

异构信息网络的注意力感知多通道图卷积评分预测模型

周明强, 代开浪, 吴全旺, 朱庆生

引用本文

周明强, 代开浪, 吴全旺, 朱庆生. 异构信息网络的注意力感知多通道图卷积评分预测模型[J]. 计算机科学, 2023, 50(3): 129-138.

ZHOU Mingqiang, DAI Kailang, WU Quanwang, ZHU Qingsheng. [Attention-aware Multi-channel Graph Convolutional Rating Prediction Model for Heterogeneous Information Networks](#) [J]. Computer Science, 2023, 50(3): 129-138.

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)

[文档增强型知识库问答](#)

Document-enhanced Question Answering over Knowledge-Bases

计算机科学, 2023, 50(3): 266-275. <https://doi.org/10.11896/jsjcx.220300022>

[细粒度语义知识图谱增强的中文OOV词嵌入学习](#)

Fine-grained Semantic Knowledge Graph Enhanced Chinese OOV Word Embedding Learning

计算机科学, 2023, 50(3): 72-82. <https://doi.org/10.11896/jsjcx.220700249>

[基于图神经网络的多信息优化实体对齐模型](#)

Multi-information Optimized Entity Alignment Model Based on Graph Neural Network

计算机科学, 2023, 50(3): 34-41. <https://doi.org/10.11896/jsjcx.220700242>

[SS-GCN:情感增强和句法增强的方面级情感分析模型](#)

SS-GCN: Aspect-based Sentiment Analysis Model with Affective Enhancement and Syntactic Enhancement

计算机科学, 2023, 50(3): 3-11. <https://doi.org/10.11896/jsjcx.220700238>

[基于会话式机器阅读理解模型的事件抽取方法](#)

Event Extraction Method Based on Conversational Machine Reading Comprehension Model

计算机科学, 2023, 50(2): 275-284. <https://doi.org/10.11896/jsjcx.220400271>

异构信息网络的注意力感知多通道图卷积评分预测模型

周明强 代开浪 吴全旺 朱庆生

重庆大学计算机学院 重庆 400044

摘要 异构信息网络(Heterogeneous Information Network, HIN)包含了丰富的语义信息,利用其进行评分预测已成为缓解推荐系统数据稀疏性问题的一个重要途径。然而,传统采用元路径来提取 HIN 语义信息的方法忽略了元路径中的评分信息,从而导致元路径无法精确捕获用户和推荐项目之间的语义相似性,同时也未能良好区分不同元路径的重要性。为了解决这两个问题,首先提出了一种带有评分限制的元路径以获取更准确的 HIN 语义信息,利用这些信息构建用户和项目多层网络;然后结合图卷积网络和注意力机制设计了一个用于评分预测的神经网络,通过多通道图卷积有效地表示了 HIN 的多种语义信息,采用注意力机制区分不同元路径的重要性,弥补了传统方法的不足;最后融合了用户和项目的属性信息,进一步提高了评分预测的准确性。在 Douban Book 和 Yelp 数据集上的实验结果表明所提模型明显优于对比的基线模型,尤其在数据稀疏的情况下,均方根误差比基线模型最多减少了 50%,从而验证了所提模型的优越性。

关键词: 评分预测;元路径;异构信息网络;注意力机制;图卷积网络

中图法分类号 TP183

Attention-aware Multi-channel Graph Convolutional Rating Prediction Model for Heterogeneous Information Networks

ZHOU Mingqiang, DAI Kailang, WU Quanwang and ZHU Qingsheng

College of Computer Science, Chongqing University, Chongqing 400044, China

Abstract Heterogeneous information network(HIN) contains rich semantic information, and the use of HIN for rating prediction has become an important way to alleviate the problem of data sparsity in recommender systems. However, the traditional methods using meta-paths to extract HIN semantic information ignore the rating information on the edges, making the meta-paths unable to accurately capture the semantic similarity between users and recommended items. And these methods also fail to distinguish the importance of different meta-paths. To address the two problems, rating constrained meta-path is proposed to obtain more accurate HIN semantic information which is then used to construct multi-layer homogeneous networks for users and items. Then, a neural network for rating prediction is designed by combining graph convolutional network and attention mechanism, which effectively represents various semantic information in HIN through multi-channel graph convolutional networks and distinguishes the importance of different meta-paths by using an attentional fusion function. Furthermore, the proposed model also integrates the attribute information of users and items to improve the accuracy of rating prediction. Experimental results on Douban Book and Yelp datasets show that the proposed model is significantly better than the comparative baseline models, especially in the case of sparse data, and the root mean square error reduces by up to 50% compared to the baseline model, thus verifying the superiority of the proposed model.

Keywords Rating prediction, Meta-path, Heterogeneous information network, Attention mechanism, Graph convolutional network

1 引言

随着互联网信息的指数级增长,海量信息使得互联网用户越来越难找到自己感兴趣的项目(如歌曲、书籍和电影等)。

推荐系统旨在为用户推荐可能感兴趣的项目,正被越来越多的在线平台(如亚马逊和淘宝等)所使用。在推荐系统中,用户对项目的喜好程度通常以评分的形式体现。评分预测的目的是预测用户对未评价过项目的评分,以便推荐系统根据

到稿日期:2022-03-01 返修日期:2022-09-27

基金项目:国家自然科学基金(61702060);重庆市自然科学基金(cstc2020jcyj-msxmX0137)

This work was supported by the National Natural Science Foundation of China(61702060) and Natural Science Foundation of Chongqing (cstc2020jcyj-msxmX0137).

通信作者:周明强(zmqmail@cqu.edu.cn)

预测的评分为用户进行推荐。因此,评分预测的准确度直接决定了推荐系统的性能。

近年来,协同过滤(Collaborative Filtering, CF)^[1-3]因其出色的速度和健壮性成为了评分预测任务中的主流算法之一,其基本思想是利用用户和项目的历史评分数据来预测未知的评分数据。然而,现实推荐系统中,大多数用户通常只对少数项目评分从而导致评分数据十分稀少,这被称为数据稀疏性问题。数据稀疏性问题给传统的 CF 算法带来了巨大的挑战。研究表明,辅助数据(如社交网络、用户相关属性和项目相关属性)有助于发现用户的潜在偏好,缓解数据稀疏性问题^[4-5]。但是,如何将这些异构的辅助数据与评分预测模型进行融合进而提高预测精度是一个难题。

异构信息网络(HIN)^[6]将异构信息组织成网络中不同类型的节点和连边,能够对复杂和异构的数据进行良好的建模,是评分预测领域中一个有潜力的方向。图 1 给出了一个面向书籍推荐的 HIN,其中,用户、用户的社交关系、书籍、书籍的类型和作者被抽象为 HIN 中不同类型的节点和边,节点之间的连边代表节点之间的关系(例如,作者与书籍之间的连边表示创作或被创作关系,用户和书籍之间的连边表示评分或被评分的关系),评分数据(1,2,⋯,5)被抽象为用户类型和书籍类型的节点连边上的权重。元路径^[7]通过在 HIN 中定义不同的连接模式来捕获节点间不同类型的关系(也被称为语义信息)。HIN 的拓扑结构中蕴含了丰富的语义信息,这些信息在一定程度上能够弥补推荐系统中评分数据不足的缺陷,缓解数据稀疏性问题。如图 1 中的元路径“User-Book-User”(UBU)捕获了用户之间阅读记录的关系(例如 UBU 的一个连接实例“User1-Book1-User2”表示 User1 和 User2 都阅读过 Book1);同理,元路径“Book-Type-Book”(BTB)能够捕获书籍之间的类型关系。现有的基于 HIN 的评分预测算法^[8-11]大多利用元路径从 HIN 中获取与用户和项目相关的语义信息,并取得了一定的效果,但仍有以下两个主要问题需要考虑。

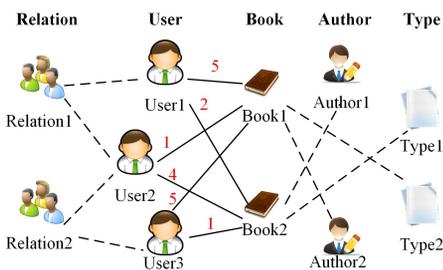


图 1 异构网络示例

Fig. 1 Example of HIN

问题 1 如何使元路径捕获推荐场景中准确的语义信息。例如,图 1 中的元路径 UBU 反映了用户之间阅读记录的关系。然而,这个语义信息可能对书籍推荐没有帮助。虽然图 1 中的 User1 和 User2 都阅读过 Book1 和 Book2,但对他们的评分相差很大(对 Book1 的评分分别是 5 和 1,对 Book2 的评分分别是 2 和 4),这表明 User1 和 User2 的阅读偏好可能并不相似。实际上,User1 和 User3 更可能有相似

的阅读偏好,因为他们都读过 Book1 和 Book2,且对两本书都给出了相似的评分。传统的元路径没有考虑评分的影响,不能区分上述情况中 User1 分别与 User2 和 User3 之间关系,而这种区别对于评分预测任务来说是十分重要的。因此,考虑元路径中的评分信息十分必要。然而如何将评分信息整合到传统的元路径中仍是一个亟待解决的问题。

问题 2 如何区分多个元路径之间的重要性。为了尽可能多地提取有利于评分预测的语义信息,通常需要设计多个元路径。不同的元路径包含不同的语义信息,这些语义信息对每个用户和项目的影晌通常是个性化的。例如,如果图 1 中的 User1 更关注书籍的作者,而 User2 更关注书籍的类型,那么元路径“Book-Author-Book”(BAB)可能对 User1 的推荐更重要,而元路径“Book-Type-Book”(BTB)对 User2 的推荐更重要。目前大多数基于元路径的评分预测模型不能很好地为每个用户和项目区分不同元路径的影响,这可能导致评分预测的精确度降低。

针对第一个问题,本文对传统的元路径进行改进,提出了一种带有评分约束的元路径,从 HIN 中提取更加准确的语义信息。针对第二个问题,本文设计了一个结合图卷积网络和注意力机制的神经网络。综合上述工作,本文提出了一个异构信息网络的注意力感知图卷积评分预测模型(HAGRP)。HAGRP 模型首先提出具有评分约束的元路径来提取语义信息,并利用这些信息构建用户和项目的多层网络;其次在构建的多层网络上进行多通道的图卷积,为用户和项目生成多个子嵌入表示;再次设计了基于注意力机制的融合函数进行融合,从而得到完整的语义嵌入表示;然后将其与用户及项目的属性融合,得到最终嵌入表示;最后通过设计的评分预测器得到预测评分。在两个真实数据集上的实验结果表明,HAGRP 明显优于基线模型,与此同时,即使是在数据比较稀疏的情况下,HAGRP 也能保持稳定的性能。

2 相关工作

评分预测任务近年来受到了相当广泛的关注。矩阵分解(Matrix Factorization, MF)^[12]是最经典和常用的评分预测模型之一,它的核心思想是将用户和项目分别嵌入到低维的向量空间,然后以用户向量和项目向量的内积作为预测的评分。由于 MF 只利用了用户和项目的历史评分数据,因此无法有效解决数据稀疏性问题。为了解决数据稀疏性问题,研究者尝试将辅助数据(如用户相关属性、项目相关属性和社交网络等)融入评分预测模型,并获得了一定程度的进步。Forsati 等^[13]设计了一个基于 MF 的推荐模型,该模型融合用户之间的信任和信任关系来提升预测效果。Liang 等^[14]提出了 CoFactor 模型,该模型结合 MF 模型和词嵌入模型,构建了项目共现网络,生成了用户嵌入和项目嵌入,在一定程度上缓解了数据稀疏性问题。Cao 等^[15]将用户生成的列表作为辅助数据,设计了基于嵌入的因子分解模型,该模型将嵌入算法融入传统的因子分解模型中,提高了模型的性能。Xu 等^[4]将用户的兴趣和社会关系作为辅助数据融合到 MF 算法中,提出了 UIS-MF 推荐模型。Luo 等^[16]考虑到用户标签和项目的

属性特征,提出了 co-SVD 模型。Zhang 等^[17]将用户标签、社会关系和地理影响融入矩阵分解模型。Nguyen 等^[18]提出了一种新的软评分推荐系统,该系统利用社区上下文信息预测未知评分。

上述方法中,大多数只能将某一类型(或某几类固定类型)的信息融合到评分预测模型中,与它们相比,基于 HIN 的评分预测模型能够灵活地融合更多复杂且异构的辅助信息。

在语义信息表达方面,HIN 也越来越受到推荐领域研究人员的关注。自 Sun 等^[19]提出元路径的概念以来,元路径便成为了提取 HIN 语义信息的主流方式。Yu 等^[20]设计了一种基于元路径学习用户和项目向量化特征的方法,实现将基于元路径的图结构信息向量化。Liang 等^[21]设计了一种基于 MF 模型的推荐方法,它利用基于元路径的相似性来度量用户之间与项目之间的相似性。Dai 等^[22]利用元图从 HIN 中提取语义信息,并结合 MF 与因子分解机(Factorization, FM)对提取的信息进行融合。Shi 等^[9]设计了一种基于元路径的推荐模型嵌入方法 HERec,可以融合多种类型的嵌入信息来提高推荐效果。Yan 等^[8]提出了基于 HIN 的网络嵌入和注意力感知元路径的推荐模型 AMERec,它在 HERec 的基础上引入了边的权重和基于深度神经网络的评分器。由此可见,通过元路径从 HIN 中提取语义信息的方式可以应用于推荐模型并提高推荐效果。

在语义信息向量化表示方面,图卷积神经网络技术^[23]取得了快速的发展,它能够利用邻居节点之间的信息共享和传递,有效地捕获图结构数据的特征。Hamilton 等^[24]提出了 Graph SAGE 图卷积网络模型,该模型学习聚合邻居节点的函数表示,而不是直接学习每个节点的嵌入表示,并且对节点的邻居进行了采样,使之具备良好的扩展性,能够被应用到大规模的图上。Ying 等^[25]提出了 Pin SAGE 图卷积网络模型,该模型结合了高效的随机游走和图卷积来生成包含图结构和节点特征信息的节点嵌入表示。同时,注意力机制^[26]被广泛应用于自然语言处理、图像识别及语音识别等各种不同类型的深度学习任务中,其优势在于能够从众多信息中选择出对当前任务目标更关键的信息。本文将利用注意力机制为每个用户和项目区分不同元路径所提取的语义信息的重要性。

3 相关定义

本节给出了一些 HIN 相关概念以及推荐系统中基于 HIN 的评分预测问题的定义。

定义 1(异构信息网络) 信息网络定义为 $G=(V, E, T_V, T_E, f_V, f_E)$,其中 V 为节点集合, E 为边集合, T_V 和 T_E 分别表示节点类型和边类型的集合, $f_V: V \rightarrow T_V$ 表示节点到节点类型的映射函数, $f_E: E \rightarrow T_E$ 表示边到边类型的映射函数。如果 $|T_V| + |T_E| > 2$,则该网络为异构信息网络,否则为同构信息网络。对于一个 HIN,当 $|T_V| = 1$ 时,其被称为多层网络。

示例 1 图 2(a)给出了一个异构信息网络,其中包含了 3 种节点类型(User, Book 和 Author)和 2 种边类型(User-Book, Author-Book)。

定义 2(元路径) 给定一个异构信息网络 $G=(V, E, T_V, T_E, f_V, f_E)$,元路径 \mathcal{P} 表示为 $T_{V_1} \xrightarrow{T_{E_1}} T_{V_2} \xrightarrow{T_{E_2}} \dots \xrightarrow{T_{E_{l-1}}} T_{V_l}$ (通常缩写为 $T_{V_1} T_{V_2} \dots T_{V_l}$),即 T_{V_1} 型节点和 T_{V_l} 型节点通过一系列关系组合连接。符合元路径 \mathcal{P} 定义的连接序列 $v_1 v_2 \dots v_l$ 被称为元路径 \mathcal{P} 的一个实例,其中 $v_x (1 \leq x \leq l)$ 表示 \mathcal{P} 的一个具体节点,且满足 $f_V(v_x) = T_{V_x}$ 。 v_1 和 v_l 被称为基于元路径 \mathcal{P} 的共现节点对。

示例 2 图 2(b)上方的方框显示的是元路径“User-Book-User”(UBU)的实例,实例两端的节点表示读过同一本书的两个用户。图 2(c)上方的方框展示了基于 UBU 的共现节点对。

定义 3(具有评分限制的元路径) 给定一条元路径 $\mathcal{P} = T_{V_1} T_{V_2} \dots T_{V_l}$,其中包含用户-项目连边的数目为 δ 。 \mathcal{P}^* 为 \mathcal{P} 所对应的具有评分约束的元路径, \mathcal{P}^* 可以表示为 $\mathcal{P}^* = (\mathcal{P}, \theta)$,其中 θ 决定了限制的程度。当 $\delta \geq 2$ 时, \mathcal{P}^* 对应的每个实例都要满足条件 $\max(\{|r_i - r_j|, 1 \leq i, j \leq \delta\}) \leq \theta$,其中 r_i 和 r_j 分别表示元路径 \mathcal{P} 中第 i 和第 j 条用户-项目连边上的评分, θ 表示一个路径实例上允许的最大评分差。注意,当 $\delta \leq 1$ 时, \mathcal{P}^* 与 \mathcal{P} 的意义相同。为了简便,下文将具有评分约束的元路径称为 RC(Rating Constrained)-元路径。

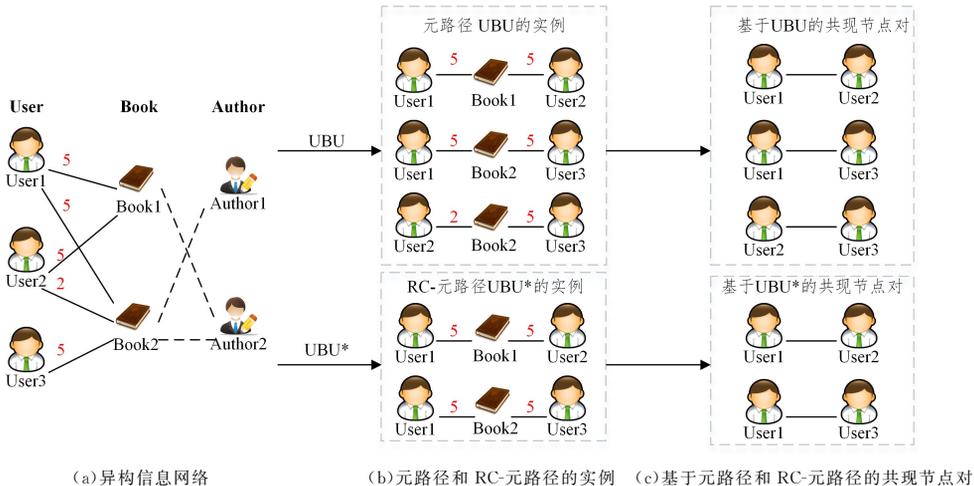


图 2 相关定义示例

Fig. 2 Examples of related definitions

示例3 图2(b)下方的方框显示的是对应于UBU的RC-元路径UBU*的实例,并且此时 $\theta=0$ 。实例两端的节点表示给一本书相同评分的两个用户。图2(c)下方的方框展示了基于UBU*的共现节点对。

定义4(基于HIN的评分预测任务) 给定一个由用户-项目交互数据和其他辅助数据构成的HIN $G=(V,E,T_V,T_E,f_V,f_E)$ 和评分记录的集合 $R=\{(u,i,r_{u,i})\}$,其中三元组 $(u,i,r_{u,i})$ 表示用户 u 给项目 i 的评分 $r_{u,i}$, $r_{u,i} \in \{1,2,\dots,5\}$ 。评分预测任务是利用 G 和 R 中的数据训练得到一个评分预测模型 φ , 预测评分 $\tilde{r}_{u,i}=\varphi(\pi_u^U, \pi_i^I)$, 其中 π_u^U 和 π_i^I 分别表示用户 u 和项目 i 的相关输入信息, 包括它们的编号、属性和邻居

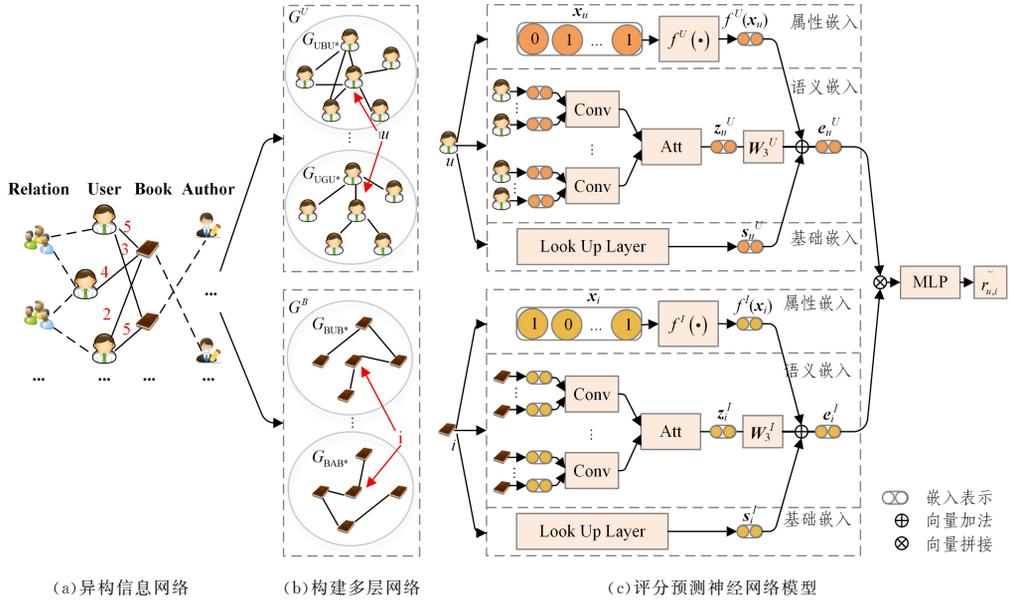


图3 模型框架示意图

Fig. 3 Framework of the proposed model

4.1 构建多层网络

本文模型利用所设计的RC-元路径来提取用户之间和项目之间的语义关系。因此模型关注的是与用户和项目相关的RC-元路径,并且每条RC-元路径两端的节点都是同一类型,即用户类型或项目类型,例如图4中的UBU*和UBABU*。

为了有效地从HIN中提取用户和项目的语义信息,本文的主要思路是利用RC-元路径将HIN转换为同构信息网络,进而构建用户和项目多层网络。这样构建同构信息网络的好处是可以将同构信息网络中相同类型的节点嵌入到相同的向量空间中,而且每个节点在不同的同构信息网络中拥有不同的嵌入表示,这避免了不同元路径语义信息之间的相互干扰,从而提升模型的性能。

$P^U = \{\mathcal{P}_1^U, \mathcal{P}_2^U, \dots, \mathcal{P}_m^U\}$ 表示以用户类型节点开始和结束的RC-元路径集合, $P^I = \{\mathcal{P}_1^I, \mathcal{P}_2^I, \dots, \mathcal{P}_n^I\}$ 表示以项目类型节点开始和结束的RC-元路径集合,其中 m 和 n 分别表示 P^U 和 P^I 中元路径的数量。

$G_{\mathcal{P}^*}$ 表示基于RC-元路径 \mathcal{P}^* 的同构信息网络,通过聚合基于 \mathcal{P}^* 的所有共现节点对得到。构建 $G_{\mathcal{P}^*}$ 的过程可表示为:

等,上标 U 和 I 分别表示用户和项目。

4 异构信息网络的注意力感知多通道图卷积评分预测模型

为了解决第1节中提到的“如何使元路径捕获推荐场景中准确的语义信息”和“如何区分元路径重要性”两个关键问题,本文提出的HAGRP主要包括两部分内容:1)设计RC-元路径从HIN(见图3(a))中提取语义信息,并利用这些信息构建用户和项目的多层网络(见图3(b));2)结合图卷积和注意力机制设计了一个评分预测神经网络(见图3(c))。

$$G_{\mathcal{P}^*} = \text{agg}(\{(u,v), (u,v) \in Q_{\mathcal{P}^*}\}) \quad (1)$$

其中, $Q_{\mathcal{P}^*}$ 表示基于 \mathcal{P}^* 的共现节点对的集合, $\text{agg}(\cdot)$ 为聚合操作。 $G_{\mathcal{P}^*}$ 中的节点 u 和 v 之间的权重 $w_{u,v}^{\mathcal{P}^*}$ 可表示为:

$$w_{u,v}^{\mathcal{P}^*} = \frac{2 \times c_{u,v}^{\mathcal{P}^*}}{c_{u,u}^{\mathcal{P}^*} + c_{v,v}^{\mathcal{P}^*}} \quad (2)$$

其中, $c_{u,v}^{\mathcal{P}^*}$ 表示节点 u 和 v 之间基于 \mathcal{P}^* 的路径实例数量。当 $G_{\mathcal{P}^*}$ 中的边和节点的数量较大时,在 $G_{\mathcal{P}^*}$ 上的图卷积操作会消耗大量的内存,导致计算变得缓慢。因此,为了让模型能够适用于大规模数据的场景,本文采取对 $G_{\mathcal{P}^*}$ 中节点的邻居进行采样的方式。对于节点 u , 采样其邻居节点 v 的概率的计算式为:

$$p(v|u) = \frac{w_{u,v}^{\mathcal{P}^*}}{\sum_{u' \in N_u^{\mathcal{P}^*}} w_{u,u'}^{\mathcal{P}^*}} \quad (3)$$

其中, $N_u^{\mathcal{P}^*}$ 表示节点 u 在 $G_{\mathcal{P}^*}$ 中的邻居集合。经过邻居采样,最终得到节点 u 在 $G_{\mathcal{P}^*}$ 中的采样邻居集合 $\tilde{N}_u^{\mathcal{P}^*}$ 。

多层网络 $G^U = \{G_{\mathcal{P}^*}, \mathcal{P}^* \in P^U\}$ 和 $G^I = \{G_{\mathcal{P}^*}, \mathcal{P}^* \in P^I\}$ 分别表示 P^U 和 P^I 中的RC-元路径生成的同构信息网络集合。此时, G^U 和 G^I 被称为用户和项目的多层网络。每个

同构信息网络 G_{ϕ^*} 被称为多层网络中的一个子网络。

图 4 通过例子给出了构建用户多层网络的过程。其中,图 4(a)是前面描述过的 HIN 实例,通过 UBU^* 和 $UBABU^*$

这两条 RC-元路径提取对应的共现节点(见图 4(b)),然后分别聚合共现节点对,构建了图 4(c)所示的包含同构信息网络 $G_{UBU^*}^U$ 和 $G_{UBABU^*}^U$ 的多层网络 G^U 。

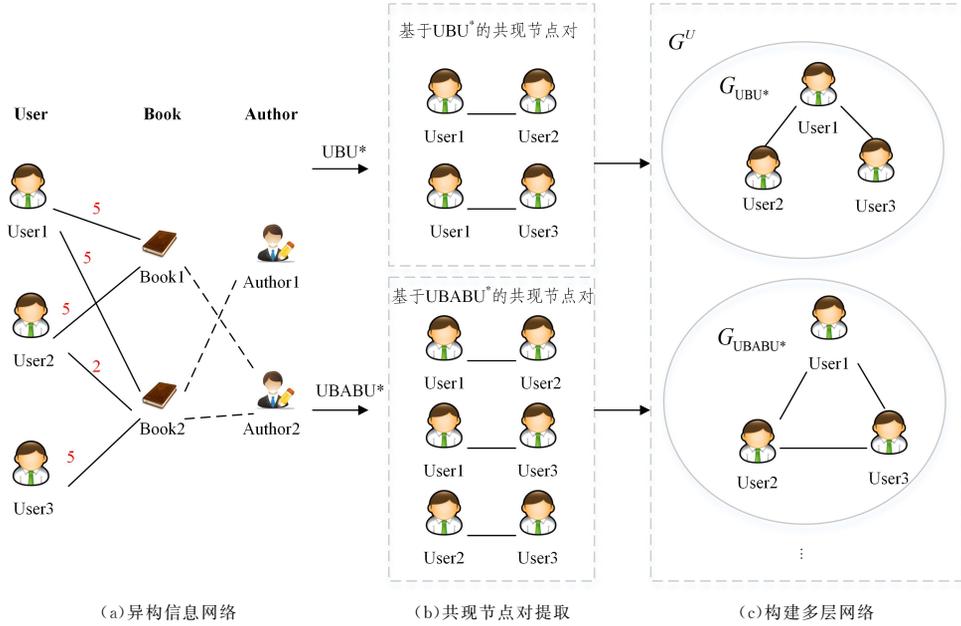


图 4 构建多层网络 G^U 示例

Figure 4 Example of constructing multi-layer network G^U

4.2 注意力感知多通道图卷积评分预测神经网络

图卷积网络能够利用邻居之间的信息共享和信息传递有效地捕获图结构数据中的特征。多层网络 G^U 和 G^I 中的每个节点在不同子网络中具有不同的邻居,表示不同的语义信息。因此,本文提出了多通道图卷积结构为 G^U 和 G^I 中的节点生成对应子网络 G_{ϕ^*} 上的子嵌入表示,其中每一个通道对应一个 G_{ϕ^*} ;同时,本文设计了注意力机制的融合函数将子嵌入表示融合为完整的语义嵌入表示,有效地区分了不同元路径的语义信息对用户和项目的个性化影响;最后与属性信息进行融合形成最终的嵌入表示,并通过一个 MLP(Multilayer Perceptron)评分预测器进行评分预测。该神经网络的具体结构如图 3(c)所示。

4.2.1 用户和项目嵌入表示的生成

用户与项目的嵌入表示生成过程是相同的,下文以用户嵌入表示生成过程为例进行详细说明。在生成用户和项目嵌入表示的网络中涉及不共享的参数分别用上标 U 和 I 加以区别,即 U 表示用户相关, I 表示项目相关。

用户子嵌入表示 $\mathbf{h}_u^{\phi^*(k)}$;对于多层网络 G^U ,用户 u 在子网络 G_{ϕ^*} ($G_{\phi^*} \in G^U$) 中的子嵌入表示记为 $\mathbf{h}_u^{\phi^*(k)} \in \mathbb{R}^{d(k)}$, $1 \leq k \leq K$,其中 k 表示第 k 次卷积操作, K 是总的卷积次数, $d(k)$ 是第 k 次卷积操作后得到的嵌入表示维度。 $\mathbf{h}_u^{\phi^*(k)}$ 通过聚合用户 u 在 G_{ϕ^*} 中的采样邻居在 $k-1$ 次卷积后的嵌入表示而得到,其聚合过程可表示为:

$$\mathbf{h}_u^{\phi^*(k)} = g(\{\mathbf{h}_{u'}^{\phi^*(k-1)}, \forall u' \in \tilde{N}_u^{\phi^*}\}) \quad (4)$$

其中, $g(\cdot)$ 是聚合邻居子嵌入表示的函数, $\tilde{N}_u^{\phi^*}$ 是用户 u 在 G_{ϕ^*} 中的采样邻居集合, $\mathbf{h}_{u'}^{\phi^*(k-1)}$ ($k \geq 2$) 表示邻居 u' 在第 $(k-1)$ 次卷积后得到的嵌入表示。卷积前的初始子嵌入表示 $\mathbf{h}_u^{\phi^*(0)}$ 可表示为:

$$\mathbf{h}_u^{\phi^*(0)} = \mathbf{t}_u^{\phi^*} + f^{\phi^*}(\mathbf{x}_u^U) \quad (5)$$

其中, $\mathbf{t}_u^{\phi^*} \in \mathbb{R}^{d_t}$ 由查找层得到, \mathbf{x}_u^U 为 multi-hot 形式的用户属性(如年龄、性别等)向量, $f^{\phi^*}(\cdot)$ 为 G_{ϕ^*} 对应的映射函数(本文使用的是 MLP),将用户属性向量映射到与 $\mathbf{t}_u^{\phi^*}$ 相同的嵌入表示空间。

这里函数 $g(\cdot)$ 是一个均值聚合函数:

$$\mathbf{h}_u^{\phi^*(k)} = \sigma(\mathbf{W}_1^{\phi^*(k)} \cdot \text{mean}(\{\mathbf{h}_{u'}^{\phi^*(k-1)}, \forall u' \in \tilde{N}_u^{\phi^*}\}) + \mathbf{b}_1^{\phi^*(k)}) \quad (6)$$

其中, $\mathbf{W}_1^{\phi^*(k)}$ 和 $\mathbf{b}_1^{\phi^*(k)}$ 分别表示子网络 G_{ϕ^*} 在第 k 次卷积操作时的权重矩阵和偏置向量, $\sigma(\cdot)$ 表示激活函数,如 ReLU。将经过 K 次卷积操作后得到的最终子嵌入表示记为 $\mathbf{h}_u^{\phi^*} \in \mathbb{R}^{d_h}$ 。在经过多通道图卷积操作之后,将得到用户 u 的一组子嵌入表示 $H_u^U = \{\mathbf{h}_u^{\phi^*}, \phi^* \in P^U\}$ 。不同的子嵌入表示包含不同类型的语义信息,为了得到完整的语义信息,需要将所有子嵌入表示融合为一个嵌入表示,称作语义嵌入表示。用户 u 的语义嵌入表示用 \mathbf{z}_u^U 表示,通过一个融合函数得到:

$$\mathbf{z}_u^U = \text{fuse}(H_u^U) \quad (7)$$

其中, $\text{fuse}(\cdot)$ 为融合函数,例如均值融合函数:

$$\mathbf{z}_u^U = \frac{1}{|H_u^U|} \sum_{\mathbf{h}_u^{\phi^*} \in H_u^U} \mathbf{h}_u^{\phi^*} \quad (8)$$

考虑到不同 RC-元路径对用户的影响具有个性化的特征,本文模型设计了注意力机制的非线性融合函数来整合这些子嵌入表示。注意力机制的子嵌入表示融合过程可表示为:

$$\mathbf{z}_u^U = \sum_{\mathbf{h}_u^{\phi^*} \in H_u^U} \omega_u^{\phi^*} \mathbf{h}_u^{\phi^*} \quad (9)$$

其中, $\omega_u^{\phi^*}$ 是 $\mathbf{h}_u^{\phi^*}$ 融合时的权重,其计算式为:

$$\omega_u^{\otimes*} = \frac{\exp((\mathbf{a}^U)^\top \tanh(\mathbf{W}_2^U \cdot \mathbf{h}_u^{\otimes*} + \mathbf{b}_2^U))}{\sum_{\hat{\mathbf{h}}_u^{\otimes*} \in \mathcal{P}^U} \exp((\mathbf{a}^U)^\top \tanh(\mathbf{W}_2^U \cdot \hat{\mathbf{h}}_u^{\otimes*} + \mathbf{b}_2^U))} \quad (10)$$

其中, $\mathbf{a}^U \in \mathbb{R}^{d_a}$ 为可训练的注意力向量, \mathbf{W}_2^U 和 \mathbf{b}_2^U 分别表示可训练参数矩阵和偏置向量。用 \mathbf{e}_u^U 表示用户最终的嵌入表示, 其计算式为:

$$\mathbf{e}_u^U = \mathbf{s}_u^U + \alpha \mathbf{W}_3^U \cdot \mathbf{z}_u^U + \beta f(\mathbf{x}_u^U) \quad (11)$$

其中, $\mathbf{s}_u^U \in \mathbb{R}^{d_s}$ 为基础嵌入, 由查找层获得; $f(\cdot)$ 是一个映射函数, 将用户 u 的属性嵌入 \mathbf{x}_u^U 映射到与 \mathbf{s}_u^U 相同的空间, 这里采用了一个 MLP; \mathbf{W}_3^U 为可训练的权重矩阵, 将语义嵌入表示 \mathbf{z}_u^U 转换到与 \mathbf{s}_u^U 相同的空间; α 与 β 分别为 $\mathbf{W}_3^U \cdot \mathbf{z}_u^U$ 和 $f(\mathbf{x}_u^U)$ 的系数。

类似地, 采用同样的方法, 模型可以得到项目 i 的嵌入表示 \mathbf{e}_i^I 。

4.2.2 评分预测器

得到用户和项目的最终嵌入表示后, 我们可以对用户和项目之间的关系进行建模, 以生成用户对项目的评分。模型使用 MLP 来建模用户和项目嵌入表示之间的关系。用户 u 对项目 i 的预测评分 $\tilde{r}_{u,i}$ 定义为:

$$\tilde{r}_{u,i} = \text{MLP}(\text{CONCAT}(\mathbf{e}_u^U, \mathbf{e}_i^I)) \quad (12)$$

其中, $\text{MLP}(\cdot)$ 表示多层感知机, $\text{CONCAT}(\cdot)$ 表示向量拼接操作。

4.2.3 模型优化

评级预测任务的优化目标是 minimized 预测评分 $\tilde{r}_{u,i}$ 和真实评分 $r_{u,i}$ 之间的差异。模型采用小批量优化方法, 并结合 Adam 优化算法对模型进行优化, 损失函数为:

$$\mathcal{L} = \frac{1}{|B|} \sum_{(u,i,r_{u,i}) \in B} (r_{u,i} - \tilde{r}_{u,i})^2 \quad (13)$$

其中, B 表示采样的一批用户-项目评分记录集合。

5 实验

为了验证所提模型的有效性, 本节在两个真实数据集上与其他基线算法进行了对比, 并通过一系列实验对所提模型的特性进行了探究和分析。

5.1 数据集介绍

实验采用了两个被广泛引用的真实世界数据集: Douban Book 和 Yelp。Douban Book 数据集包含 13024 个用户和 22347 个项目, 评分范围为 1~5。该数据集的辅助信息包括书籍和社交网络的作者和出版商等。Yelp 数据集来自商业领域, 其中包含 198397 个评分, 其辅助信息包括类别、企业的地点和用户的社交网络。两个数据集的具体信息如表 1 所列, 实验使用的元路径如表 2 所列。

表 1 数据集的详细信息

Table 1 Dataset details

数据集	稠密度	连接类型 ($T_{V_A} - T_{V_B}$)	T_{V_A} 类型 节点数	T_{V_B} 类型 节点数	边数
Douban Book	0.27%	User-Book	13024	22347	792026
		User-User	12478	12748	169150
		Book-Author	21907	10805	21905
		Book-Publisher	21773	1815	21773
Yelp	0.08%	User-Business	16239	14284	198397
		User-Compliment	14411	11	76875
		Business-City	14267	47	14267
		Business-Category	14180	511	40009

表 2 实验使用的元路径

Table 2 Meta-paths used in experiment

数据集	元路径
Douban Book	UBU*, UU*, UBABU*, UBPBU*, BUB*, BAB*, BPB*
Yelp	UBU*, UBCiBU*, UBCaBU*, BUB*, BCiB*, BCaB*

5.2 评价指标

为了衡量模型的预测精确度, 本文使用平均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root Mean Square Error, RMSE) 作为评价指标。MAE 和 RMSE 的定义如下:

$$\text{MAE} = \frac{1}{|D_{\text{test}}|} \sum_{(u,i,r_{u,i}) \in D_{\text{test}}} |\tilde{r}_{u,i} - r_{u,i}|, \quad (14)$$

$$\text{RMSE} = \sqrt{\frac{1}{|D_{\text{test}}|} \sum_{(u,i,r_{u,i}) \in D_{\text{test}}} |\tilde{r}_{u,i} - r_{u,i}|^2} \quad (15)$$

其中, D_{test} 表示测试集数据, $\tilde{r}_{u,i}$ 表示用户 u 对项目 i 的评分预测值, $r_{u,i}$ 表示用户 u 对项目 i 的真实评分。

5.3 对比方法

本文实验进行对比的 7 个模型如下。

(1) PMF^[27]: 最经典的协同过滤模型之一, 它在大型、稀疏和不平衡的数据集上具有良好的性能。

(2) HeteMF^[20]: 一种基于 MF 的推荐方法, 它利用基于元路径的相似性来度量 HIN 上实体间的相似性。

(3) SemRec^[6]: 一个个性化的推荐模型, 它考虑了 HIN 中边的权重, 以及元路径的权重。

(4) HERec^[9]: 一个基于 HIN 嵌入的评分预测模型, 它通过基于元路径的随机游走和 word2vec 为每个元路径生成用户或项目的嵌入, 然后融合这些嵌入为每个用户或项目生成最终嵌入。

(5) AMERec^[8]: 一种基于 HIN 网络嵌入和注意力感知元路径的推荐模型, 它在 HERec 的基础上引入了边的权重和基于深度神经网络的评分器。

(6) HAGRP: 本文提出的评分预测模型, 它采用具有评分限制的元路径来提取语义信息, 并设计了注意力感知多通道图卷积的神经网络进行评分预测。

(7) HAGRP_{mean}: 将 HAGRP 中注意力机制的融合函数替换为均值融合函数。

5.4 实验设置

每个数据集中的评分数据按一定比例随机分为训练集和测试集。Douban Book 数据集训练集数据的比例设置为 {80%, 60%, 40%, 20%}, 因为 Yelp 数据集的评分数据太过于稀疏, 所以训练比例设置为 {90%, 80%, 70%, 60%}。对于两个数据集的每个训练比例, 重复进行 5 次实验, 最终结果取平均值。在本实验中, HAGRP 和 HAGRP_{mean} 模型采用的 RC-元路径如表 2 所列, 模型学习率设置为 $\mu = 0.0001$, 每一批训练数据大小 $num_{\text{batch}} = 512$, 其他参数的选取将在 5.5.2 节中详细讨论。本文模型使用 PyTorch 实现, 实验的系统环境为 Linux, 显卡为 GeForce RTX 3090 Ti, 显存为 24 GB。

5.5 结果与讨论

5.5.1 总体结果对比和分析

不同模型在两个数据集上的实验结果如表 3 所列, 从中可以观察到如下特点。

表3 在 DoubanBook 和 Yelp 数据集上的实验结果

Table 3 Experimental results on Douban Book and Yelp datasets

数据集	训练比	指标	PMF	HeteMF	SemRec	HERec	AMERec	HAGRP _{mean}	HAGRP
Douban Book	80%	MAE	0.5774	0.5740	0.5675	0.5502	0.5496	0.5485	0.5480
		Improve		+0.59%	+1.71%	+4.71%	+4.81%	+5.01%	+5.1%
		RMSE	0.7414	0.7360	0.7283	0.6811	0.6912	0.6954	0.6933
	60%	Improve		+0.77%	+1.81%	+8.17%	+6.87%	+6.20%	+6.49%
		MAE	0.6065	0.5823	0.5833	0.5600	0.5556	0.5545	0.5512
		Improve		+3.99%	+3.83%	+7.67%	+8.39%	+8.57%	+9.11%
	40%	RMSE	0.7908	0.7466	0.7505	0.7123	0.7023	0.6995	0.6975
		Improve		+5.59%	+5.10%	+9.93%	+11.19%	+11.54%	+11.80%
		MAE	0.6800	0.5982	0.6025	0.5774	0.5692	0.5595	0.5587
	20%	Improve		+12.03%	+11.40%	+15.09%	+16.30%	+17.72%	+17.83%
		RMSE	0.9023	0.7779	0.7751	0.7400	0.7242	0.7068	0.7056
		Improve		+15.47%	+15.78%	+19.59%	+16.30%	+21.67%	+21.80%
Yelp	90%	MAE	1.0344	0.6327	0.6481	0.6540	0.5900	0.5756	0.5740
		Improve		+38.99%	+37.35%	+37.65%	+42.96%	+44.35%	+44.51%
		RMSE	1.4414	0.8236	0.8350	0.8581	0.7407	0.7213	0.7205
	80%	Improve		+42.39%	+42.07%	+40.47%	+48.61%	+49.96%	+50.01%
		MAE	1.0412	0.9487	0.9043	0.8395	0.8067	0.7945	0.7922
		Improve		+8.88%	+13.15%	+19.37%	+22.52%	+23.69%	+23.91%
	70%	RMSE	1.4268	1.2549	1.1637	1.0907	1.0506	1.0155	1.0141
		Improve		+12.05%	+18.44%	+23.56%	+26.37%	+28.83%	+28.92%
		MAE	1.0791	0.9654	0.9176	0.8475	0.8088	0.7960	0.7928
	60%	Improve		+10.54%	+14.97%	+21.46%	+25.04%	+26.23%	+26.53%
		RMSE	1.4816	1.2799	1.1771	1.1117	1.0569	1.0162	1.0152
		Improve		+13.61%	+20.55%	+24.97%	+28.66%	+31.41%	+31.48%
50%	MAE	1.1170	0.9975	0.9407	0.8580	0.8164	0.7988	0.7946	
	Improve		+10.70%	+15.78%	+23.19%	+26.91%	+28.49%	+28.86%	
	RMSE	1.5387	1.3329	1.2810	1.1256	1.0710	1.0206	1.0185	
40%	Improve		+14.02%	+21.31%	+26.85%	+30.40%	+33.67%	+33.81%	
	MAE	1.1778	1.0368	0.9637	0.8759	0.8392	0.8056	0.8004	
	Improve		+11.97%	+18.18%	+25.63%	+28.75%	+31.60%	+32.04%	
30%	RMSE	1.6167	1.3713	1.2380	1.1488	1.0758	1.0223	1.0195	
	Improve		+15.18%	+23.42%	+28.94%	+33.46%	+36.76%	+36.94%	

注:其中包括了相对于 PMF 的提升百分比

(1) 基于 HIN 的评分预测模型 (HeteMF, SemRec, HERec, AMERec, HAGRP_{mean} 和 HAGRP) 比传统的基于 MF 的模型 (PMF) 具有更好的性能, 说明了 HIN 能够有效帮助模型提高预测精度。这是因为基于 HIN 的模型能够充分利用异构的辅助信息。在现实世界中, 用户偏好和选择受多种因素影响。例如, 在电影推荐系统中, 用户的偏好可能会受电影的类型、演员、导演、网站上的评论以及用户的社交网络等因素的影响。因此, 在推荐时考虑尽可能多的信息是必要的, 基于 HIN 的模型有能力集成所有这些异构信息。

(2) 随着训练数据变得稀疏 (即训练集的比例减少), 参与实验的模型在两个数据集上的表现都呈现变差的趋势。但值得注意的是, HAGRP_{mean} 和 HAGRP 的表现受到数据稀疏性变化的影响明显小于其他对比模型。例如, 在 Douban Book 数据集上, 训练集比例从 80% 降到 20%, HAGRP 的 RMSE 指标的变化值为 0.0272 (0.6933 ~ 0.7205), HAGRP_{mean} 的变化值为 0.0259 (0.6954 ~ 0.7213), AMERec 的变化值为 0.0495 (0.6912 ~ 0.7407), HERec 的变化值为 0.1770 (0.6811 ~ 0.8581), SemRec 的变化值为 0.1067 (0.7283 ~ 0.8350), HeteMF 的变化值为 0.0876 (0.7360 ~ 0.8236), PMF 的变化值为 0.7000 (0.7414 ~ 1.4414)。可以看出, HAGRP 相比其他模型, 在面对数据稀疏性变化时具有更好的稳定性。

(3) 对比 HAGRP 和 HRPMG_{mean} 的结果可以发现, 前者

在两个数据集上的表现都优于后者, 这说明了利用注意力机制区分不同元路径语义信息的重要性能够提升模型的表现。HAGRP 中注意机制的融合函数可以为每个用户和项目学习个性化的子嵌入表示权重, 能够更准确地捕捉到用户和项目的特征。

5.5.2 参数分析和选择

(1) 嵌入表示维度的影响。HAGRP 的神经网络模型中有 3 个重要的嵌入表示维度参数, 包括式 (5) 中嵌入表示 t_u^U 的维度 d_t , 卷积后的子网络嵌入表示 h_u^U 的维度 d_h 和最终嵌入表示的维度 d_e 。本小节分别在 Douban Book 和 Yelp 两个数据集上对上述参数进行实验, 以探究它们的变化对模型的影响。实验中两个数据集的训练集比例都设置为 80%, 用户和项目对应的维度参数都设置为相同的值。图 5(a) — 图 5(c) 给出了在 Douban Book 数据集上的实验结果, 图 5(d) — 图 5(f) 给出了在 Yelp 数据集上的实验结果。

从图 5(a) — 图 5(f) 可以看出, HAGRP 的性能受 d_t , d_h 和 d_e 变化影响较小, 总体呈现的趋势是 d_t , d_h 和 d_e 过小或过大时, 模型性能相对较差。需要注意的是, MAE 和 RMSE 指标可能不会同时达到最佳点。例如, 在图 5(b) 中, $d_h = 60$ 时 RMSE 达到最小, 而 $d_h = 80$ 时 MAE 达到最小。因此, 在选择维度参数时需要做一些权衡。当 MAE 和 RMSE 的最佳点不同时, 倾向于选择较小的维度, 因为较小的表示维度可以减少内存和计算时间的消耗。因此, 实验时 Douban Book

数据集的维度参数确定为 $d_i = 30, d_h = 60$ 和 $d_e = 80$, Yelp

数据集的维度参数确定为 $d_i = 40, d_h = 60$ 和 $d_e = 100$ 。

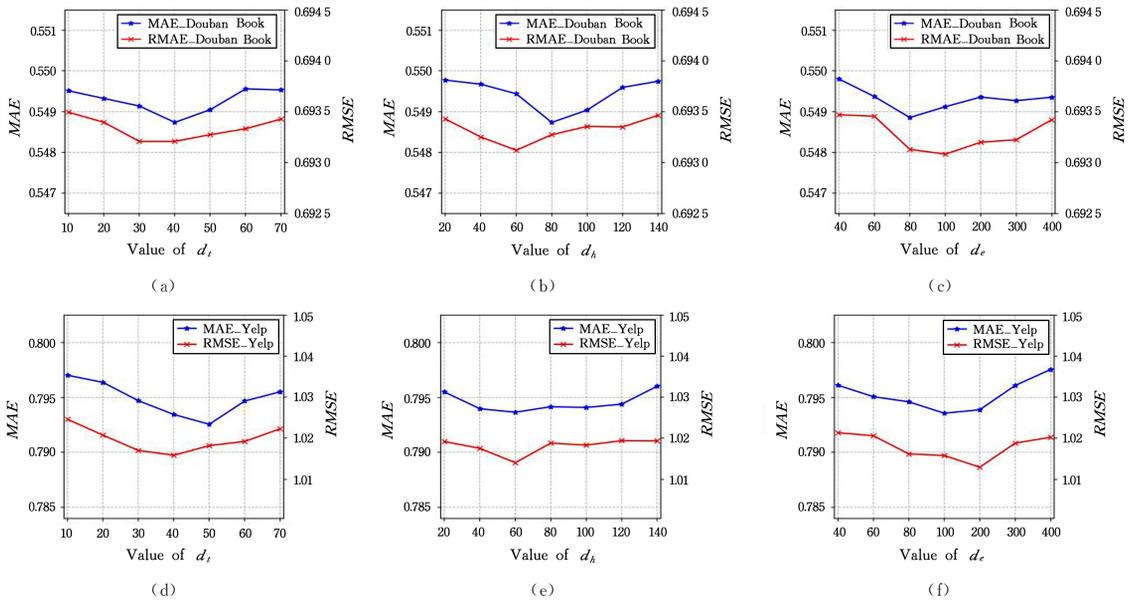


图 5 嵌入表示维度的影响

Fig. 5 Influence of embedding representation dimension

(2) α 和 β 的影响。模型中的 α 和 β 分别为语义嵌入表示和属性嵌入表示的系数, 详见式(11)。本实验探究它们对模型的影响, 实验时 Douban Book 数据集的训练集比例为 20%, Yelp 数据集的训练集比例为 60%, α 和 β 的搜索空间均为 $0 \sim 2.0$, 搜索步长为 0.2。实验结果如图 6 所示, 在 Douban Book 数据集上 α 和 β 最优取值为 1.0 和 1.8, 在 Yelp 数据集上 α 和 β 最优取值为 0.4 和 1.8。

(即只考虑语义嵌入表示)这两种情况下, 后者对模型性能的提升效果更显著。而图 6(b)显示, 在数据集 Yelp 上, 单独的语义嵌入表示或属性嵌入表示对模型性能的提升效果相差不大。综上所述, 单独的语义嵌入或属性嵌入对模型的性能提升都有一定的帮助, 但是对于不同数据集, 两者的影响大小可能不同, 而将两者结合能达到更好的效果。

(3) θ 的影响。 θ 为第 3 节定义 3 中对元路径的评分限制参数, 表示一个路径实例上允许的最大评分差。本小节实验探究 θ 对模型性能的影响。实验中, Douban Book 数据集的训练集比例为 20%, Yelp 的训练集比例为 60%, θ 的取值范围均为 $\{0, 1, 2, 3, 4\}$ 。当 $\theta = 0$ (即路径实例中所有评分都必须相同) 时, 限制最大; 当 $\theta = 4$ 时, RC-元路径就退化为了普通元路径 (因为评分记录中最大评分为 5, 最小评分为 1), 即没有限制。实验结果如图 7 所示, 在 Douban Book 数据集上 (见图 7(a)), 模型在 $\theta = 1$ 时达到了最好的性能; 在 Yelp 数据集上 (见图 7(b)), 模型在 $\theta = 2$ 时达到了最好的性能。可以看出, 具有评分限制的元路径确实有助于提升模型的性能。除此之外, 还可以观察到, 对于 Douban Book 数据集, 在 θ 值较小时模型性能更好, 而在 Yelp 数据集上情况则相反。这表明不同的数据集对元路径的限制程度有不同的要求, 这可能与数据集本身的一些特性 (如数据的稀疏性、所属的推荐领域等) 相关。

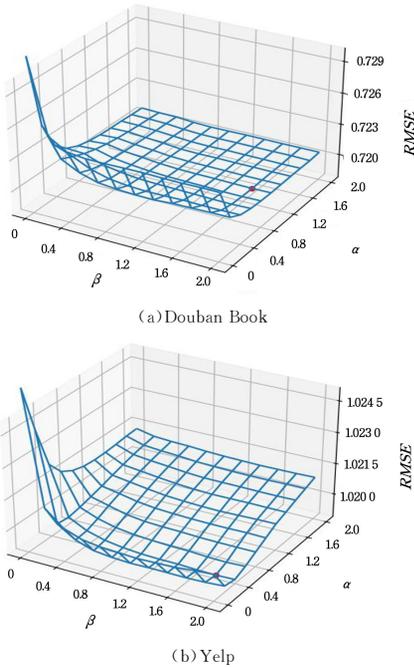


图 6 α 和 β 的影响

Fig. 6 Influence of α and β

在图 6(a)和图 6(b)中, RMSE 在 $\alpha = 0$ 和 $\beta = 0$ 处都发生了突变, 这说明语义嵌入表示和属性嵌入表示对模型性能提升的帮助较大。从图 6(a)中可以看到, 在数据集 Douban Book 上, 在 $\alpha = 0, \beta \neq 0$ (即只考虑属性嵌入表示) 和 $\alpha \neq 0, \beta = 0$

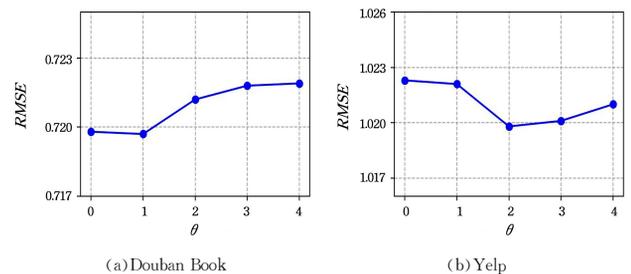


图 7 θ 的影响

Fig. 7 Influence of θ

(4)RC-元路径对模型的影响。本实验是为了进一步探讨不同 RC-元路径的影响,实验中向 HAGRP 中逐个添加 RC-元路径,然后观察 MAE 和 RMSE 的变化。

从图 8 可以看出,模型性能在两个数据集上的总体趋势是随着 RC-元路径的增加而提升。这说明 HAGRP 可以有效地集成不同的 RC-元路径来提升性能。但是,观察细节后可以发现,在添加了某些元路径后,模型性能提升不明显,甚至会略微下降。这可能是因为一些元路径包含噪声,从而影响了模型表现。此外,另一个观察结果是,较长的元路径可能不如较短的元路径有效。例如,图 8(a)中的 UBABU* 和 UBPPU* 和图 8(b)中的 UBCaBU* 和 UBCiBU* 在加入模型后,只对性能带来了很小的改善,性能甚至有所降低。这可能是因为节点间的语义相关性会随着元路径长度的增加而减小,从而导致提取的语义信息对推荐的帮助减小。

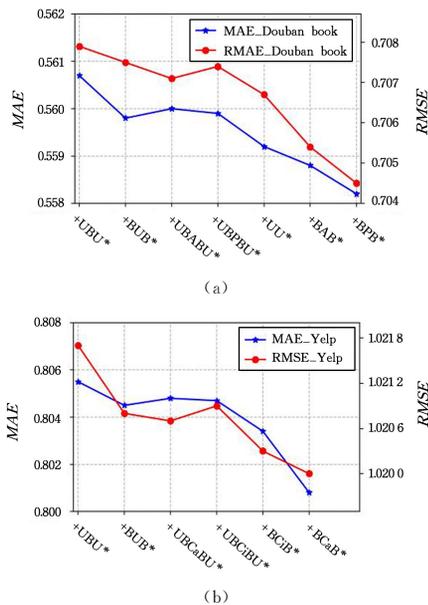


图 8 逐步添加 RC-元路径时的性能变化

Fig. 8 Performance change when adding RC-meta paths incrementally

5.5.3 模型可扩展性

为了说明该模型的可扩展性,本小节在 DoubanBook 数据集和 Yelp 数据集上进行了可扩展性实验,测试了 4 种不同的训练比率(即 0.2,0.4,0.6 和 0.8)的每个训练周期的平均运行时间。图 9 中,每个训练周期花费的时间与两个数据集的训练比率几乎是线性关系,这说明该模型具有良好的可扩展性,能够适用于大规模数据的场景。

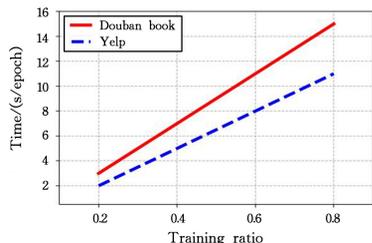


图 9 训练集数据比例变化对训练时间的影响

Fig. 9 Influence of changing the ratio of training set on training time

的元路径;然后利用具有评分限制的元路径构建了多层网络;之后结合图卷积网络与注意力机制设计了能够融合异构图语义信息和属性信息的评分预测神经网络模型;最后进行了实验,验证了 HAGRP 的有效性,探究了 HAGRP 的相关特性。

所提出的 HAGRP 模型适用于静态场景下的评分预测任务,未考虑用户兴趣等动态变化。但在现实场景中,用户的兴趣会随着时间的推移而变化,经常导致网络的动态变化。因此,我们计划在未来工作中对本文模型进行拓展,使之能够处理动态情景的评分预测问题。

参考文献

- [1] WU J X,ZHANG Z H. Collaborative Filtering Recommendation Algorithm Based on User Rating and Similarity of Explicit and Implicit Interest [J]. Computer Science,2021,48(5):147-154.
- [2] HE Y F,ZHANG Y W,LV Z H, et al. Meta Path-Aware Rating Collaborative Filtering in Heterogeneous Information Network [J]. Chinese Journal of Computers,2020,43(12):2385-2397.
- [3] KOREN Y. Factor in the Neighbors; Scalable and Accurate Collaborative Filtering [J]. ACM Transactions on Knowledge Discovery from Data,2010,4(1):1-24
- [4] XU K,ZHENG X,CAI Y, et al. Improving User Recommendation by Extracting Social Topics and Interest Topics of Users in Uni-Directional Social Networks [J]. Knowledge-Based Systems,2018,140(C):120-133.
- [5] YANG N,MA Y,CHEN L, et al. A meta-feature based unified framework for both cold-start and warm-start explainable recommendations [J]. World Wide Web,2020,23(1):241-265.
- [6] SHI C,ZHANG Z,JI Y, et al. SemRec: A Personalized Semantic Recommendation Method Based on Weighted Heterogeneous Information Networks [J]. World Wide Web,2019,22(1):153-184.
- [7] YIZHOU S,JIawei H. Mining Heterogeneous Information Networks; Principles and Methodologies [M]. California; Morgan & Claypool,2012:57-72.
- [8] YAN S,WANG H,LI Y, et al. Attention-aware metapath-based network embedding for HIN based recommendation [J]. Expert Systems with Applications,2021,174(8):114601.1-114601.12.
- [9] SHI C,HU B,ZHAO W X, et al. Heterogeneous Information Network Embedding for Recommendation [J]. IEEE Transactions on Knowledge & Data Engineering,2019,31(2):357-370.
- [10] DONG Y,CHAWLA N V,SWAMI A. metapath2vec: Scalable Representation Learning for Heterogeneous Networks [C] // Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Halifax,NS,Canada: Association for Computing Machinery,2017:135-144.
- [11] ZHAO J L,ZHAO Z Y. Recommendation Algorithm Based on Heterogeneous Information Network Embedding and Attention Neural Network [J]. Computer Science,2021,48(8):72-79.
- [12] KOREN Y,BELL R,VOLINSKY C. Matrix factorization techniques for recommender systems [J]. Computer,2009,42(8):30-37.
- [13] FORSATI R,MAHDAVI M,SHAMSFARD M, et al. Matrix Factorization with Explicit Trust and Distrust Side Information for Improved Social Recommendation [J]. ACM Transactions on

结束语 本文提出了一个异构信息网络的注意力感知多通道卷积评分预测模型 HAGRP。首先设计了具有评分限制

- Information Systems, 2014, 32(4):1-38.
- [14] LIANG D, ALTOSAAR J, CHARLIN L, et al. Factorization Meets the Item Embedding: Regularizing Matrix Factorization with Item Co-Occurrence[C]// Proceedings of the 10th ACM Conference on Recommender Systems. Association for Computing Machinery, 2016:59-66.
- [15] CAO D, NIE L, HE X, et al. Embedding Factorization Models for Jointly Recommending Items and User Generated Lists [C]// Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. Association for Computing Machinery, 2017:585-594.
- [16] LUO L, XIE H, RAO Y, et al. Personalized recommendation by matrix co-factorization with tags and time information [J]. Expert Systems with Applications, 2019, 119(1):311-321.
- [17] ZHANG Z, LIU Y, ZHANG Z, et al. Fused matrix factorization with multi-tag, social and geographical influences for POI recommendation[J]. World Wide Web, 2019, 22(3):1135-1150.
- [18] NGUYEN V D, HUYNH V N, SRIBOONCHITTA S. Integrating Community Context Information Into a Reliably Weighted Collaborative Filtering System Using Soft Ratings [J]. IEEE Transactions on Systems, Man, Cybernetics: Systems, 2020, 50(4):1318-1330.
- [19] SUN Y, HAN J, YAN X, et al. PathSim: Meta Path-Based Top-K Similarity Search in Heterogeneous Information Networks [J]. Proceedings of the Vldb Endowment, 2011, 4(11):992-1003.
- [20] YU X, REN X, SUN Y, et al. Personalized Entity Recommendation: A Heterogeneous Information Network Approach [C]// Proceedings of the 7th ACM International Conference on Web Search and Data Mining. Association for Computing Machinery, 2014:283-292.
- [21] LIANG T, CHEN L, WU J, et al. Meta-Path Based Service Recommendation in Heterogeneous Information Networks[C]// Service-Oriented Computing. Springer International Publishing, 2016:371-386.
- [22] DAI F, GU X, LI B, et al. Meta-Graph Based Attention-Aware Recommendation over Heterogeneous Information Networks [C]// Computational Science (ICCS 2019). Springer International Publishing, 2019:580-594.
- [23] WU Z, PAN S, CHEN F, et al. A Comprehensive Survey on Graph Neural Networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(1):4-24.
- [24] 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. Long Beach, California, USA: Curran Associates Inc., 1025-1035.
- [25] YING R, HE R, CHEN K, et al. Graph Convolutional Neural Networks for Web-Scale Recommender Systems[C]// Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, United Kingdom: Association for Computing Machinery, 2018:974-983.
- [26] FU J, LIU J, JIANG J, et al. Scene Segmentation With Dual Relation-Aware Attention Network [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(6):2547-2560.
- [27] SALAKHUTDINOV R, MNIH A. Probabilistic matrix factorization [C]// Proceedings of the 21st International Conference on Neural Information Processing Systems (NIPS'08), Curran Associates Inc. 2008:1257-1264.



ZHOU Mingqiang, born in 1977, Ph.D, associate professor, is a member of China Computer Federation. His main research interests include the different aspects of software engineering, service computing, complex network and graph network representation learning and applications.

(责任编辑:喻黎)