后,设计了具有 3 个候选聚合器的通道聚合模块,将 3 个不同单一类型子网生成的语义表示融合为全局特征,可将全局信息融合到最终嵌入向量中。

HGCN 模型^[33]将原网络划分为包含两种节点类型和一种边类型的子网络。对每个子网络设计一个卷积滤波器,保留不同类型的节点语义。再设计一种基于初始模块(Inception Module)的关系特征学习方法,来捕捉异质信息网络中的多关系层次结构。

Yan 等^[34]设计了基于异质信息网络的推荐模型 HicRec,该模型从用户对物品(Item)的兴趣出发将网络划分为用户网络和物品网络,采用 GCN 从元路径中提取信息,既

考虑了图的结构,又考虑了用户/物品的特征,在相应的元路径中进一步学习到更强大的用户和物品嵌入表示。

在现有的算法中,HGSL^[35]首次尝试异质信息网络的结构学习,联合学习异构信息网络结构和 GNN 参数。在图结构学习部分,以关系为划分依据对每个关系子图分别进行学习。在每个生成的关系子图中,生成 3 种类型的候选图,即特征相似图(Feature Similarity Graph)、特征传播图(Feature Propagation Graph)和语义图(Semantic Graph),用于挖掘异构节点特征和图结构中的复杂关联。学习到的图进一步融合为异构信息网络并反馈给 GNN,对图结构学习参数和 GNN 参数进行联合优化,以达到分类目标。

3.1.2 应用注意力机制的 GNN

一般来说,模型的参数量与模型的表达能力和模型存储的信息量呈正相关,但这也带来了信息过载问题。在基于 GNN 的异质信息网络表示学习任务中引入注意力机制可以使模型聚焦于关键消息的传递^[36],降低模型对其他信息的关注度,从而提高表示学习的效率和准确性。

Wang 等^[37]利用节点属性,设计了一种基于图卷积网络的 HANE 模型,引入注意机制对邻域内不同类型的节点赋予不同的重要性。邻居节点 v_j 对节点 v_i 的重要性分数定义为:

$$S_{i,j} = score(\vec{f}_i, \vec{f}_j) = g(\vec{f}_i)g(\vec{f}_j)^T \tag{1}$$

其中, $\vec{f}_i$ 表示节点 v_i 的属性向量, $g(\cdot)$ 表示向量映射函数。Zhao 等^[38]将异质信息网络应用于机器人检测问题中,提出了一种基于权重的节点嵌入方法,该方法学习节点之间的交互行为,并将其集成到相似度图中进行图卷积操作。这种方法能够更全面地刻画机器人特征,并且能够学习到机器人之间的区别特征。

为了减小元路径的信息损失,Fu 等^[39]提出了 MAGNN 模型,将属性信息映射到同一隐藏层的向量空间中,进而利用注意力机制分别采用元路径内聚合和元路径间聚合,以便充分利用元路径内部的语义信息和多个元路径的聚合信息。给定一条元路径 $P, P(v,u)$ 为连接目标节点 v 和基于元路径 P 的邻居节点 u 的元路径实例。元路径内聚合计算不同类型节点对目标节点的表示做出的贡献。 e_{vu}^P 表示元路径实例 $P(v,u)$ 中邻居节点 $u \in N_v^P$ 对目标节点 v 的重要性。

$$e_{vu}^p = \text{LeakyRelu}(\mathbf{a}_p^\top \cdot [\mathbf{h}_v' \parallel \mathbf{h}_{p(v,u)}]) \quad (2)$$

其中, $\mathbf{a}_p$ 是元路径 P 的参数化注意力向量, $\parallel$ 表示向量拼接运算符。元路径间聚合使用注意力机制融合节点 v 的跨元路径节点向量。

$$e_{P_i} = \mathbf{q}_A^\top \cdot \mathbf{s}_{P_i} \quad (3)$$

其中, $\mathbf{q}_A$ 是节点类型 A 的参数化注意力向量, $\mathbf{s}_{P_i}$ 表示平均所有节点变换后的元数据路径 P_i 特定节点 v 的向量。然而, MAGNN 在元路径级别聚合信息, 忽略了局部结构的整体性, 这会导致聚合过程中的信息丢失。

现有异质信息网络中元路径中的语义信息通常被简化为节点对之间的连接路径或者关系信息, 为了深度挖掘元路径中丰富的语义信息, Wang 等^[40]提出了一种解耦注意力网络, 它从异质信息网络的不同方面学习分离的节点表示。首先将物品的属性投影到不同的子空间中, 再使用注意力机制学习邻居在不同子空间下的权重, 聚合每个元关系 (Meta-relation) 组内的语义信息。

3.1.3 应用多视图学习的 GNN

异质信息网络中节点之间的语义关系是多种多样的, 仅从一个视图捕捉信息会造成数据缺失。因此, 研究者们提出了多视图融合的代表学习方法, 其中“多视图”描述的是同一个异质信息网络的不同切入点。

GATNE^[41]将节点嵌入分为基本嵌入 (Base Embedding) 和边嵌入 (Edge Embedding) 两个视图, 同时它也是一个带属性异质信息网络 (Attributed Heterogeneous Information Networks, AHIN) 的嵌入模型。基本嵌入是为了分离网络的拓扑特征, 而边嵌入则是为了学习某一类型的节点与不同类型的边连接下的嵌入向量, 最后将两个视图下节点的嵌入利用自注意力机制融合。然而, 对于每个单一的网络视图, GATNE 忽略了不同类型节点之间的多重关系, 导致无法有效地学习不同类型节点之间的关系。

Wang 等^[42]提出了一种具有协同对比学习的异质图神经网络 HeCo。HeCo 使用视图掩码机制, 在网络模式和元路径两个视图下, 基于 GNN 邻居聚合方法得到每个节点的初步表示。再利用自监督对比学习机制使两个视图互相补充和监督, 进一步提高了对比性能。

3.2 基于生成式对抗网络的 HIN 表示学习

在文本和图像数据的表示学习中, 生成式对抗网络已经被广泛使用。它依赖于对抗性学习的思想, 使鉴别器和生成器相互竞争, 学习底层的数据分布。具体来说, 给定一个节点, 生成器尝试生成与给定节点相关联的伪样本并将其提供给判别器, 而判别器则尝试更新其参数来将伪样本与真样本分离。在这个重复的过程中, 判别器会迫使生成器产生更好的伪样本, 而判别器也会增强其判断能力, 最终生成器和判别器都得到了正强化。GraphGAN^[43]和 GANE^[44]将生成对抗网络应用于同质网络表示学习, 它的主要思想是学习节点之间存在边的概率, 通过优化节点和边的分布确定节点的向量表示。MG-HIF^[45]在异质社会关系网络中模拟连接模式分布来生成给定用户的潜在朋友。为了进一步提升复杂语义信息的解析性能, 研究者们从语义和网络结构角度构造生成式对抗网络。

3.2.1 对抗性解耦表示学习

从语义的角度来说, 节点的向量表示对于下游任务来说可能是高度耦合的, 例如, 某作者曾在多个学科领域发表过出版物, 这可能会使预测他/她的研究兴趣变得困难。为了解决这个问题, Wang 等^[46]提出了基于解耦表示的 HEAD 模型, 作者认为节点存在固有特征和特有特征, 固有特征对于元路径种类具有不变性, 而特有特征强依赖于元路径语义。HEAD 模型分为 3 个部分: 1) 初始节点嵌入; 2) 元路径解耦; 3) 对抗学习器。如图 8 所示, 图 8(a) 中生成不同元路径中的节点表示作为模型的初始输入。图 8(b) 中将不同元路径的初始嵌入输入同一编码器, 固定特征编码被转换为具有方差的随机变量。而特有特征从嵌入搜索层中生成。将两者通过生成器重构节点表示。图 8(c) 中利用元路径鉴别器进一步提纯与元路径无关的固有特征, 使用包含语义分类器和真/假分类器的语义鉴别器, 将生成更依赖于元路径的特有特征。该方法与最优秀的基线方法相比, 在分类精度上最高提升了 15%, 充分证明了 HEAD 的固有特征和特有特征分离的有效性。DR.hin^[47]在不同视图下设计了对抗性解耦器, 以分离隐藏在 HIN 嵌入中的不同信息因素, 用于大规模安卓恶意软件检测。




图 8 HEAD 框架

Fig. 8 HEAD framework

3.2.2 多视图对抗生成网络

从网络结构的角度来看,Zhao 等提出了一个在多视图异质信息网络中应用生成对抗网络的模型 MV-ACM^[48]。作者认为网络结构越相似,同一节点在不同视图中的语义表示就越相似,每个视图表示一个关系空间。生成器中计算同一节点在不同视图中的语义表示相似性来生成互补视图,鉴别器通过拓扑结构相似度判断视图是否互补,最后通过聚合融合视图的邻居信息更新节点表示。多视图的对抗学习使生成的样本更加接近于真实数据。

3.3 基于自编码器的 HIN 表示学习

自编码器^[49]是一个比较典型的基于重构损失学习节点嵌入的表示学习方法,通常采用无监督或半监督学习模式。它由两部分组成,将原始输入编码为潜在表示的编码器和从潜在表示中恢复数据的解码器。给定节点 i 的初始向量 $\mathbf{x}_i$,编码器将其映射到低维空间中:

$$\mathbf{z}_i = \sigma(\mathbf{W}_{\text{pos}}^{\text{EN}} \mathbf{x}_i + \mathbf{b}_{\text{pos}}^{\text{EN}})$$
 (4)

其中, σ 表示 sigmoid 函数, $\mathbf{W}_{\text{pos}}^{\text{EN}}$ 和 $\mathbf{b}_{\text{pos}}^{\text{EN}}$ 分别代表编码器的权重向量和偏置向量, pos 表示位置信息。解码器产生 $\mathbf{x}_i$ 的重构:

$$\hat{\mathbf{x}}_i = \sigma(\mathbf{W}_{\text{pos}}^{\text{DE}} \mathbf{z}_i + \mathbf{b}_{\text{pos}}^{\text{DE}})$$
 (5)

其中, $\mathbf{W}_{\text{pos}}^{\text{DE}}$ 和 $\mathbf{b}_{\text{pos}}^{\text{DE}}$ 分别代表解码器的权重向量和偏置向量,学习过程描述为最小化原始输入 $\mathbf{x}_i$ 和重构 $\hat{\mathbf{x}}_i$ 表示之间的差异。

$$\min \sum_i^N \text{dist}(\mathbf{x}_i, \hat{\mathbf{x}}_i)$$
 (6)

3.3.1 节点相似性保持

HIRL 模型^[50]将传统的基于元路径的随机游走策略和自编码器结合,引入一种被称为路径表示的中间表示来细化表示过程,并且集成节点之间的高阶相似度、语义信息和全局结构信息。Zhang 等^[25]提出了能捕捉更多语义信息的复合

元图。该模型将传统的深度自编码器应用于稀疏异质信息网络中,通过多层编码和解码器的非线性映射,学习网络中的不同阶的相似度。Zhang 等^[51]提出的 PAHINE 在编码层将相互邻近感知机制与策略性深度自编码器相结合,以更好地保持潜在表示空间中节点之间的相似性。

3.3.2 多模态编码

Zhu 等提出的 LRHNE 模型^[52]设计了一种交叉对齐的变分图自动编码器,在部分先验知识的指导下将图的结构和潜在关系特征融合到嵌入中。

用于推荐任务的 MvDGAE 模型^[53]将多方面语义提取为用户和产品的多视图,对于每个视图分别提出了一个独立的图编码器网络来学习基于元路径的语义嵌入。多个视图的嵌入被聚合成互补的表示形式。在训练过程中,在编码器中随机删除一些 user-item 交互视图,同时强制解码器使用有限的视图来恢复完整视图。需要注意的是,解码器的重构目标是多视图的 user-user 和 user-item 关系图,而不是原始输入图,这使得元路径中相似 user 或 item 的特征更加紧密。最后,采用贝叶斯任务权重学习器来自动平衡多视图重构目标。

3.4 小结

本节分别介绍了基于图神经网络、生成对抗网络和自编码器的异质信息网络表示学习方法。

基于图神经网络的异质信息网络表示学习方法是当前异质信息网络表示学习的主流方法,它主要依靠相邻节点之间的消息传递机制聚合邻居节点的信息,可以单独学习节点表示,也可以结合下游任务完成端到端式的学习。通过增加不同层次的注意力模块可以更有效地捕捉节点之间的语义关系。表 2 列出了基于图神经网络的特征嵌入方法。

表 2 GNN 特征聚合方法汇总

Table 2 Summary of GNN feature aggregation

模型	聚合器	更新器
GAHNE	$\mathbf{n}_v = \text{Attention/Gate/Pooling}(\mathbf{z}_u \mid u \in N(v))$	$\mathbf{Z}_v^{l+1} = \text{ReLU}(\mathbf{W} \mathbf{n}_v + \mathbf{b})$
HGCN	$g_{\Theta} \otimes G_{v,u} \chi_{v,u} = \sum_{K=1}^K P_{v,u}^K \chi_{v,u} \otimes \Theta_k^{v,u}$ $\mathbf{N} = r(g_{\Theta} \otimes G_{\text{ts}} \chi_{\text{ts}}^v, \cdots, g_{\Theta} \otimes G_{\text{ts}_{m_v}} \chi_{\text{ts}_{m_v}}^v)$	$\mathbf{H} = \mathbf{N} \Theta$
HicRec	User: $\mathbf{N} = \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{A}^* \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{X}$ Item: $\mathbf{N} = \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{I}^* \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{X}$	$\mathbf{Z}_v^{l+1} = \text{ReLU}(\mathbf{N} \mathbf{W})$
HGSL	$\mathbf{N} = \tilde{\mathbf{D}}^{-\frac{1}{2}} (\mathbf{A}' + \mathbf{I}) \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{X}$	$\mathbf{H} = \mathbf{N} \Theta$
HANE	$a_{v,u} = g(\vec{f}_v) g(\vec{f}_u)^T$ $a'_{v,u} = \frac{\exp a_{v,u}}{\sum_{u \in N(v)} \exp a_{v,u}}$	$\mathbf{Z}_v^{l+1} = \text{ReLU}(g(\vec{f}_v) \oplus \sum_{u \in N(v)} a'_{v,u} g(\vec{f}_u))$
MAGNN	$a_{v,u} = \text{LeakyRelu}(\mathbf{a}_P^T \cdot [\mathbf{h}_v' \parallel \mathbf{h}_{P(v,u)}])$ $a'_{v,u} = \frac{\exp a_{v,u}}{\sum_{u \in N(v)} \exp a_{v,u}} \mathbf{n}_v = \sigma(\sum_{u \in N(v)} a'_{v,u} \mathbf{h}_{P(v,u)})$	$\mathbf{Z}_v^{l+1} = \mathbf{n}_v$
GATNE	$\mathbf{n}_v = \text{Mean/Pooling}(\mathbf{z}_u \mid u \in N(v))$ Node-level: $a_{v,u} = \text{LeakyRelu}(\mathbf{a}_P^T \cdot [\mathbf{h}_v' \parallel \mathbf{h}_{P(v,u)}])$ $a'_{v,u} = \frac{\exp a_{v,u}}{\sum_{u \in N(v)} \exp a_{v,u}} \mathbf{n}_v = \sigma(\sum_{u \in N(v)} a'_{v,u} \mathbf{h}_{P(v,u)})$	$\mathbf{Z}_v^{l+1} = \mathbf{n}_v$
HeCo	Type-level: $w_{\Phi_m} = \sum_{v \in V} \mathbf{a}^T \cdot \tanh(\mathbf{W} \cdot \mathbf{h}^{\Phi_m} + \mathbf{b})$ $\beta_{\Phi_m} = \frac{\exp w_{\Phi_m}}{\sum_{u \in N(v)} \exp w_{\Phi_m}} \mathbf{n}_v = \sum_{u \in N(v)} \beta_{\Phi_m} \mathbf{h}_v^{\Phi_m}$	$\mathbf{Z}_v^{l+1} = \mathbf{n}_v$

基于生成对抗网络的异质信息网络表示学习方法利用编码器增加训练样本,配合解码器的对抗学习可以使嵌入表示更稳定,有利于持续地提高模型的表示能力。

基于自编码器的异质信息网络表示学习方法可以有效地缓解节点特征中的噪声带来的影响。将不同阶数的近似值作为自编码器的输入可以将异质信息网络表示学习问题转化为数据降维问题,通过减小重构损失来达到特征嵌入的目的。

4 异质信息网络表示中的关键问题

HIN 中节点间依赖的多样性和关系的复杂性是异质信息网络表示学习的一项重要挑战,有效的异质网络语义提取算法生成的节点嵌入会大幅提升下游任务的性能。另外,网络的演化过程也给语义关系的提取带来了困难。下文将讨论如何有效地进行异质信息网络的语义信息自动提取,以及如何解决动态网络的表示问题。


4.1 语义信息自动提取

现有的异质信息网络表示学习方法大都依赖任务相关的元路径/元图^[54]来捕捉网络的语义信息,元路径/元图通常由领域专家给出,或基于筛选规则进行初始元路径选择^[55],但这对于一个新任务或缺乏经验的研究人员来说很难完成。为了高效提取语义信息,提高模型的可解释性,研究者探索了

自动元路径选择和基于关系的语义提取两种方法进行异质信息网络语义信息提取。

4.1.1 自动元路径选择

为了灵活地选择有效的元路径,并选择任务相关度最高的元路径,Yang 等^[56]提出了一种自动学习元路径重要性的可解释异质图卷积网络 ie-HGCN 模型来学习网络中对象的表示。图 9(a)给出了节点类型数为 4 的 DBLP 数据集上 ie-HGCN 的总体框架,模型共包含 5 层,每层包含 4 个块。实线表示特定关系映射,虚线表示自关系映射。在分类任务中,softmax 函数可以作用于最后一层输出的节点表示以获得预测分数。在每个块中,执行 3 个关键步骤:投影、对象级聚合和类别级聚合。图 9(b)中,以 P 为目标节点类型为例。投影层利用 W 矩阵将不同类型的相邻对象投影到一个公共语义空间中,使不同类型的特征具有可比性。其次使用邻接矩阵权重 A 完成对象级聚合。最后利用 a 矩阵进行类别级聚合,融合来自不同类别邻居对象的表示。该方法可以自动评估 HIN 中所有可能的元路径,从而发现最有用的元路径。这也给模型带来了良好的可解释性。Megnn 模型^[57]利用可以生成多种卷积图探索不同的局部结构的异构卷积模块来自动提取有利的元路径,并且额外引入了一个单位矩阵,用于学习长度可变的元路径。



(a) Instance of ie-HGCN on DBLP

(b) Calculation flow in a P block

图 9 ie-HGCN 框架

Fig. 9 ie-HGCN framework

Hwang 等^[58]提出了一种新的基于元路径的自监督辅助学习方法,将预测元路径作为辅助任务来学习主要任务链路预测和节点分类。除了主要学习者网络之外,额外给出了一个提示网络,提示网络为学习者网络信息纠正答案,以增强学习者网络的表示能力。

4.1.2 基于关系的语义提取

从关系中提取语义信息的方法根据邻域信息直接抽取语义信息,无需定义元路径。PGRA 模型^[59]和 HetSANN 模型^[60]在节点消息聚合时聚合来自原始边的信息。由于节点的异质性,聚合之前需要将每种类型的节点和关系分别投影到各自的特征空间中,应用带有注意力机制的图神经网络对投影领域的多关系信息进行聚合。PGRA 模型用于捕捉一阶、二阶邻域信息。而 HetSANN 模型设计了类型注意力层来替代传统 GNN 中的卷积层,可以叠加多层来捕获高阶的

相似度信息,并在每一层定义不同实体空间投影到相同低维空间的方法,用于异构节点之间的交互。

4.2 动态异质信息网络的表示学习方法

相比静态网络,动态异质信息网络强调了网络中节点和边出现的顺序和时间,可以分为等间隔采样的快照网络和记录网络中所有变化的连续时间网络。在异构和动态环境中,预测网络中将来出现的节点和边将会对特征信息带来的影响是一个具有挑战性的任务。

4.2.1 增量式训练

Peng 等^[61]提出的 Lime 模型利用不同关系类型来约束学习网络嵌入误差。首先学习静态网络的节点嵌入,然后应用增量学习来更新已更改网络的节点嵌入。模型主体部分为,在作者提出的新型长方体结构模式中,应用遍历网络拓扑关系的 RNN 组件来学习静态网络中的嵌入。接着改变网络

结构,通过增量学习方法校准动态网络嵌入,最小化目标函数误差。基于元路径的动态 HIN 嵌入模型 DyHNE^[14],其表示学习过程如图 10 所示。在 t 时刻基于元路径 APA, APCPA 和 APTPA 提取元路径增强邻接矩阵,并将其与权重融合,获得增强邻接矩阵 W^t ,得到保留基于元路径的




图 10 DyHNE 框架
Fig. 10 DyHNE framework

4.2.2 编码时序信息

Jiang 等提出了一个可将动态引文网络的引用信号转换为引用时间序列的模型 HINTS^[62],它是一个新颖的端到端深度学习框架。HINTS 不需要将论文发表后前几年的引用情况作为前导值进行预测,而是通过编码论文发表前的历史信息,从发表日期预测新论文的被引时间序列,来解决冷启动问题。然后将这些嵌入转换为可以在发表后立即预测引用的正式模型的参数。Zhang 等提出了一种将时间信息整合到 HIN 中的多视图动态 HIN 嵌入框架 MDHNE^[63],它可以有效地保留来自不同视图的隐式关系的演化模式,如图 11 所示。其将 HIN 转换为对应于不同视图的一系列同构网络,应用递归神经网络将复杂网络结构和节点间语义关系的演变模式整合到潜在的嵌入空间中,因此当 HIN 随时间演变时,可以学习和更新来自多个视图的节点向量。Xie 等^[64]提出了可以在网络发展时更新嵌入的方法 DyHINE。该方法包含两个关键设计——动态时间序列嵌入模块和在线实时更新模块。动态时间序列嵌入模块采用分层注意机制聚合相邻特征和时间随机游走,以捕获动态交互作用;在线实时更新模块通过动态运算符高效更新计算出的嵌入。THINE^[65]则结合 Hawkes 过程来模拟时序网络演化,并结合注意力机制和元路径来保留 HIN 中的结构和语义信息。

4.3 小结

本节介绍了异质信息网络表示学习中的两个关键问题:无需元路径的表示学习方法和动态异质信息网络的表示学习。无需人工设置元路径的方法降低了模型的主观性,可以更全面地学习到全局的语义信息。由于元路径作为异质信息网络的重要定义,大部分研究者都会采用元路径,因此研究成果相对较少,可研究的空间依然很大。

一、二阶节点嵌入 U^t 。在 $t+1$ 时刻, HIN 增加了 3 个节点和 5 条边, HIN 中结构和语义的变化用融合元路径增广邻接矩阵的扰动 ΔW 表示。基于矩阵扰动理论, DyHNE 得到变化部分的嵌入 ΔU , 进而得到 $t+1$ 时刻的网络嵌入 $U^{t+1} = \Delta U + U^t$ 。

近年来已经陆续有很多关于动态异质信息网络建模的研究成果。增量式训练往往以静态图快照为基本研究对象,编码时序信息可以通过 Hawkes 过程等方法将时间信息灵活地嵌入到关系中。考虑时间变化的捕获网络连续演化模式能够得到明显的性能提升。




图 11 多视图动态网络
Fig. 11 Multi-view dynamic network

5 异质信息网络表示学习的新型应用

异质信息网络表示学习为海量、动态的异质数据的管理和探索提供了一种更有效的方式。目前异质信息网络表示学习方法已经扩展到各个领域,如智慧交通、异常行为检测、自然语言处理等。

5.1 智慧交通

Hong 等^[66]和 Luo 等^[67]同时在智能道路交通领域的预计到达时间问题上构建了异质信息网络。Hong 提出的 HetETA 模型将交通网络转化为一个由路线图和车辆轨迹图组成的多关系网络,车辆轨迹可以视为一种网络模式。他们还认为时间数据也存在一致性,将时间分为近期时段、日时段和周时段 3 类,并将路线图和车辆轨迹图分别送入图卷积

网络中嵌入空间异质信息。该方法适用于稀疏的大规模网络。Luo 等^[67]侧重于研究网约车客户实时响应预测。在动态异质信息网络中利用多层神经网络模型学习用户历史行为和周围环境对当前事件的影响,学习事件的有效表示。该框架已经被应用于滴滴平台的实际应用中。

5.2 异常检测

在数据挖掘中,异常检测的任务是识别不匹配预期模式或数据集中其他项目、事件或观测值。由于网络空间的安全面临着严重的威胁,通常异常项目会转变成银行欺诈、结构缺陷、医疗问题、文本错误等类型的问题。对于异常检测问题的传统解决方案是对每个节点进行细微的特征工程,如用户画像、信用历史等业务相关的行为,再将现实问题转化为分类问题。传统解决方案很少能充分利用真实业务场景下存在的丰富的交互行为。研究者对垃圾邮件检测^[68-69]、欺诈者检测^[70-71]、金融违规检测^[72]、套现欺诈^[73]交互行为构建了异质信息网络,利用元路径连接的邻居的结构信息、属性信息增强节点的特征表示,并设计了基于图神经网络的嵌入算法,有效地预测了异常行为发生的概率。

5.3 自然语言处理

深度学习已经成为应对各种自然语言处理任务的主导方法,输入文本通常被表示为序列化的 tokens,但图结构的形式往往可以对许多 NLP 问题进行更好的表达。因此,有必要针对 NLP 任务来开发基于图的深度学习技术。现有的基于异质信息网络的 NLP 任务有抽取式文档生成^[74-75]、社区问答^[76]、姓名消歧^[77-78]等。由词节点和句子节点构成的文档异质信息网络包含了词和句子之间的冗余信息,并可以通过消息传递提供句子之间的标签依赖关系。与序列式输入文本相比,异质信息网络下的自然语言处理任务在训练和推理效率方面有了质的飞跃。

6 总结及未来发展

异质信息网络中具有很多能描述个体特征的异质性信息,更加逼近于真实世界中实体及实体间的关系,因此异质信息网络表示学习在近几年成为了网络表示学习的热点内容。

虽然目前的算法都对异质信息网络中异质性信息的保留进行了较为有效的尝试,但是大部分算法只利用了单一的异质信息,如常用的文本信息,而视频、音频信息等还未得到有效利用,并且大部分算法都无法达到工业级应用,距离实际应用还有很长一段距离。因此,基于深度学习的异质网络表示学习的研究还具有很大的发展空间,在未来工作中可以从以下几个方面着手研究。

(1)捕捉异质信息网络的结构变化

绝大多数现实世界的对象交互本质上是异质和动态的,包含许多不同类型的节点和边,而且可能随着时间的推移而发生巨大变化。动态性和异质性使得推理网络结构极具挑战性。不幸的是,现有的方法在模拟现实生活中的动态网络方面是不够的,因为它们要么对给定的随机过程有强烈的假设,要么无法捕获网络结构的异质性,并且它们都需要大量的计算资源。设计能够适应在线更新网络结构的动态异质信息网络表示学习模型,使表示学习模型不再仅仅停留在实验室研究中,更具有实际应用价值。

(2)边嵌入方法

常见的异质信息网络嵌入输入为节点嵌入,表示学习方法给图中相似节点赋予相似的向量表示。而边嵌入可以有效预测关系的存在,与节点之间的相似度不同,边通常表示成对节点的关系,并且包含方向性,在链路预测、知识图实体/关系预测应用中有着重要作用,值得更加深入的研究。

(3)HIN 开发框架的构建

开发框架可以有效地提高代码的可扩展性、复用性、协同性和开发效率等。随着图神经网络的兴起,图开源工具包为从事图相关的人员提供了极大的便利。目前应用较广的图计算平台有 Deep Graph Library(DGL)和 Pytorch Geometric(PyG)。此外,学术界也陆续开源了部分框架,如提供 networkx 到 PyG 接口的 DeepSNAP、清华大学出品的图神经网络复现工具 CogDL 和面向研究图结构信息模式相关深度学习任务的 DiveIntoGraph 等。这些工具包都不能直接应用于节点和边类别不唯一的异质信息网络。

现有两个适用于异质图神经网络的开源工具包,一是由北京邮电大学 DMGroup 发布的 OpenHINE,二是由北京邮电大学 GAMMA Lab 开发的 OpenHGNN。OpenHINE 统一了异质信息网络嵌入模型的输入/输出/测评接口,并且修订和复现了许多流行模型的实现,包括 DHNE, HAN, HERec, HIN2vec 等。OpenHGNN 则以深度学习框架 PyTorch 与图神经网络框架 DGL 为底层框架,设计了异质图神经网络训练流程的基本架构,集成了异质图神经网络 SOTA 模型,使研究者们能够轻松地将模型扩展到新数据集中,以便进行训练和评估。持续建设适用于深度学习方法的异质信息网络表示学习的算法包,集成更多数据集、选取评估工具、构建完善的测试平台可以促进异质信息网络表示学习的发展。

(4)HIN 嵌入的迁移学习

不同应用场景下的两个异质信息网络(源和目标)可能完全不重叠,但它们在结构上有共性,如产品-评价者网络^[79](源网络)中包含信任和不信任关系,可以用其信息帮助预测移动网络(目标网络)中用户之间的社会关系(家庭、朋友、同事),如图 12 所示。源网络通常很容易收集关系信息,而目标网络很难获得关系信息,利用源网络可用的关系预测目标网络中的关系可以解决关系可用性不平衡问题,实现跨异质信息网络的迁移学习。

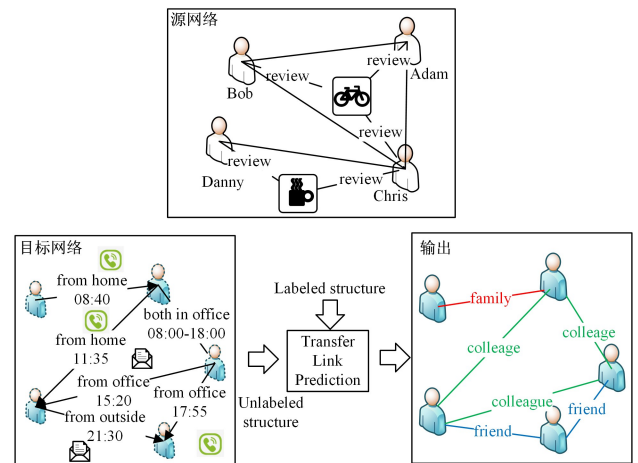


图 12 HIN 嵌入的迁移学习

Fig. 12 Transfer learning in HIN embedding

(5)大规模异质信息网络训练效率的提升

真实世界的异质信息网络规模都非常大,例如 Facebook 的社交网络图有数十亿级的节点和万亿级的边。大规模的网络结构增加了数据存储和模型训练压力。如何利用已有的硬件设备设计合理的存储策略提高存取效率,如何控制模型训练中的计算资源和内存空间都将是大规模异质信息网络发展的挑战。网络结构上的并发计算是异质信息网络表示学习未来的发展方向之一。然而与序列数据不同的是,网络结构中的节点具有较强的依赖性和顺序关联性,要获取一个节点的需要聚集其邻节点和边的信息,实现并发计算需要将整个网络分解为多个互不相交的子任务。

参 考 文 献

[1] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality [C]//Proceedings of the 26th International Conference on Neural Information Processing Systems. 2013;3111-3119.

[2] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems(NeurIPS). 2017;1025-1035.

[3] WANG D, CUI P, ZHU W. Structural Deep Network Embedding[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016;1225-1234.

[4] ZENG X, ZHU S, LU W, et al. Target identification among known drugs by deep learning from heterogeneous networks [J]. Chemical Science, 2020, 11(7):1775-1797.

[5] ATHANASIOS T, STJIN V D, ANTON J E, et al. Network visualization and analysis of gene expression data using biolayout express(3D) [J]. Nature Protocols, 2009, 4(10):1535-1550.

[6] YANG X, WANG W, MA J L, et al. BioNet: a large-scale and heterogeneous biological network model for interaction prediction with graph convolution [J]. Briefings in Bioinformatics, 2022, 23(1):bbab491.

[7] GAO Y L, LI X Y, HAO P, et al. HinCTI: A Cyber Threat Intelligence Modeling and Identification System Based on Heterogeneous Information Network [J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(2):708-722.

[8] HOU S, YE Y, SONG Y, et al. HinDroid: An Intelligent Android Malware Detection System Based on Structured Heterogeneous Information Network[C]//Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2017;1507-1515.

[9] WU S Q, DONG Y H, WANG X, et al. Learning attribute network algorithm based on high-order similarity[J]. Telecommunication Science, 2020, 36(12):13.

[10] ZHANG J, SHI X, ZHAO S, et al. STAR-GCN: stacked and reconstructed graph convolutional networks for recommender systems[C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence. 2019;4264-4270.

[11] GONG J, WANG S, WANG J, et al. Attentional Graph Convolutional Networks for Knowledge Concept Recommendation in MOOCs in a Heterogeneous View[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Develop-

ment in Information Retrieval. 2020;79-88.

[12] CHEN C, MA W, ZHANG M, et al. Graph Heterogeneous Multi-Relational Recommendation [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2021;3959-3966.

[13] LU Y, FANG Y, SHI C. Meta-learning on Heterogeneous Information Networks for Cold-start Recommendation[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2020;1563-1573.

[14] WANG X, LU Y, SHI C, et al. Dynamic Heterogeneous Information Network Embedding with Meta-path based Proximity [J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(3):1117-1132.

[15] ZHANG Y, XIONG Y, KONG X, et al. Deep Collective Classification in Heterogeneous Information Networks[C] // Proceedings of the 2018 World Wide Web Conference. 2018;399-408.

[16] LIU M, LIU J, CHEN Y, et al. AHNG: Representation Learning on Attributed Heterogeneous Network [J]. Information Fusion, 2019, 50:221-230.

[17] XU S, YANG C, SHI C, et al. Topic-aware Heterogeneous Graph Neural Network for Link Prediction[C]//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. 2021;2261-2270.

[18] WANG H, ZHANG F, HOU M, et al. SHINE: Signed Heterogeneous Information Network Embedding for Sentiment Link Prediction[C]//Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. 2018;592-600.

[19] SHI C, WANG R J, WANG X. Survey on Heterogeneous Information Networks[J]. Journal of Software, 2022, 33(2):598-621.

[20] ZHOU L H, WANG J L, WANG L Z. Heterogeneous Information Network Representation Learning: A Survey [J]. Chinese Journal of Computers, 2022, 45(1):160-189.

[21] WANG X, BO D, SHI C, et al. A Survey on Heterogeneous Graph Embedding: Methods, Techniques, Applications and Sources [J]. IEEE Transactions on Big Data, 2023, 9(2):415-436.

[22] LIU J W, SHI C, YANG C, et al. Heterogeneous Information Network based Recommender Systems: a survey[J]. Journal of Cyber Security, 2021, 6(5):1-16.

[23] SUN Y, HAN J. Mining heterogeneous information networks: a structural analysis approach [J]. SIGKDD Explor Newsl, 2013, 14(2):20-28.

[24] HUANG Z, ZHENG Y, CHENG R, et al. Meta Structure: Computing Relevance in Large Heterogeneous Information Networks [C] // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016;1595-1604.

[25] ZHANG Z, HUANG J, TAN Q, et al. CMG2Vec: A composite meta-graph based heterogeneous information network embedding approach [J]. Knowledge-Based Systems, 2021, 216:106661. 1-106661. 14.

[26] 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. 2014;701-710.

[27] JIANG H, SONG Y, WANG C, et al. Semi-supervised learning over heterogeneous information networks by ensemble of meta-

- graph guided random walks[C]//Proceedings of the 26th International Joint Conference on Artificial Intelligence. 2017:1944-1950.
- [28] GAO X, CHEN J, ZHAN Z, et al. Learning heterogeneous information network embeddings via relational triplet network [J]. *Neurocomputing*, 2020, 412: 31-41.
- [29] XU L, WEI X, CAO J, et al. Embedding of Embedding (EOE): Joint Embedding for Coupled Heterogeneous Networks[C]//Proceedings of the Tenth ACM International Conference on Web Search and Data Mining. 2017:741-749.
- [30] TANG J, QU M, MEI Q. PTE: Predictive Text Embedding through Large-scale Heterogeneous Text Networks[C]//Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2015:1165-1174.
- [31] SCARSELLI F, GORI M, TSOI A C, et al. The Graph Neural Network Model [J]. *IEEE Transactions on Neural Networks*, 2009, 20(1): 61-80.
- [32] LI X, WEN L, QIAN C, et al. GAHNE: Graph-Aggregated Heterogeneous Network Embedding [C]//proceedings of the 2020 IEEE 32nd International Conference on Tools with Artificial Intelligence (ICTAI). 2020:1012-1019.
- [33] ZHU Z, FAN X, CHU X, et al. HGCN: A Heterogeneous Graph Convolutional Network-Based Deep Learning Model Toward Collective Classification [C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2020:1161-1171.
- [34] YAN D, XIE W, ZHANG Y. Heterogeneous information network-based interest composition with graph neural network for recommendation [J]. *Applied Intelligence*, 2022, 52(10): 11199-11213.
- [35] ZHAO J, WANG X, SHI C, et al. Heterogeneous Graph Structure Learning for Graph Neural Networks [C]//Proceedings of the 35th AAAI Conference on Artificial Intelligence. 2021, 35: 4697-4705.
- [36] QIN X, SHEIKH N, REINWALD B, et al. Relation-aware Graph Attention Model with Adaptive Self-adversarial Training [C]//Proceedings of the 35th AAAI Conference on Artificial Intelligence. 2021:9368-9376.
- [37] WANG Y, DUAN Z, LIAO B, et al. Heterogeneous Attributed Network Embedding with Graph Convolutional Networks [C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2019:10061-10062.
- [38] ZHAO J, LIU X, YAN Q, et al. Multi-attributed heterogeneous graph convolutional network for bot detection [J]. *Information Sciences*, 2020, 537: 380-393.
- [39] FU X, ZHANG J, MENG Z, et al. MAGNN: Metapath Aggregated Graph Neural Network for Heterogeneous Graph Embedding [C]//Proceedings of The Web Conference (WWW). 2020: 2331-2341.
- [40] TANG S, LEI Y, WANG S. DisenHAN: Disentangled Heterogeneous Graph Attention Network for Recommendation [C]//The 29th ACM International Conference on Information and Knowledge Management (CIKM '20). 2020.
- [41] CEN Y, ZOU X, ZHANG J, et al. Representation Learning for Attributed Multiplex Heterogeneous Network [C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019:1358-1368.
- [42] WANG X, LIU N, HAN H, et al. Self-supervised Heterogeneous Graph Neural Network with Co-contrastive Learning [C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. 2021:1726-1736.
- [43] WANG H W, WANG J, WANG J L, et al. GraphGAN: Graph Representation Learning with Generative Adversarial Nets [C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2018:2508-2515.
- [44] HONG H, LI X, WANG M. GANE: A Generative Adversarial Network Embedding [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 31(7): 2325-2335.
- [45] ZHANG C, WANG Y, ZHU L, et al. Multi-Graph Heterogeneous Interaction Fusion for Social Recommendation [J]. *ACM Transactions Information Systems*, 2022, 40(2): 28:21-28:26.
- [46] WANG R J, SHI C, ZHAO T Y, et al. Heterogeneous Information Network Embedding with Adversarial Disentangler [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(2): 1581-1593.
- [47] HOU S, FAN Y, JU M, et al. Disentangled Representation Learning in Heterogeneous Information Network for Large-scale Android Malware Detection in the COVID-19 Era and Beyond [C]//the 35th AAAI Conference on Artificial Intelligence. 2021:7754-7761.
- [48] ZHAO K, BAI T, WU B, et al. Deep Adversarial Completion for Sparse Heterogeneous Information Network Embedding [C]//Proceedings of The Web Conference (WWW). 2020:508-518.
- [49] HINTON G E, ZEMEL R S. Autoencoders, minimum description length and Helmholtz free energy [C]//Proceedings of the 6th International Conference on Neural Information Processing Systems. 1993:3-10.
- [50] YU B, HU J, XIE Y, et al. Rich heterogeneous information preserving network representation learning [J]. *Pattern Recognit*, 2020, 108: 107564.
- [51] ZHANG C, WANG G, YU B, et al. Proximity-aware heterogeneous information network embedding [J]. *Knowledge-Based Systems*, 2020, 193: 105468. 1-105468. 13.
- [52] ZHU Z, FAN X, CHU X, et al. LRHNE: A Latent-Relation Enhanced Embedding Method for Heterogeneous Information Networks [C]//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. 2020: 1923-1932.
- [53] ZHENG J, MA Q, GU H, et al. Multi-view Denoising Graph Auto-Encoders on Heterogeneous Information Networks for Cold-start Recommendation [C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. 2021:2338-2348.
- [54] XIE F, ZHENG A, CHEN L, et al. Attentive Meta-graph Embedding for item Recommendation in heterogeneous information networks-ScienceDirect [J]. *Knowledge-Based Systems*, 2020, 211: 106524. 1-106524. 13.
- [55] ZHANG X, CHEN L. mSHINE: A Multiple-meta-paths Simultaneous Learning Framework for Heterogeneous Information Network Embedding [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(7): 3391-3404.
- [56] YANG Y, GUAN Z, LI J, et al. Interpretable and Efficient Heterogeneous Graph Convolutional Network [J]. *IEEE Transac-*

tions on Knowledge and Data Engineering, 2023, 35(2):1637-1650.

[57] CHANG Y, CHEN C, HU W, et al. Megnn: Meta-path extracted graph neural network for heterogeneous graph representation learning [J]. Knowledge-Based Systems, 2022, 235: 107611. 1-107611. 11.

[58] HWANG D, PARK J, KWON S, et al. Self-supervised Auxiliary Learning with Meta-paths for Heterogeneous Graphs[C]// Advances in Neural Information Processing Systems(NeurIPS). 2020:10294-10305.

[59] CHAIRATANAKUL N, LIU X, MURATA T. PGRA: Projected graph relation-feature attention network for heterogeneous information network embedding [J]. Information Sciences, 2021, 570(1): 769-794.

[60] HONG H, GUO H, LIN Y, et al. An Attention-based Graph Neural Network for Heterogeneous Structural Learning[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2020:4132-4139.

[61] PENG H, YANG R, WANG Z, et al. LIME: Low-Cost and Incremental Learning for Dynamic Heterogeneous Information Networks [J]. IEEE Transactions on Computers, 2022, 71(3): 628-642.

[62] JIANG S, KOCH B, SUN Y. HINTS: Citation Time Series Prediction for New Publications via Dynamic Heterogeneous Information Network Embedding[C]// Proceedings of the Web Conference(WWW). 2021:3158-3167.

[63] ZHANG Z, HUANG J, TAN Q. Multi-view Dynamic Heterogeneous Information Network Embedding [J]. The Computer Journal, 2022, 65(8): 2016-2033.

[64] XIE Y, OU Z, CHEN L, et al. Learning and Updating Node Embedding on Dynamic Heterogeneous Information Network[C]// Proceedings of the 14th ACM International Conference on Web Search and Data Mining(WSDM). 2021:184-192.

[65] HUANG H, SHI R, ZHOU W, et al. Temporal Heterogeneous Information Network Embedding[C]// Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence. 2021:1470-1476.

[66] HONG H, LIN Y, YANG X, et al. HetETA: Heterogeneous Information Network Embedding for Estimating Time of Arrival [C]// Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2020: 2444-2454.

[67] LUO W, ZHANG H, YANG X, et al. Dynamic Heterogeneous Graph Neural Network for Real-time Event Prediction[C]// Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2020:3213-3223.

[68] GUO Z W, TANG L G, GUO T, et al. Deep Graph neural network-based spammer detection under the perspective of heterogeneous cyberspace [J]. Future Generation Computer Systems, 2021, 117: 205-218.

[69] SUN X, YIN H, LIU B, et al. Heterogeneous Hypergraph Embedding for Graph Classification [C]// proceedings of the Proceedings of the 14th ACM International Conference on Web Search and Data Mining(WSDM). 2021:725-733.

[70] SHEHNEPOOR S, TOGNERI R, LIU W, et al. HIN-RNN: A Graph Representation Learning Neural Network for Fraudster Group Detection With No Handcrafted Features [J]. arXiv: 2015. 11602, 2021.

[71] LIU Z, DOU Y, YU P S, et al. Alleviating the Inconsistency Problem of Applying Graph Neural Network to Fraud Detection [C]// Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2020:1569-1572.

[72] ZHONG Q, LIU Y, AO X, et al. Financial Defaulter Detection on Online Credit Payment via Multi-view Attributed Heterogeneous Information Network[C]// Proceedings of The Web Conference(WWW). 2020:785-795.

[73] HU B, ZHANG Z, SHI C, et al. Cash-Out User Detection Based on Attributed Heterogeneous Information Network with a Hierarchical Attention Mechanism [C]// Proceedings of the THIRTY-THIRD AAAI Conference on Artificial Intelligence. 2019: 946-953.

[74] JIA R, CAO Y, TANG H, et al. Neural Extractive Summarization with Hierarchical Attentive Heterogeneous Graph Network [C]// proceedings of the Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing(EMNLP). 2020:3622-3631.

[75] XU R, LIU T, LI L, et al. Document-level Event Extraction via Heterogeneous Graph-based Interaction Model with a Tracker [C]// Annual Meeting of the Association for Computational Linguistics. 2021:3533-3546.

[76] WU Y, ZHAO S, GUO R. A novel community answer matching approach based on phrase fusion heterogeneous information network [J]. Information Processing & Management, 2021, 58(1): 102408.

[77] SUN Q, PENG H, LI J, et al. Pairwise Learning for Name Disambiguation in Large-Scale Heterogeneous Academic Networks [C]// Proceedings of the 2020 IEEE International Conference on Data Mining(ICDM). 2020:511-520.

[78] WANG H, WANG R, WEN C, et al. Author Name Disambiguation on Heterogeneous Information Network with Adversarial Representation Learning[C]// THIRTY-FOURTH AAAI Conference on Artificial Intelligence. 2020:238-235.

[79] TANG J, LOU T, KLEINBERG J, et al. Transfer Learning to Infer Social Ties across Heterogeneous Networks [J]. ACM Transactions on Information System, 2016, 34(2): 1-43.



WANG Huiyan, born in 1998, master, is a student member of China Computer Federation. Her main research interests include machine learning and deep learning.



YU Ge, born in 1962, professor, Ph.D supervisor, is a member of China Computer Federation. His main research interests include distributed system and big data management.