



# 多网络混合嵌入学习的服务推荐方法研究

王雪纯<sup>1</sup>, 吕晟凯<sup>1</sup>, 吴浩<sup>2</sup>, 何鹏<sup>1,3+</sup>, 曾诚<sup>1</sup>

1. 湖北大学 计算机与信息工程学院, 武汉 430062

2. 华中科技大学 计算机科学与技术学院, 武汉 430074

3. 湖北大学 数学与统计学学院 应用数学湖北省重点实验室, 武汉 430062

+ 通信作者 E-mail: 546280153@qq.com

**摘要:**网络嵌入是将网络节点投影到一个向量空间,从而有效地提取网络中各节点的特征信息。在服务推荐领域,已有研究表明引入网络嵌入方法能有效缓解推荐过程中数据稀疏等问题。但现有的网络嵌入方法多针对某一种特定结构的网络,并没有从根源上协同多种关系网络。因此,从垂直和平行两个角度将多种关系网络映射到同一个向量空间,提出一种基于多网络混合嵌入的服务推荐模型(MNHER)。首先,构建用户社交关系网络、服务标签共有网络、用户-服务异质信息网络;然后,通过多网络混合嵌入学习,得到用户和服务在同一向量空间的嵌入向量;最后,应用用户和服务的表征向量向目标用户推荐服务。此外,也对嵌入学习中的随机游走方法进行了优化,确保能更有效地提取和保留原网络的特征信息。为验证该方法的有效性,在三个公开数据集上与多种代表性的服务推荐方法进行了对比分析,相比基于单一关系网络和简单融合多关系网络的服务推荐方法,F-measure值分别可提高21%、15%。实验结果证明了多网络混合嵌入方法可有效地协同多关系网络,提高服务推荐质量。

**关键词:**异质信息网络;关系网络;网络嵌入;服务推荐;协同过滤

**文献标志码:**A **中图分类号:**TP391

## Research on Service Recommendation Method of Multi-network Hybrid Embedding Learning

WANG Xuechun<sup>1</sup>, LYU Shengkai<sup>1</sup>, WU Hao<sup>2</sup>, HE Peng<sup>1,3+</sup>, ZENG Cheng<sup>1</sup>

1. School of Computer and Information Engineering, Hubei University, Wuhan 430062, China

2. School of Computer Science and Technology, Huazhong University of Science and Technology, Wuhan 430074, China

3. Hubei Key Laboratory of Applied Mathematics, Faculty of Mathematics and Statistics, Hubei University, Wuhan 430062, China

**Abstract:** The network embedding method can map the network nodes to a low-dimensional vector space and extract the feature information of each node effectively. In the field of service recommendation, some studies show that the introduction of network embedding method can effectively alleviate the problem of data sparsity in the recommendation process. However, the existing network embedding methods are mostly aimed at a specific structure of

**基金项目:**国家重点研发计划(2018YFB1003801);国家自然科学基金(61832014,61902114);应用数学湖北省重点实验室开放基金(HBAM201901)。

This work was supported by the National Key Research and Development Program of China (2018YFB1003801), the National Natural Science Foundation of China (61832014, 61902114) and the Open Foundation of Hubei Key Laboratory of Applied Mathematics (HBAM201901).

**收稿日期:**2021-01-07 **修回日期:**2021-03-04

the network, and do not cooperate with a variety of relationship networks from the source. Therefore, this paper proposes a service recommendation method based on multi-network hybrid embedding (MNHER), which maps multiple relational networks to the same vector space from vertical and parallel perspectives. Firstly, the social network of users, the shared network of service tags and the user-service heterogeneous information network are constructed. Then, the hybrid embedding method proposed in this paper is used to obtain the embedding vector of users and services in the same vector space. Finally, the service recommendation is made to target users based on the embedding vector of users and services. In this paper, the random walk method is further optimized to extract and retain the characteristic information of the original network more effectively. In order to verify the effectiveness of the method proposed in this paper, it is compared with a variety of representative service recommendation methods on three public datasets, and the F-measure values of the service recommendation methods based on single relational network and simply fused multi-relational network are improved by 21% and 15%, respectively. It is proven that the method of multi-network hybrid embedding can effectively coordinate multi-relationship network and improve the quality of service recommendation.

**Key words:** heterogeneous information network; relational network; network embedding; service recommendation; collaborative filtering

近年来,推荐系统有效地帮助人们在数量巨大的信息资源中获取感兴趣的信息。尤其对于互联网服务,推荐系统的地位日渐凸显。出现了越来越多有关服务推荐方法的研究,其中,基于内容和基于协作的推荐系统是最常用的推荐系统<sup>[1]</sup>,也有结合当下热门的机器学习框架的服务推荐方法<sup>[2]</sup>,以及面向异质信息网络的推荐方法<sup>[3]</sup>。

传统的推荐方法(如协同过滤、矩阵分解)主要考虑用户和服务直接影响的关系(如评分、标注的标签、评论等)。但在现实中,这种直接的关系数据往往比较稀疏,随之而来的是冷启动等问题。为解决该问题,大家趋向于综合考虑用户与服务的多种关系和元素<sup>[4]</sup>。虽然综合考虑多种关系能提高服务推荐的质量,但是有效地协同各种关系仍面临诸多挑战。

网络嵌入(network embedding)作为一种方便有效的网络表征学习方法,不断受到关注,最近已经成为基于神经网络和深度学习的热门研究问题<sup>[5-6]</sup>。网络嵌入学习能够将信息网络投影到低维向量空间 $\mathbb{R}^d$ ,可以有效地提取出信息网络的多元特征。并将这些特征融入节点的嵌入向量。利用嵌入向量进行服务推荐比直接机械地利用信息网络的结构性信息更加高效。不同结构的关系网络适用的网络嵌入方法不同。对于同质信息网络,通过随机游走的方法将网络转换为顶点序列库,然后借用文本特征学习模型训练是一种常用的方法。对于异质信息网络建模,将随机游走直接应用在异质信息网络的效果并不理想<sup>[7]</sup>。

大多数异质信息网络嵌入方法都是通过在网络中游走产生元路径,并将不同的元路径分别进行嵌入学习<sup>[8]</sup>。现在有很多代表性的网络嵌入算法:Node2vec<sup>[8]</sup>、LINE (large-scale information network embedding)<sup>[9]</sup>、SDNE (structural deep network embedding)<sup>[10]</sup>和BINE (bipartite network embedding)<sup>[11]</sup>等。

现在也有学者提出基于网络嵌入的服务推荐,已有研究存在的不足:如在文献[12-13]中,作者将网络嵌入方法成功应用于同质信息网络。该方法通过得到的用户嵌入向量找出相似集群,基于相似集群进行服务推荐,但该类方法忽略了服务本身的特征。文献[3]通过构建复杂异质信息网络,并通过构建元路径序列,分别得到用户和服务的嵌入向量,最后训练优化用户与服务嵌入向量的映射模型,但是这种方法得到的是不同向量空间的嵌入向量。不同向量空间的嵌入向量之间没有直接影响关系。需要借助矩阵分解或者深层映射等方法,建立各向量空间之间的联系。

因此,这些学者并没有从根源上将多个关系网络协同考虑。而且异质信息网络具有特异性,针对一种特定的服务类型,不同的服务类型其异质信息网络的结构是完全不同的,因此该方法不具有良好的鲁棒性和拓展性。因此,有必要解决将多个不同种类的关系网络嵌入到同一个低维向量空间,得到统一的向量表示。但是现有的网络嵌入方法都只针对某一种特定的信息网络,比如同质信息网络、异质信息网络等。

针对上述问题,本文提出一种多网络混合嵌入的服务推荐方法(service recommendation method based on multi-network hybrid embedding, MNHER),将多种关系网络的节点嵌入到同一个向量空间,得到统一的向量表示。使得同类节点的嵌入向量包含多关系网络的特征,不同类型节点的嵌入向量包含直接的影响关系,并且考虑到方法可扩展性,将用户与服务的关系分为两类,如图1所示。一种是垂直关系:指用户与服务的直接关联,如图中直线所示。这种关系虽然是稀疏的,但是能直接地反映用户的偏好特征。另一种是平行关系:指用户之间、服务之间的相互影响,即图中弧线所示。例如用户之间的社交关系、服务之间的共享标签关系。这些关系可以间接地为服务推荐提供更多的依据。




图1 用户-服务关系网络

Fig.1 User-service network

本文的主要贡献可概括为:

(1) 提出一种多网络混合嵌入方法,将两种不同类型的节点映射到同一个低维向量空间,并适用于多种不同的关系网络。

(2) 提出一种基于多网络混合嵌入的服务推荐模型MNHER。对用户-服务评分关系网络、用户社交关系网络和服务标签共有网络进行学习。

(3) 在三个公开数据集上与多种代表性的服务推荐方法进行对比分析。多角度验证了本文方法的有效性和合理性,也讨论了不同的关系网络对推荐质量的影响。

## 1 相关工作

### 1.1 基于标签的服务推荐

在Web服务中流行对服务标注标签,比如豆瓣电影网站会对电影标注类型、语言、作者、演员和年代等标签,豆瓣读书网站会对书籍标注作者、语言、类型和年代等标签。这些标签可帮助用户获取到服务的基本特征,而且这些标签同样也可以代表用户的喜好。因此涌现出很多基于服务标签的服务推荐方法。

Luo等人<sup>[14]</sup>提出了一种基于coSVD(co-singular value decomposition)的模型来丰富单一数据源,可以有效控制矩阵分解中存在的过拟合问题。用户偏好不仅通过评级数据而且还通过标签数据来丰富。该方法可用于各类专家智能系统中解决上述问题,如广告推荐、评分网站、社交媒体平台等,这些都需要用户输入相对较大的数据。Shi等人<sup>[15]</sup>使用基于媒体元数据的主题向量来比较被重新创建媒体和被重新创建媒体的主题之间的相似性,从而预测用户对被搜索媒体单元的媒体再创建服务的评分。在不消耗大量时间的情况下,提高了效率,降低了MAE(mean absolute error)。为了解决冷启动和简化问题,Zhang等人<sup>[16]</sup>提出了一种基于矩阵分解的混合标签多样化推荐算法,挖掘用户现有的偏好和条目的相关性。结果表明,该方法能够在保证准确性的基础上提高标签推荐的覆盖率和多样性。为了解决服务推荐效率低下的问题,Qiang等人<sup>[17]</sup>提出了一种检测重叠社区结构的多标签传播算法,然后利用重叠的社区结构向目标用户推荐项目。结果表明,该方法提高了推荐效率,在线精度基本不变。

在基于标签的服务推荐中,TF-IDF(term frequency-inversion document frequency)是一种常用的信息检索和数据挖掘的加权算法,通常用于评价用户之间的相似度。Ba等人<sup>[18]</sup>使用TF-IDF技术计算目标用户与其每个邻居之间的相似度,而不考虑公共项的详细评级。该方法可以提高推荐系统的精度、实时性和可扩展性。为了帮助用户找到与他们的兴趣相关的新标签,Otsuka等人<sup>[19]</sup>构建了一个TF-IDF的变体——HF-IHU(hashtag frequency-inverse hashtag ubiquity)排名方案。在Twitter大数据集上的实验表明,与TF-IDF技术相比,该方法更加稳定可靠。

### 1.2 基于社交关系的服务推荐

社交应用在当今互联网环境下迅猛发展,用户可以拥有自己的社交关系网络。研究证明社交关系对挖掘用户喜好有积极作用,并且社交关系具有明显的集群聚类特征,同一个集群的相似用户具有更大喜好交集<sup>[20]</sup>,因此各种有关相似用户聚类 and 相似用户挖掘的个性化推荐系统应运而生,推荐系统用于准确主动地为用户提供潜在的信息或服务。Wang等人<sup>[20]</sup>提出了一种基于EM(expectation-maximization)的算法,该算法可同时对社交网络中的强弱关系进行分类,赋予强类型社交朋友更高的影响力。然而,考虑到原始社交网络的高度稀疏性,提取的关系过



于稀疏,无法有效提高推荐性能。

Zhou等人<sup>[21]</sup>提出了一种基于分布式在线学习的云辅助差分推荐系统。考虑到社交媒体数据的稀疏性和异构性,另提出了一种新的几何差分模型,可以大大降低性能损失。Hu等人<sup>[22]</sup>提出了一种功能张量分解方法来对用户和时尚商品之间的交互进行建模。使用基于梯度上升的方法来学习非线性目标函数,以将特征向量从特征空间映射到一些低维潜在空间。通过对来自流行时尚的社交网络的真实世界用户数据进行的大量实验,验证了该算法的有效性。协同过滤是一种广泛采用的推荐方法,但是稀疏数据和冷启动用户通常是提供高质量推荐的障碍。为了解决这些问题,Yang等人<sup>[23]</sup>提出了通过集成用户提供的稀疏评级数据和相似用户之间的稀疏社会信任网络来提高协同过滤的性能。该方法采用矩阵分解技术,根据用户的信任关系将其映射到低维潜在特征空间,目的是更准确地反映用户对自己意见形成的相互影响,并更好地学习用户对高质量推荐的偏好模式。Jiang等人<sup>[24]</sup>提出一种基于社会关系和时间影响的个性化服务推荐,综合考虑了用户熟悉度和偏好相似度。结果表明,该方法优于一般的基于标签和基于社会的推荐方法,不用依赖于用户的历史数据,可以满足为新用户和不活跃用户进行服务推荐的需求。

### 1.3 基于表征学习的服务推荐

推荐系统作为互联网产品的一项重要技术,能够帮助用户获取所需信息。近年来涌现了很多对于复杂网络分析的工作,表征学习以其可以得到隐含的向量表示,而被大量应用于推荐领域。Liu等人<sup>[25]</sup>提出了一种用于隐式反馈推荐的深度学习框架。在这个框架中,同时通过node2vec学习用户和项目的分布式表示,以改进负抽样策略。并开发了一个深度神经网络推荐模型来集成用户特征、产品特征和交互特征。在两个真实数据集上进行的实验证明了该框架和方法的有效性。Zhuang等人<sup>[26]</sup>提出了一种新的表征学习框架——双自编码推荐ReDa(representation learning via dual-autoencoder)。通过自动编码器同时学习用户和项目的隐性表示,并通过学习用户和项目的表示最小化训练数据的偏差,该方法能够一定程度上解决矩阵分解存在的缺陷。针对协同过滤算法只使用商品用户评价矩阵而不考虑语义的问题,Wu等人<sup>[27]</sup>提出了一种基于表征推荐算法,利用知识图表征学习方法,将已有的语义数据嵌入到低

维语义空间中。通过计算项目间的语义相似度,将项目间的语义信息集成到协同过滤推荐中,克服了协同过滤算法不考虑项目语义信息的缺点,在语义层次上提高了协同过滤推荐的效果。

Tang等人<sup>[9]</sup>提出了一种新型网络嵌入方法,分析了随机游走方法存在的问题,利用负采样机制缓解随机梯度下降过程中存在的缺陷,提高了网络嵌入的有效率。Wu等人<sup>[28]</sup>提出了一种新的基于上下文感知的用户项目表示学习模型(context-aware user-item representation learning, CARL)。根据给定用户-项对的单个潜在特征和潜在特征交互,导出它们的联合表示,然后CARL采用因子分解机,在用户-项对的基础上进一步建立高阶特征交互模型,进行等级预测。实验表明,CARL有更显著的评级预测效果。Kong等人<sup>[29]</sup>利用近年来文本和网络表征学习在无监督特征设计方面的研究成果,开发了一个科学论文推荐系统VOPRec,满足用户科学论文准确推荐的需求。Salah等人<sup>[30]</sup>提出了一种新的用户偏好和项目上下文生成模型——概率协同表征学习(probabilistic collaborative representation learning, PCRL)。依赖于贝叶斯泊松分解(Bayesian Poisson factorization)对用户-项目交互进行建模,并使用多层潜在变量体系结构从上下文中学习项目的表征形式。作者在多个大型数据集上验证了该模型的优越性。为了有效地捕获用户的偏好,Han等人<sup>[31]</sup>设计了一种基于异构网络嵌入和卷积神经网络的方法,分别从用户-项目交互结构和查看文本中学习用户和项目的特征表示。此外,Shi等人<sup>[32]</sup>设计了一种基于元路径的随机游走策略来生成网络嵌入的节点数,并将其集成到扩展的MF(matrix decomposition)模型中。验证了该模型对冷启动问题的有效性和能力,结果表明转换后的嵌入信息确实提高了推荐性能。

## 2 多网络混合嵌入的服务推荐

本文方法分为三部分:(1)构建信息网络。构建用户-服务异质信息网络、服务标签共有网络 and 用户社交关系网络。(2)多网络混合嵌入。将上一步中得到的三类信息网络嵌入到同一个低维向量空间,得到用户和服务的嵌入向量。(3)基于用户的协同推荐。利用学习到的用户和服务嵌入向量进行服务评分预测,并综合考虑相似用户的喜好影响,最终推荐Top-K个服务序列,如图2所示。比如在豆瓣电影中需要为用户推荐其感兴趣的电影。可以根据用户对

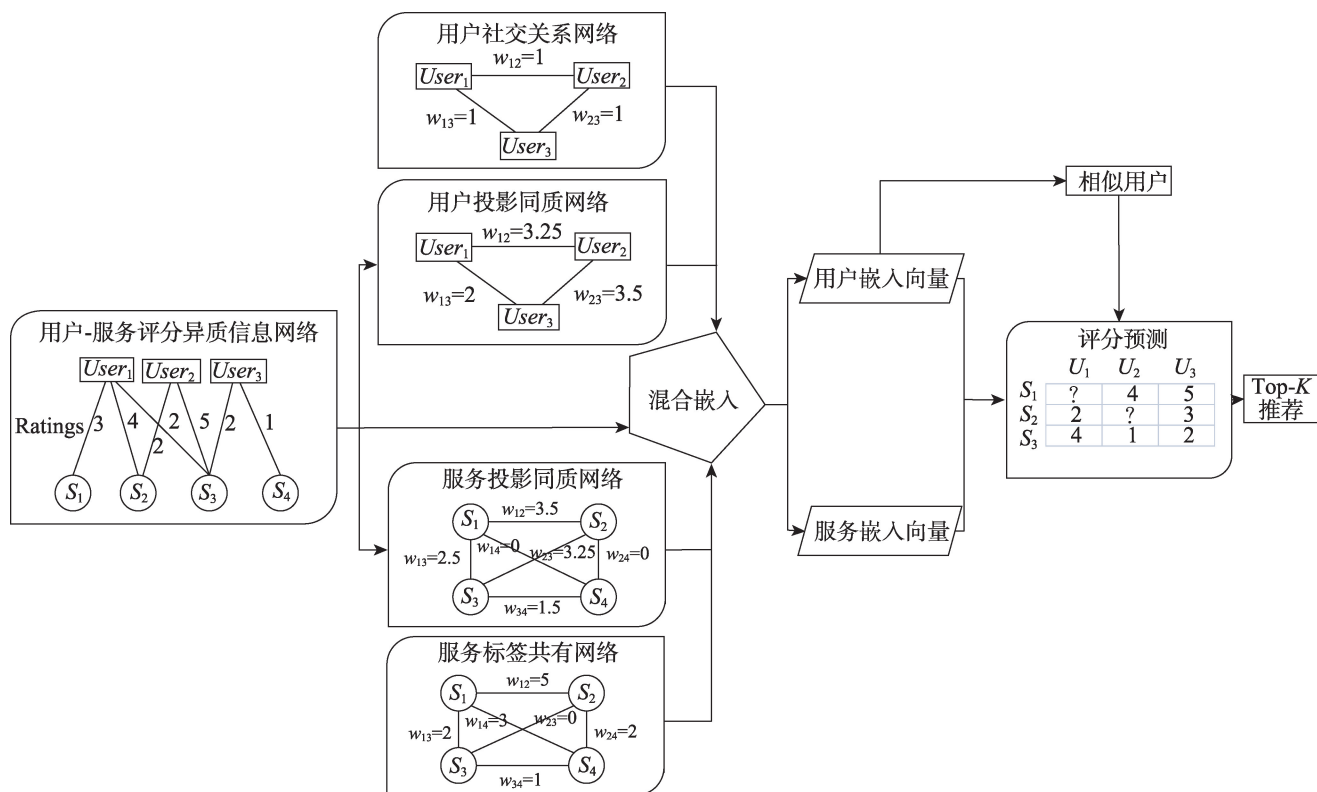


图2 多网络混合嵌入学习模型

Fig.2 Multi-network hybrid embedding learning model

电影的打分构建用户-电影异质信息网络,利用电影的类型信息构建电影标签共有网络,根据用户之间的关注和交互信息构建用户社交网络。然后通过多网络混合嵌入得到用户和电影的嵌入向量,最后利用基于用户的协同推荐为用户推荐其感兴趣的电影。

### 2.1 构建信息网络

用户-服务评分异质信息网络 (user-service heterogeneous information network): 异质信息网络简单的理解是指网络中节点或连边的种类在两种及以上的网络。在本文中,根据用户对服务的评分信息,可构建用户-服务异质信息网络  $Net_{HIN}=(U,S,W)$ , 其中  $U=\{u_1,u_2,\dots,u_m\}$  为用户集,  $S=\{s_1,s_2,\dots,s_n\}$  为服务集,  $W=\{w_{ij}=r_{ij}|i=1,2,\dots,n,j=1,2,\dots,m\}$  为连边集, 当  $r_{ij} \neq 0$  时,代表用户  $u_i$  在服务  $s_j$  上标注的评分为  $r_{ij}$ 。

服务标签共有网络 (service co-tag network): 现实中,每个服务都会被分配多个标签。通过计算不同服务之间共用的标签个数可以构建服务标签共有网络  $Net_{co-tag}=(S,E)$ 。服务  $s_i$  和  $s_j$  的连边  $e'_{ij}=w_{ij}$ ,  $w_{ij}$  为两个服务共有的标签个数。

用户社交网络 (user social network): 现有很多公共服务平台,比如 Yelp 和豆瓣,用户通过这些平台不

仅可以对不同的服务进行评分,也可以跟其他用户交流。根据提供的用户交互数据,假如一个用户  $u_i$  关注 (contact) 或 followed 了另一个用户  $u_j$ , 则可视两个用户之间存在一种社交关联。因此,用户之间的社交关系网络  $Net_{social}=(U,E)$ ,  $U=\{u_i|i=1,2,\dots,m\}$  为用户集,  $E=\{e_{ij}|i,j=1,2,\dots,m\}$  为连边集,考虑到虚拟社交平台中用户之间的亲密程度和影响权重是一个复杂的因素。把用户之间的社交网络只作为一个非加权的网络处理。即,若用户  $u_i$  和  $u_j$  之间有交互关系, 则  $e_{ij}=1$ , 否则为 0。

### 2.2 多网络混合嵌入

将网络中的节点投影到低维向量空间  $\mathbb{R}^d$  的方法,已在机器学习领域得到有效验证。网络嵌入方法可以有效地提取出信息网络的三维特征,并将这些特征融入节点的嵌入向量。

将多网络建模分为两个层次:垂直关系建模和平行关系建模。

#### 2.2.1 垂直关系建模

垂直关系是指用户和服务之间直接的关联关系。在异质信息网络  $Net_{HIN}=(U,S,W)$  中两个节点  $u_i$  与  $s_j$  之间存在直接的连边。利用节点之间的局部邻

近度对这种显性关系建模。节点  $u_i$  与  $s_j$  联合的概率定义为:

$$p(u_i, s_j) = \frac{w_{ij}}{\sum w_{ij}} \quad (1)$$

其中,  $w_{ij}$  表示  $u_i$  与  $s_j$  连边的权重。显然, 若  $w_{ij}$  值越大, 则  $u_i$  与  $s_j$  联合的概率越大。借鉴当下流行的 word2vec<sup>[33]</sup>模型, 利用 Sigmoid 函数将嵌入向量之间的联系转换成概率:

$$\hat{p}(u_i, s_j) = \frac{1}{1 + \exp(-\mathbf{u}_i^T \cdot \mathbf{s}_j)} \quad (2)$$

其中,  $\mathbf{u}_i, \mathbf{s}_j \in \mathbb{R}^d$  都是节点  $u_i$  与  $s_j$  的嵌入向量。通过最小化  $p(u_i, s_j)$  与  $\hat{p}(u_i, s_j)$  之间的差异, 学习得到嵌入向量  $\mathbf{u}_i, \mathbf{s}_j$ :

$$\text{minimize } O_1 = KL(\hat{p}(u_i, s_j) || p(u_i, s_j)) \infty - \sum_{e_{ij} \in E} w_{ij} \lg \hat{p}(u_i, s_j) \quad (3)$$

通过最小化  $O_1$ , 两个节点的连边权重越大, 两个节点的向量的联系也越紧密。因此, 可以将两个节点之间的显性关系融入到节点的嵌入向量中。

### 2.2.2 平行关系建模

平行关系是指同一类节点之间互相影响的关系, 即用户之间的社交网络和服务之间的标签共有网络等。可以通过对异质信息网络投影, 得到用户和服务的投影网络  $Net_{\text{HIN}}^U$ 、 $Net_{\text{HIN}}^S$ 。参考 PageRank<sup>[34]</sup>, 将投影操作定义为:

$$w_{ij}^U = \frac{\sum_{k \in S} \frac{w_{ik} + w_{kj}}{2}}{|S|}, w_{ij}^S = \frac{\sum_{k \in U} \frac{w_{ik} + w_{kj}}{2}}{|U|} \quad (4)$$

通过式(4)的处理后, 可分别得到  $\mathbf{W}^U$ 、 $\mathbf{W}^S$  两个投影矩阵——两个同质信息网络。这两个同质信息网络可以进一步转化成节点序列进行嵌入学习。

随机游走方法是最常用的将网络转化成节点序列的方法, 但传统的随机游走方法 DeepWalk 并不能有效地保留网络中节点的分布特征。BINE<sup>[11]</sup>通过考虑节点的中心性进行优化, node2vec<sup>[8]</sup>通过考虑局部的网络结构进行优化。本文将以上两种优化方法进行合并, 提出一种更有效的随机游走算法, 如算法1所示。

#### 算法1 WalkGenerator( $Net, d, mw, p$ )

输入: 同质信息网络  $Net = (V, E)$ , 嵌入向量维度  $d$ , 最短步长  $mw$ , 控制游走结束的概率参数  $p$ 。

输出: 一个节点序列集合  $C$ 。

1. 计算节点中心性:  $I = \text{Measure}(Net)$ ;
2. For each 节点  $v_i \in V$  do
3.  $l = mw \cdot (1 + I(v_i))$ ;

4. For  $i = 0$  to  $l$  do
5.  $C_{v_i} = \text{INode2vecWalk}(Net, v_i, p)$ ;
6. Add  $C_{v_i}$  to  $C$ ;
7. Return  $C$ ;

保留局部网络结构的计算机制, 将固定的游走次数修改为根据节点中心性动态计算, 节点中心性度量  $\text{Measure}(Net)$  标准有很多, 本文实验部分会进行比较分析。增加控制游走停止的概率参数  $p$ , 使产生的节点序列长度不规则, 其中  $mw$  是最低游走次数。

对  $Net_{\text{HIN}}^U$ 、 $Net_{\text{HIN}}^S$ 、 $Net_{\text{social}}$  和  $Net_{\text{co-tag}}$  分别利用改进的随机游走算法得到节点序列  $C^U$ 、 $C^S$ 、 $C^{\text{UR}}$  和  $C^{\text{SR}}$  后, 利用 Skip-gram 文本嵌入模型对得到的节点序列进行嵌入学习, 该模型的思想是在同一序列中的节点的嵌入向量应该是相似的。以  $C^U$  为例, 对于节点  $u_i \in U$  和节点序列  $seq^U \in C^U$ , 应该最大化  $seq^U_{u_i}$  与  $u_i$  联合的条件概率, 经对数优化学习之后的目标函数如下:

$$\text{maximize } O_2 = \sum_{u_i \in U} \sum_{k=1}^{|seq^U_{u_i}|} \lg p_{U^U}(u_k | u_i) \quad (5)$$

其中,  $seq^U_{u_i}$  与节点  $u_i$  同属一个节点序列的节点集合。同理, 对于  $C^S$ 、 $C^{\text{UR}}$  和  $C^{\text{SR}}$  可得目标函数:

$$\text{maximize } O_3 = \sum_{s_j \in S} \sum_{k=1}^{|seq^S_{s_j}|} \lg p_S(s_k | s_j) \quad (6)$$

$$\text{maximize } O_4 = \sum_{u_i \in U} \sum_{k=1}^{|seq^{\text{UR}}_{u_i}|} \lg p_{\text{UR}}(u_k | u_i) \quad (7)$$

$$\text{maximize } O_5 = \sum_{s_j \in S} \sum_{k=1}^{|seq^{\text{SR}}_{s_j}|} \lg p_{\text{SR}}(s_k | s_j) \quad (8)$$

参照多种代表性的网络嵌入方法<sup>[8-11]</sup>, 利用 softmax 函数将  $p_U(u_k | u_i)$ 、 $p_S(s_k | s_j)$ 、 $p_{\text{UR}}(u_k | u_i)$  和  $p_{\text{SR}}(s_k | s_j)$  参数化为:

$$p_U(u_k | u_i) = \frac{\exp(\mathbf{u}_i^T \cdot \mathbf{u}_k)}{\sum_{n=1}^{|U|} \exp(\mathbf{u}_i^T \cdot \mathbf{u}_n)} \quad (9a)$$

$$p_S(s_k | s_j) = \frac{\exp(\mathbf{s}_j^T \cdot \mathbf{s}_k)}{\sum_{n=1}^{|S|} \exp(\mathbf{s}_j^T \cdot \mathbf{s}_n)} \quad (9b)$$

$$p_{\text{UR}}(u_k | u_i) = \frac{\exp(\mathbf{u}_i^T \cdot \mathbf{u}_k)}{\sum_{n=1}^{|U|} \exp(\mathbf{u}_i^T \cdot \mathbf{u}_n)} \quad (9c)$$

$$p_{\text{SR}}(s_k | s_j) = \frac{\exp(\mathbf{s}_j^T \cdot \mathbf{s}_k)}{\sum_{n=1}^{|S|} \exp(\mathbf{s}_j^T \cdot \mathbf{s}_n)} \quad (9d)$$



并用利用负采样对式(9)进行优化,其思想是利用负采样代替全局参数进行训练,从而减少大量的参数训练带来的资源消耗。参考文献[8]中的方法,以  $p_U(u_k|u_i)$  为例,可利用负采样改写为:

$$p_U(u_k|u_i) = \prod_{z \in \{u_k\} \cup N_{seq}^{ns}(u_i)} P(z|u_i) \quad (10)$$

其中,  $N_{seq}^{ns}(u_i)$  表示以  $u_i$  为中心的负采样节点集。

$$P(z|u_i) = \begin{cases} q(\mathbf{u}_i^T \cdot \boldsymbol{\theta}_z^H), z \in seq_{u_i}^U \\ 1 - q(\mathbf{u}_i^T \cdot \boldsymbol{\theta}_z^H), z \in N_{seq}^{ns}(u_i) \end{cases} \quad q(x) = \frac{1}{1 + e^{-x}} \quad (11)$$

其中,当  $z \in seq_{u_i}^U$ ,即  $z$  与  $u_i$  同属一个节点序列,则  $z$  与  $u_i$  的嵌入向量应趋于相似,因此最大化其条件概率。 $z \in N_{seq}^{ns}(u_i)$  即  $z$  为  $u_i$  的负采样节点,则  $z$  为  $u_i$  的嵌入向量应趋于不同,因此最小化其条件概率,公式中通过将其转为求互补实现最小化。 $\boldsymbol{\theta}_z^H$  表示  $z$  的嵌入向量,为了区别表示,方便读者理解。同理,对于  $p_S(s_k|s_j)$ 、 $p_{UR}(u_k|u_i)$  和  $p_{SR}(s_k|s_j)$  可以得到经负采样优化之后的概率参数化公式,不再赘述。

### 2.2.3 联合优化

为了从纵向和横向两个角度将多网络中的用户节点和服务节点联合嵌入同一个向量空间,将其目标函数结合,提出一个联合训练的目标函数:

$$\max f = \alpha(O_2 + O_4) + \beta(O_3 + O_5) - \omega O_1 \quad (12)$$

将联合目标函数按照纵向和横向的关系分为三部分,分别通过权衡参数  $\alpha$ 、 $\beta$ 、 $\omega$  连接。考虑到本文方法的普适性,将横向关系分为用户和服务两类。并且将最小化  $O_1$  转化为与其他目标函数一致的求最大化。

为了求联合目标函数最大值,利用随机梯度上升(stochastic gradient ascent algorithm, SGA)去优化。由于联合目标函数的三部分是不同的目标函数,设计了一个组合的训练模式。对不同的目标函数也给出了详细的训练计算方法,如算法2所示。

#### 算法2 HINE训练

输入:异质信息网络  $Net_{HIN} = (U, S, W)$ , 用户社交关系网络  $Net_{social} = (U, E)$ , 服务标签共有网络  $Net_{co-lag} = (S, E)$ , 采样窗口大小  $ws$ , 负采样集合大小  $nn$ , 嵌入向量维度  $d$ , 最短步长  $mw$ , 游走停止的概率参数  $p$ 。

输出:节点嵌入向量集合  $U$  和  $S$ 。

1.  $Net_{HIN}^U, Net_{HIN}^S = \text{Projection}(Net_{HIN})$  w.r.t Eq(4);
2. Initialize embedding vectors  $\mathbf{u}_i, \mathbf{u}_i^H, \mathbf{u}_i^R, \mathbf{s}_j^H, \mathbf{s}_j^R$  and  $\mathbf{s}_j$ ;
3. Initialize context vectors  $\boldsymbol{\theta}_z^H, \boldsymbol{\theta}_z^R$  and  $\boldsymbol{\gamma}_z^H, \boldsymbol{\gamma}_z^R$ ;
4.  $C^U = \text{WalkGenerator}(Net_{HIN}^U, d, mw, p)$ ;
5.  $C^S = \text{WalkGenerator}(Net_{HIN}^S, d, mw, p)$ ;

$$6. C^{UR} = \text{WalkGenerator}(Net_{social}, d, mw, p);$$

$$7. C^{SR} = \text{WalkGenerator}(Net_{co-lag}, d, mw, p);$$

8. For each edge  $(u_i, s_j, w_{ij}) \in Net_{HIN}$  do

9. Update  $\mathbf{u}_i$  and  $\mathbf{s}_j$  using Equations (13), (14)

$$10. \mathbf{u}_i^H = \mathbf{u}_i;$$

11. For each  $(u_i, u_c^h)$  in the context  $seq \in C^U$  do

12. Negative sampling to generate  $N_{seq}^{ns}(u_i)$ ;

13. Update  $\mathbf{u}_i^H$  using Equation (15);

14. Update  $\boldsymbol{\theta}_z^H$  using Equation (19) where  $x \in seq \cup$

$N_{seq}^{ns}(u_i)$ ;

$$15. \mathbf{u}_i^R = \mathbf{u}_i;$$

16. For each  $(u_i, u_c^R)$  in the context  $seq \in C^{UR}$  do

17. Negative sampling to generate  $N_{seq}^{ns}(u_i)$ ;

18. Update  $\mathbf{u}_i^R$  using Equation (16);

19. Update  $\boldsymbol{\theta}_z^R$  using Equation (20) where  $x \in seq \cup$

$N_{seq}^{ns}(u_i)$ ;

$$20. \mathbf{u}_i = \delta \cdot \mathbf{u}_i^H + (1 - \delta) \cdot \mathbf{u}_i^R;$$

$$21. \mathbf{s}_j^H = \mathbf{s}_j;$$

22. For each  $(s_j, s_c^h)$  in the context  $seq \in C^S$  do

23. Negative sampling to generate  $N_{seq}^{ns}(s_j)$ ;

24. Update  $\mathbf{s}_j^H$  using Equation (17);

25. Update  $\boldsymbol{\gamma}_z^H$  using Equation (21) where  $x \in seq \cup$

$N_{seq}^{ns}(s_j)$ ;

$$26. \mathbf{s}_j^R = \mathbf{s}_j;$$

27. For each  $(s_j, s_c^R)$  in the context  $seq \in C^{SR}$  do

28. Negative sampling to generate  $N_{seq}^{ns}(s_j)$ ;

29. Update  $\mathbf{s}_j^R$  using Equation (18);

30. Update  $\boldsymbol{\gamma}_z^R$  using Equation (22) where  $x \in seq \cup$

$N_{seq}^{ns}(s_j)$ ;

$$31. \mathbf{s}_j = \delta \cdot \mathbf{s}_j^H + (1 - \delta) \cdot \mathbf{s}_j^R;$$

32. Return vertex embedding matrices  $U$  and  $S$ .

算法2辅助说明整个联合训练的过程。其中第1行为对异质信息网络投影;2~3行为初始化各网络的嵌入向量;4~7行为对于4个横向关系的网络通过随机游走得到序列集;8~32行为联合训练的过程。

**步骤1** 纵向关系,如两个节点  $u_i$  与  $s_j$ ,通过正向累加梯度(SGA)训练嵌入向量  $\mathbf{u}_i$ 、 $\mathbf{s}_j$  使  $-\omega O_1$  最大化。对于具体的计算方法如下:

$$\mathbf{u}_i = \mathbf{u}_i + \lambda \cdot \left( \omega \cdot w_{ij} \cdot \frac{\exp(-\mathbf{u}_i^T \cdot \mathbf{s}_j)}{1 + \exp(-\mathbf{u}_i^T \cdot \mathbf{s}_j)} \cdot \mathbf{s}_j \right) \quad (13)$$

$$\mathbf{s}_j = \mathbf{s}_j + \lambda \cdot \left( \omega \cdot w_{ij} \cdot \frac{\exp(-\mathbf{u}_i^T \cdot \mathbf{s}_j)}{1 + \exp(-\mathbf{u}_i^T \cdot \mathbf{s}_j)} \cdot \mathbf{u}_i \right) \quad (14)$$

其中,  $\lambda$  为学习率。括号内的部分为  $-\omega O_1$  的梯度,

推导过程省略。

**步骤2** 横向关系,因为这类关系的目标函数类型相同,所以采用相同的参数训练方法。以  $O_2$  为例,对于  $u_i \in U$  和  $z \in \{u_k\} \cup N_{seq}^{ns}(u_i)$ ,通过正向累加梯度(SGA)训练嵌入向量  $\mathbf{u}_i^H$ 、 $\theta_z^H$  使  $O_2$  最大化。对于具体的计算方法如下:

$$\mathbf{u}_i^H = \mathbf{u}_i^H + \lambda \cdot \sum_{z \in \{u_k\} \cup N_{seq}^{ns}(u_i)} \alpha \cdot [b(z, u_i) - \text{sig}(\mathbf{u}_i^{HT} \theta_z^H)] \cdot \theta_z^H \quad (15)$$

其中,  $b(z, u_i)$  判断  $z$  是否属于  $N_{seq}^{ns}(u_i)$ ,当  $z \in N_{seq}^{ns}(u_i)$  时值为0,否则为1。 $\text{sig}$  表示 Sigmoid 函数。同理可得:

$$\mathbf{u}_i^R = \mathbf{u}_i^R + \lambda \cdot \sum_{z \in \{u_k\} \cup N_{seq}^{ns}(u_i)} \alpha \cdot [b(z, u_i) - \text{sig}(\mathbf{u}_i^{RT} \theta_z^R)] \cdot \theta_z^R \quad (16)$$

$$\mathbf{s}_j^H = \mathbf{s}_j^H + \lambda \cdot \sum_{z \in \{s_k\} \cup N_{seq}^{ns}(s_j)} \beta \cdot [b(z, s_j) - \text{sig}(\mathbf{s}_j^{HT} \gamma_z^H)] \cdot \gamma_z^H \quad (17)$$

$$\mathbf{s}_j^R = \mathbf{s}_j^R + \lambda \cdot \sum_{z \in \{s_k\} \cup N_{seq}^{ns}(s_j)} \beta \cdot [b(z, s_j) - \text{sig}(\mathbf{s}_j^{RT} \gamma_z^R)] \cdot \gamma_z^R \quad (18)$$

其中,  $\theta_x^H$ 、 $\theta_x^R$ 、 $\gamma_x^H$ 、 $\gamma_x^R$  为不同网络中的抽样集中节点的嵌入向量。 $\mathbf{u}_i$ 、 $\mathbf{s}_j$  的上标也用于标识不同网络。对于抽样集节点嵌入向量的训练方法如下:

$$\theta_z^H = \theta_z^H + \lambda \cdot \alpha \cdot [b(z, u_i) - \text{sig}(\mathbf{u}_i^{HT} \theta_z^H)] \cdot \mathbf{u}_i^H \quad (19)$$

$$\theta_z^R = \theta_z^R + \lambda \cdot \alpha \cdot [b(z, u_i) - \text{sig}(\mathbf{u}_i^{RT} \theta_z^R)] \cdot \mathbf{u}_i^R \quad (20)$$

$$\gamma_z^H = \gamma_z^H + \lambda \cdot \beta \cdot [b(z, s_j) - \text{sig}(\mathbf{s}_j^{HT} \gamma_z^H)] \cdot \mathbf{s}_j^H \quad (21)$$

$$\gamma_z^R = \gamma_z^R + \lambda \cdot \beta \cdot [b(z, s_j) - \text{sig}(\mathbf{s}_j^{RT} \gamma_z^R)] \cdot \mathbf{s}_j^R \quad (22)$$

**步骤3** 步骤2完成后,得到  $\mathbf{u}_i^H$ 、 $\mathbf{u}_i^R$ 、 $\mathbf{s}_j^H$ 、 $\mathbf{s}_j^R$ 。将  $\mathbf{u}_i^H$ 、 $\mathbf{u}_i^R$  和  $\mathbf{s}_j^H$ 、 $\mathbf{s}_j^R$  分别通过线性组合赋值给  $\mathbf{u}_i$ 、 $\mathbf{s}_j$ 。然后进行下一轮操作。

### 2.3 基于用户的协同推荐

通过之前的多网络混合嵌入,得到用户和服务的嵌入向量  $\mathbf{E}_U$ 、 $\mathbf{E}_S$  后,因多网络混合网络嵌入方法已经把用户和服务节点嵌入到同一个向量空间,所以可以直接利用向量距离计算用户对服务的喜好程度。本文还增加了对相似集群的考虑。首先需要得到目标用户的相似用户集。利用余弦相似度衡量两个用户向量的相似度,计算方法如下:

$$\text{sim}(u_i, u_j) = \frac{\mathbf{u}_i \cdot \mathbf{u}_j}{\|\mathbf{u}_i\| \times \|\mathbf{u}_j\|} \quad (23)$$

构建了一个综合考虑相似用户喜好和目标用户喜好的评分预测器。对于目标用户  $u_i$  和服务  $s_j$ ,预测评分计算方式如下:

$$r_{ij} = \mu \frac{\sum_{u_i \in S(u_i)} \text{sim}(\mathbf{u}_i, \mathbf{s}_j)}{|S(u_i)|} + (1 - \mu) \cdot \text{sim}(\mathbf{u}_i, \mathbf{s}_j) \quad (24)$$

其中,相似用户的评分与目标用户的主观评分通过

权衡参数  $\mu$  链接,目的是能够有效地协同目标用户和相似用户的喜好。按照预测的评分大小取前 Top-K 个服务,最后可返回向目标用户  $u_i$  一个未曾关注过的服务序列。给出了算法3辅助说明基于相似用户的协同过滤过程。

#### 算法3 RecSystem( $u_i, E_U, E_S, k_{sim}, k_{ser}$ )

输入:嵌入向量集合  $E_U$  和  $E_S$ ,目标用户  $u_i$ ,推荐服务个数  $k_{ser}$ ,相似用户个数  $k_{sim}$ 。

输出:推荐的服务序列  $S_{rec}$ 。

1. 与目标用户向量  $\mathbf{u}_i$  的相似性计算:  $SIM_{u_i} = \text{Sim}(u_i, E_U)$ ;
- 相似用户集  $S(u_i) = \text{Top}(k_{sim}, SIM_{u_i})$ ;
2. For each vertex  $s_j \in E_S$  do
3.  $r_j = \text{Prediction}(u_i, s_j, S(u_i), E_U)$  w.r.t Eq(24);
4. Add  $r_j$  to  $R_{u_i}$ ;
5.  $S_{rec} = \text{Top}(k_{ser}, R_{u_i})$ ;
6. Return  $S_{rec}$ ;

## 3 实验分析

本文在3个公开数据集上进行实证分析,旨在回答以下研究问题:

**问题1** 与各种具有代表性的服务推荐方法相比,本文所提方法的推荐质量是否有所提高?

**问题2** 增加关系网络进行联合训练的方式是否对提高推荐质量有效?

**问题3** 考虑网络节点重要性的随机游走规则是否有利于节点的网络表征学习?

首先介绍实验的基本设置,然后依次回答以上的研究问题,最后说明本文方法存在的不足和未来的改进方向。

### 3.1 实验设置

#### 3.1.1 实验数据

实验数据来源于Github平台(<https://github.com/librahu/Heterogeneous-Information-Network-Datasets-for-Recommendation-and-Network-Embedding>)。Douan Movie数据集包括用户13 367个,服务(Movie)12 677个。Yelp数据集包括用户16 239个,服务(Business)14 284个。Movielens数据集包括用户1 370个,服务(Item)2 682个。实验数据信息如表1所示。

表1 实验数据集

Table 1 Experimental dataset

| 名称           | 用户     | 服务     | 评分数据      | 社交关系    |
|--------------|--------|--------|-----------|---------|
| Douban Movie | 13 367 | 12 677 | 1 068 278 | 4 085   |
| Yelp         | 16 239 | 14 284 | 198 397   | 158 590 |
| Movielens    | 1 370  | 2 682  | 100 000   | 47 150  |



数据集中,有用户对服务标注评分的行为数据,也有用户之间的交互数据。用户信息网络建模后,所得网络信息统计如表2。为提高实验数据的质量,过滤掉了关注服务个数少于5个的用户。

表2 信息网络数据统计情况

Table 2 Data statistics of information network

| 名称           | 网络       | 节点数    | 连边数    |
|--------------|----------|--------|--------|
| Douban Movie | 用户同质信息网络 | 10 279 | 78 311 |
|              | 服务同质信息网络 | 8 207  | 63 483 |
|              | 用户社交网络   | 9 032  | 3 357  |
| Yelp         | 同质信息网络   | 13 279 | 87 137 |
|              | 服务同质信息网络 | 12 540 | 69 257 |
|              | 用户社交网络   | 14 367 | 98 573 |
| Movielens    | 用户同质信息网络 | 1 170  | 23 367 |
|              | 服务同质信息网络 | 2 194  | 17 621 |
|              | 用户社交网络   | 1 037  | 45 889 |

### 3.1.2 评价指标

本文采用 F-Measure、NDGG、MRR 和 MAP 四个指标评价推荐系统的质量。指标的定义如下:

$F1@K$ : 是一种综合评价召回率 ( $Recall@K$ ) 和准确率 ( $Precision@K$ ) 的指标。对于目标用户  $u_i$ , 令  $S_i$  表示该用户真实选择的服务集合, 令  $S_i^{TopK}$  表示向该用户推荐的 Top-K 个服务,  $U_{test}$  为测试用户集。

$$F1@K = \frac{2 \times Precision@K \times Recall@K}{Precision@K + Recall@K} \quad (25)$$

$$Recall@K = \frac{1}{|U_{test}|} \sum_{i=1}^{|U_{test}|} \frac{|S_i \cap S_i^{TopK}|}{|S_i|} \quad (26)$$

$$Precision@K = \frac{1}{|U_{test}|} \sum_{i=1}^{|U_{test}|} \frac{|S_i \cap S_i^{TopK}|}{|S_i^{TopK}|} \quad (27)$$

$MAP@K$ : 是一种求平均准确率的指标。平均准确率越高, 推荐质量越高。定义如下:

$$MAP@K = \frac{1}{|U_{test}|} \sum_{i=1}^K Precision@i \quad (28)$$

$MRR@K$ : 是一种比较推荐命中的服务在推荐序列中的次序。平均次序越靠前, 推荐质量越高。令  $rank_i^j$  表示服务  $s_j$  在推荐序列中的次序。定义如下:

$$MRR@K = \frac{1}{|U_{test}|} \sum_{i=1}^{|U_{test}|} \sum_{j=1}^{|S_i|} \frac{1}{rank_i^j} \quad (29)$$

$NDGG@K$ : 是一种广泛应用于信息检索领域的评价指标, 也是一种求命中服务所在推荐序列的平均次序的指标, 值越大表示推荐质量越高。定义如下:

$$NDGG = \frac{1}{|U_{test}|} \sum_{u \in U_{test}} \frac{DCG_u}{IDCG_u} \quad (30)$$

$$DCG_u = \sum_{j=1}^{|S_j|} \frac{1}{lb(rank_i^j + 1)} \quad (31)$$

$$IDCG_u = \sum_{j=1}^{|S_j|} \frac{1}{lb(j + 1)} \quad (32)$$

### 3.1.3 基准方法

为了验证本文所提推荐方法的有效性, 本文分别选取基于用户-服务评分、基于社交关系和基于服务标签等不同类型的代表方法做基准。

#### (1) 基于用户-服务评分的推荐方法

Sorec<sup>[35]</sup> 是一种混搭用户评分矩阵和社交关系的协同推荐方法。SemRec<sup>[36]</sup> 是一种基于加权的用户评分异质信息网络的服务推荐方法。在服务推荐的过程中可以综合考虑用户-用户、用户-服务和用户-服务多种关系。

#### (2) 基于社交关系的推荐方法

本文方法在 BPR (Bayesian personalized ranking from implicit feedback)<sup>[37]</sup> 的基础上将社交关系分成亲密度不同的多个层次。改善了基于用户服务推荐存在的冷启动和数据稀疏问题。CPLR (collaborative pairwise learning to rank for personalized recommendation)<sup>[38]</sup> 是一种新型基于 pairwise ranking 的服务推荐方法。UPCC (user-based pearson correlation coefficient algorithm)<sup>[39]</sup> 是一种经典的基于相似用户的协同推荐算法。

#### (3) 基于服务标签的推荐方法

FM<sub>hnn</sub><sup>[40]</sup> 是一种基于上下文感知的矩阵分解器, 该方法在对用户-评分矩阵进行分解的同时考虑服务的标签信息。MVIR (multi-view item recommendation)<sup>[23]</sup> 是最近被提出的一种基于事项的服务推荐方法, 该方法从多视角挖掘事项的隐性特征。

### 3.1.4 参数设置

为了公平比较分析, 基准方法的所有参数均取其默认值。对于本文方法, 参照多个网络嵌入方法<sup>[8-9]</sup> 的参数设置, 将用户向量和用户-服务向量的维度设置为 128。将权衡参数  $\omega$  设定为 0.01,  $\alpha$  和  $\beta$  在区间 [0.01, 0.05, 0.10, 0.50, 1.00] 中取值。设置最短步长  $mw$  从 [4, 6, 8, 10, 12, 14] 中取值。设置负采样样本个数  $ns$  从 [1, 2, 4, 6, 8, 10] 中取值。设置游走停止的概率  $p$  从 [0.05, 0.10, 0.15, 0.20, 0.30, 0.40] 中取值。设置线性组合权重  $\delta = 0.6$ , 相似用户集  $|S(u)| = 25$ 。根据文献[8]中对学习率的讨论, 设置学习率为 0.1。在 3 个数据集上进行实证分析, 参数均保持一致。

### 3.2 推荐质量比较分析

为证明本文方法的有效性,分别在3个数据集上与基准方法进行比较实验,实验结果如表3所示。为

了便于观察,取训练比例为80%的实验数据绘制了增幅矩阵图,如图3所示。

实验结果显示,在绝大部分情况下,本文所提

表3 不同模型在三个数据集上的推荐质量比较

Table 3 Comparison of recommendation quality of different models on three datasets

| Dataset      | Train rate | Metrics | UPCC  | BPR   | FM <sub>MIN</sub> | Sorec        | SemRec | MVIR         | CPLR         | MNHER        |
|--------------|------------|---------|-------|-------|-------------------|--------------|--------|--------------|--------------|--------------|
| Yelp         | 80%        | F1@10   | 0.148 | 0.124 | 0.189             | 0.180        | 0.216  | 0.295        | 0.317        | <b>0.396</b> |
|              |            | NDGG@10 | 0.146 | 0.132 | 0.190             | 0.190        | 0.206  | 0.244        | 0.270        | <b>0.271</b> |
|              |            | MAP@10  | 0.167 | 0.076 | 0.132             | 0.165        | 0.209  | 0.350        | 0.254        | <b>0.358</b> |
|              |            | MRR@10  | 0.393 | 0.190 | 0.273             | 0.260        | 0.382  | 0.503        | 0.442        | <b>0.552</b> |
|              | 60%        | F1@10   | 0.145 | 0.122 | 0.156             | 0.177        | 0.189  | 0.289        | 0.321        | <b>0.389</b> |
|              |            | NDGG@10 | 0.143 | 0.129 | 0.157             | 0.186        | 0.202  | 0.217        | 0.204        | <b>0.243</b> |
|              |            | MAP@10  | 0.151 | 0.075 | 0.067             | 0.064        | 0.117  | 0.164        | 0.221        | <b>0.289</b> |
|              |            | MRR@10  | 0.386 | 0.186 | 0.552             | 0.549        | 0.483  | 0.625        | 0.515        | <b>0.631</b> |
|              | 40%        | F1@10   | 0.136 | 0.118 | 0.149             | 0.171        | 0.184  | 0.234        | 0.311        | <b>0.377</b> |
|              |            | NDGG@10 | 0.138 | 0.125 | 0.182             | 0.181        | 0.195  | 0.240        | 0.216        | <b>0.258</b> |
|              |            | MAP@10  | 0.134 | 0.073 | 0.064             | 0.062        | 0.113  | 0.207        | 0.216        | <b>0.283</b> |
|              |            | MRR@10  | 0.374 | 0.181 | 0.526             | 0.532        | 0.468  | 0.530        | 0.534        | <b>0.680</b> |
|              | 20%        | F1@10   | 0.132 | 1.104 | 0.164             | 0.161        | 0.172  | 0.262        | 0.292        | <b>0.353</b> |
|              |            | NDGG@10 | 0.130 | 0.117 | 0.103             | 0.108        | 0.183  | 0.219        | 0.183        | <b>0.241</b> |
|              |            | MAP@10  | 0.083 | 0.068 | 0.060             | 0.058        | 0.106  | 0.113        | 0.220        | <b>0.263</b> |
|              |            | MRR@10  | 0.350 | 0.169 | 0.458             | 0.499        | 0.438  | 0.500        | 0.417        | <b>0.508</b> |
| Douban Movie | 80%        | F1@10   | 0.108 | 0.119 | 0.152             | 0.150        | 0.170  | 0.260        | <b>0.345</b> | 0.319        |
|              |            | NDGG@10 | 0.118 | 0.043 | 0.257             | 0.272        | 0.173  | 0.222        | 0.393        | <b>0.428</b> |
|              |            | MAP@10  | 0.095 | 0.114 | 0.071             | 0.075        | 0.105  | 0.186        | 0.161        | <b>0.239</b> |
|              |            | MRR@10  | 0.494 | 0.242 | 0.439             | 0.447        | 0.552  | 0.605        | 0.524        | <b>0.655</b> |
|              | 60%        | F1@10   | 0.131 | 0.113 | 0.143             | 0.143        | 0.161  | <b>0.353</b> | 0.337        | 0.299        |
|              |            | NDGG@10 | 0.112 | 0.041 | 0.214             | <b>0.258</b> | 0.165  | 0.190        | 0.199        | 0.236        |
|              |            | MAP@10  | 0.072 | 0.108 | 0.051             | 0.072        | 0.100  | 0.170        | 0.135        | <b>0.194</b> |
|              |            | MRR@10  | 0.316 | 0.235 | 0.331             | 0.336        | 0.426  | 0.502        | 0.492        | <b>0.615</b> |
|              | 40%        | F1@10   | 0.086 | 0.106 | 0.156             | 0.149        | 0.160  | 0.293        | 0.296        | <b>0.338</b> |
|              |            | NDGG@10 | 0.100 | 0.192 | 0.052             | 0.054        | 0.163  | 0.199        | 0.345        | <b>0.406</b> |
|              |            | MAP@10  | 0.089 | 0.053 | 0.144             | 0.142        | 0.099  | 0.168        | 0.173        | <b>0.192</b> |
|              |            | MRR@10  | 0.384 | 0.225 | 0.365             | 0.416        | 0.513  | 0.632        | 0.554        | <b>0.693</b> |
|              | 20%        | F1@10   | 0.177 | 0.101 | 0.145             | 0.142        | 0.153  | 0.281        | 0.238        | <b>0.327</b> |
|              |            | NDGG@10 | 0.095 | 0.184 | 0.047             | 0.052        | 0.156  | 0.211        | 0.196        | <b>0.245</b> |
|              |            | MAP@10  | 0.085 | 0.051 | 0.130             | 0.136        | 0.095  | 0.169        | 0.147        | <b>0.184</b> |
|              |            | MRR@10  | 0.393 | 0.215 | 0.318             | 0.398        | 0.491  | 0.604        | 0.516        | <b>0.633</b> |
| Movielens    | 80%        | F1@10   | 0.105 | 0.112 | 0.111             | 0.119        | 0.143  | 0.209        | 0.205        | <b>0.282</b> |
|              |            | NDGG@10 | 0.109 | 0.105 | 0.103             | 0.108        | 0.102  | 0.179        | 0.206        | <b>0.257</b> |
|              |            | MAP@10  | 0.059 | 0.056 | 0.042             | 0.046        | 0.062  | 0.106        | 0.109        | <b>0.136</b> |
|              |            | MRR@10  | 0.169 | 0.181 | 0.208             | 0.293        | 0.238  | 0.293        | 0.272        | <b>0.469</b> |
|              | 60%        | F1@10   | 0.107 | 0.109 | 0.114             | 0.116        | 0.071  | 0.123        | 0.229        | <b>0.273</b> |
|              |            | NDGG@10 | 0.076 | 0.102 | 0.109             | 0.105        | 0.061  | 0.215        | 0.180        | <b>0.250</b> |
|              |            | MAP@10  | 0.033 | 0.054 | 0.047             | 0.045        | 0.030  | 0.068        | 0.125        | <b>0.132</b> |
|              |            | MRR@10  | 0.167 | 0.172 | 0.227             | 0.279        | 0.226  | 0.230        | 0.259        | <b>0.446</b> |
|              | 40%        | F1@10   | 0.136 | 0.104 | 0.106             | 0.111        | 0.068  | 0.194        | 0.220        | <b>0.262</b> |
|              |            | NDGG@10 | 0.109 | 0.098 | 0.094             | 0.103        | 0.059  | 0.138        | 0.192        | <b>0.239</b> |
|              |            | MAP@10  | 0.037 | 0.056 | 0.042             | 0.045        | 0.030  | 0.063        | 0.109        | <b>0.149</b> |
|              |            | MRR@10  | 0.159 | 0.207 | 0.216             | 0.227        | 0.224  | 0.291        | 0.237        | <b>0.442</b> |
|              | 20%        | F1@10   | 0.126 | 0.100 | 0.103             | 0.106        | 0.065  | 0.186        | 0.221        | <b>0.251</b> |
|              |            | NDGG@10 | 0.098 | 0.093 | 0.082             | 0.096        | 0.056  | 0.181        | 0.193        | <b>0.229</b> |
|              |            | MAP@10  | 0.046 | 0.047 | 0.050             | 0.038        | 0.025  | 0.091        | 0.091        | <b>0.113</b> |
|              |            | MRR@10  | 0.152 | 0.198 | 0.202             | 0.217        | 0.214  | 0.279        | 0.227        | <b>0.422</b> |

MNHER方法的四个指标均优于七种基准方法。特别是在数据集 MovieLens 上, MNHER 在四个指标有可观的提升。当训练比例为 80% 时, 相比 BPR 方法,  $F1@10$  的提升幅度为 151%,  $NDGG@10$  的提升幅度为 145%,  $MAP@10$  的提升幅度为 143%,  $MRR@10$  的提升幅度为 159%; 相比 Sorec 方法,  $F1@10$  的提升幅度为 137%,  $NDGG@10$  的提升幅度为 138%,  $MAP@10$  的提升幅度为 196%,  $MRR@10$  的提升幅度为 60%; 相比 MVIR 方法,  $F1@10$  的提升幅度为 35%,  $NDGG@10$  的提升幅度为 44%,  $MAP@10$  的提升幅度为 28%,  $MRR@10$  的提升幅度为 60%。因此, 本文方法的推荐质量均优于单独的基于某一种关系网络的服务推荐方法, 在服务推荐中考虑多种关系网络有助于提高推荐质量, 本文使用联合嵌入的方法得到的多个关系网络的特征向量, 包含了更多目标用户的正积极因素。

### 3.3 增加关系网络的比较分析

为比较分析在对二分异质信息网络的表征学习中增加考虑其他关系网络的影响, 在三个数据集上对四种不同的关系组合进行了实验分析, 即  $MNHER_{null}$  仅考虑用户与服务之间的垂直关系;  $MNHER_{social}$  增加用户之间的平行关系, 如社交关系;  $MNHER_{cotag}$  增加服务之间的平行关系, 如标签共有关系; MNHER 综合考虑以上用户之间和服务之间的平行关系。实验结果如表 4 所示, 为了便于观察, 绘制了增幅矩阵图, 如图 4 所示。得出以下几个结论。

首先, 经比较发现,  $MNHER_{null}$  方法在三个数据集下的服务推荐质量均为最低。增加考虑用户之间或者服务之间的平行关系能够提高整体服务推荐的质量。因此增加考虑二分异质信息网络中的平行关系有助于挖掘用户与服务之间的关系。其次, 通过比较后三者的实验结果, 发现综合考虑两种平行关




图3 在不同数据集上与基线的性能对比

Fig.3 Performance comparisons with baselines on different datasets




图4 考虑不同关系的实验结果对比

Fig.4 Comparison of experimental results considering different relations

表4 考虑不同关系的实验结果对比

Table 4 Comparison of experimental results considering different relations

| Method           | Yelp         |              |              |              | Douban Movie |              |              |              | MovieLens    |              |              |              |
|------------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|                  | F1           | NDGG         | MAP          | MRR          | F1           | NDGG         | MAP          | MRR          | F1           | NDGG         | MAP          | MRR          |
| $MNHER_{null}$   | 0.339        | 0.255        | 0.306        | 0.470        | 0.310        | 0.381        | 0.206        | 0.653        | 0.239        | 0.220        | 0.118        | 0.346        |
| $MNHER_{social}$ | 0.354        | 0.267        | 0.320        | 0.491        | 0.329        | 0.368        | 0.216        | <b>0.683</b> | 0.250        | 0.230        | 0.123        | 0.392        |
| $MNHER_{cotag}$  | 0.382        | <b>0.287</b> | 0.370        | 0.546        | 0.326        | <b>0.412</b> | 0.203        | 0.659        | 0.272        | 0.258        | <b>0.140</b> | 0.427        |
| MNHER            | <b>0.396</b> | 0.285        | <b>0.376</b> | <b>0.580</b> | <b>0.345</b> | 0.380        | <b>0.251</b> | 0.677        | <b>0.096</b> | <b>0.270</b> | 0.133        | <b>0.493</b> |



系的方法的推荐质量更优于只考虑一种平行关系的方法。虽然数据存在一些波动,但可以明显看出最优的推荐质量大部分来自 MNHER。

本文进一步对综合两种平行关系的组合权重  $\delta$  进行讨论分析,实验结果如图 5 所示。发现在三个数据集的实验结果中,当  $\delta$  取值在  $[0.2, 0.3]$  区间中 F1@10 为最大值。进一步证明综合考虑平行关系更有利于对异质信息网络的表征,进而提高服务推荐的质量。




图5 参数  $\delta$  的实验分析结果

Fig.5 Experimental analysis of parameter  $\delta$

### 3.4 游走规则的比较分析

为分析考虑网络节点中心性的随机游走规则对网络表征学习的影响,本文比较分析了三种不同的网络节点中心性,分别为BC(介数中心性)、EC(特征向量中心性)和PR(PageRank)。实验结果如表 5 所示。实验结果显示,考虑节点中心性的游走策略能有效提高服务推荐的质量。考虑 PageRank 中心性的服务推荐质量最高,在不同数据集的实验中各项指标平均提升了 20%。因此,考虑节点中心性的随机游走策略有助于挖掘网络中的节点关系。并且在 Movielens 数据集上的实验中,提升幅度最明显。因为 Movielens 的数据集最为稀疏,所以增加考虑节点重要性有助于改善关系网络数据稀疏的问题。

本文还在随机游走算法中增加了两个控制参数 ( $mw, p$ ),一起控制随机游走的步长,使每次随机游走的步长都是随机的。本文也进行了实验讨论。实验

结果如图 6 所示。 $mw$  在区间  $[6, 8]$  取值为最优。当  $mw$  取值大于 8 时,推荐质量呈现降低的趋势。因此,随机游走的步长不宜过长,而且最优值也跟关系网络的规模有关系, $p$  在区间  $[0.05, 0.10]$  取值为最优。当取值大于 0.10 时,曲线都呈现下降的趋势。 $p$  值过大会使得步长都偏小,因此步长也不宜过短。

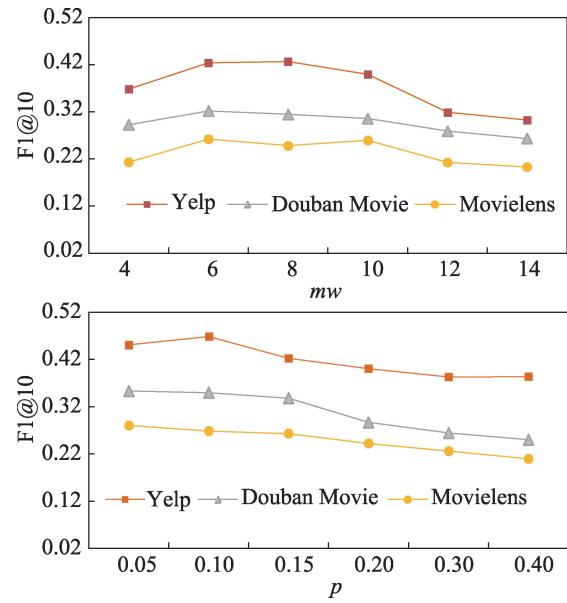


图6 参数  $mw, p$  实验分析

Fig.6 Experimental analysis of parameter  $mw, p$

## 4 结束语

本文提出一种多关系网络混合嵌入的服务推荐方法,利用混合网络嵌入的方法,得到多关系网络映射的用户和服务表征向量。再利用嵌入向量对目标用户进行服务推荐。在三个公开数据集上与多种代表性的服务推荐方法进行比较实验。相比基于单一关系网络和简单融合多关系网络的服务推荐方法, F-measure 值分别可提高 21%、15%。证明了本文提出的多网络混合嵌入方法可以有效地协同多关系网络,进而提高服务推荐质量。也证明了本文提出的多网络混合嵌入方法也可以有效地映射出用户和服

表5 不同中心性度量方法下的实验结果

Table 5 Experimental results under different centrality measurement methods

| Method | Yelp         |              |              |              | Douban Movie |              |              |              | Movielens    |              |              |              |
|--------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|        | F1           | NDGG         | MAP          | MRR          | F1           | NDGG         | MAP          | MRR          | F1           | NDGG         | MAP          | MRR          |
| NULL   | 0.322        | 0.243        | 0.291        | 0.447        | 0.295        | 0.267        | 0.196        | 0.621        | 0.227        | 0.209        | 0.141        | 0.329        |
| BC     | 0.339        | 0.255        | 0.306        | 0.470        | 0.310        | 0.281        | 0.206        | 0.653        | 0.239        | 0.220        | <b>0.148</b> | 0.346        |
| EC     | 0.275        | 0.261        | 0.336        | <b>0.496</b> | 0.297        | 0.375        | 0.185        | 0.599        | 0.247        | <b>0.298</b> | 0.128        | 0.400        |
| PR     | <b>0.416</b> | <b>0.285</b> | <b>0.376</b> | 0.480        | <b>0.330</b> | <b>0.450</b> | <b>0.251</b> | <b>0.688</b> | <b>0.296</b> | 0.270        | 0.143        | <b>0.493</b> |

务的表征向量,并且混合考虑多种关系网络有助于提高服务推荐质量。

本文提出的服务推荐模型目的是综合考虑多种用户与服务之间的关系。本文采取的是分离独立的关系网络,如用户社交关系网络、服务标签共有关系网络,但是在现实生活中,应该是异质的复杂关系网络。用户和服务都是多样的,关系也是多样的。因此后续的工作中,希望能对异质的复杂关系网络进行混合关系映射。并且本文进行基于相似用户集群的服务推荐时,其实是一种目标用户与推荐服务的简单映射,通过机器学习优化出一个数学模型和深度聚类都是目前流行的优化服务推荐模型的方法,后续工作也会考虑使用和改进这些方法。

### 参考文献:

- [1] BURKE R. Hybrid recommender systems: survey and experiments[J]. *User Modeling and User-Adapted Interaction*, 2002, 12(4): 331-370.
- [2] ZHOU P Y, LIU J, LIU X, et al. Is deep learning better than traditional approaches in tag recommendation for software information sites?[J]. *Information and Software Technology*, 2019, 109: 1-13.
- [3] CAI X Y, HAN J W, PAN S R, et al. Heterogeneous information network embedding based personalized query-focused astronomy reference paper recommendation[J]. *International Journal of Computational Intelligence Systems*, 2018, 11(1): 591-599.
- [4] WEI S X, ZHENG X L, CHEN D R, et al. A hybrid approach for movie recommendation via tags and ratings[J]. *Electronic Commerce Research and Applications*, 2016, 18: 83-94.
- [5] LECUN Y, BENGIO Y, HINTON G, et al. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [6] ZHANG R, XIE P, WANG C, et al. Classifying transportation mode and speed from trajectory data via deep multi-scale learning[J]. *Computer Networks*, 2019, 162: 106861.
- [7] JIAO P F, TANG M H, LIU H T, et al. Variational auto encoder based bipartite network embedding by integrating local and global structure[J]. *Information Sciences*, 2020, 519: 9-21.
- [8] GROVER A, LESKOVEC J. node2vec: scalable feature learning for networks[C]//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, Aug 13-17, 2016. New York: ACM, 2016: 855-864.
- [9] TANG J, QU M, WANG M Z, et al. LINE: large-scale information network embedding[C]//*Proceedings of the 24th International Conference on World Wide Web*, Florence, May 18-22, 2015. New York: ACM, 2015: 1067-1077.
- [10] WANG D X, CUI P, ZHU W W. Structural deep network embedding[C]//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, Aug 13-17, 2016. New York: ACM, 2016: 1225-1234.
- [11] GAO M, CHEN L H, HE X N, et al. BiNE: bipartite network embedding[C]//*Proceedings of the 41st International ACM SIGIR Conference on Research & Development in Information Retrieval*, Ann Arbor, Jul 8-12, 2018. New York: ACM, 2018: 715-724.
- [12] WU H, PENG Y N, HE P, et al. Service recommendation based on the use of reliable user network supplementary tags[J]. *Internet of Things Technology*, 2019, 9(2): 48-51.
- [13] WANG Z K. Research on recommendation algorithm based on representation learning in heterogeneous information networks[D]. Beijing: Peking University, 2019.
- [14] LUO L, XIE H R, RAO Y H, et al. Personalized recommendation by matrix co-factorization with tags and time information[J]. *Expert Systems with Application*, 2019, 119: 311-321.
- [15] SHI W S, LIU X M, YU Q. Correlation-aware multi-label active learning for Web service tag recommendation[C]//*Proceedings of the 2017 IEEE International Conference on Web Services*, Honolulu, Jun 25-30, 2017. Piscataway: IEEE, 2017: 229-236.
- [16] ZHANG S, XIA Y, LI X. Diversified recommendation algorithm for hybrid label based on matrix factorization[C]//*Proceedings of the 2018 IEEE 3rd International Conference on Cloud Computing and Big Data Analysis*, Chengdu, Apr 20-22, 2018. Piscataway: IEEE, 2018: 39-44.
- [17] QIANG H, YAN G. A method of personalized recommendation based on multi-label propagation for overlapping community detection[C]//*Proceedings of the 2012 3rd International Conference on System Science, Engineering Design and Manufacturing Informatization*, Chengdu, Oct 20-21, 2012. Piscataway: IEEE, 2012: 360-364.
- [18] BA Q L, LI X Y, BAI Z Y. A similarity calculating approach simulated from TF-IDF in collaborative filtering recommendation[C]//*Proceedings of the 5th International Conference on Multimedia Information Networking & Security*, Nov 1-3, 2013. New York: ACM, 2013: 738-741.
- [19] OTSUKA E, WALLACE S A, CHIU D. Design and evaluation of a Twitter hashtag recommendation system[C]//*Proceedings of the 18th International Database Engineering & Applications Symposium*, Porto, Jul 7-9, 2014. New York: ACM, 2014: 330-333.
- [20] WANG X, LU W, ESTER M. Social recommendation with strong and weak ties[C]//*Proceedings of the 25th ACM International Conference on Information and Knowledge Management*, Indianapolis, Oct 24-28, 2016. New York: ACM, 2016: 5-14.
- [21] ZHOU P, ZHOU Y X, WU D P, et al. Differentially private online learning for cloud-based video recommendation with multimedia big data in social networks[J]. *IEEE Transactions on Multimedia*, 2016, 18(6): 1217-1229.
- [22] HU Y, YI X, DAVIS L S. Collaborative fashion recommendation: a functional tensor factorization approach[C]//*Proceedings of the 23rd Annual ACM Conference on Multimedia Conference*, Brisbane, Oct 26-30, 2015. New York: ACM, 2015: 129-138.
- [23] YANG B, LEI Y, LIU J, et al. Social collaborative filtering

- by trust[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(8): 1633-1647.
- [24] JIANG Z G, ZHOU A, WANG S G, et al. Personalized service recommendation for collaborative tagging systems with social relations and temporal influences[C]//Proceedings of the 2016 IEEE International Conference on Services Computing, San Francisco, Jun 27-Jul 2, 2016. Washington: IEEE Computer Society, 2016: 786-789.
- [25] LIU Y, TIAN Z, SUN J, et al. Distributed representation learning via node2vec for implicit feedback recommendation[J]. Neural Computing and Applications, 2019, 7: 1-11.
- [26] ZHUANG F, ZHANG Z, QIAN M, et al. Representation learning via dual-autoencoder for recommendation[J]. Neural Networks, 2017, 90: 83-89.
- [27] 吴玺煜, 陈启买, 刘海, 等. 基于知识图谱表示学习的协同过滤推荐算法[J]. 计算机工程, 2018, 44(2): 226-232.  
WU X Y, CHEN Q M, LIU H, et al. Collaborative filtering recommendation algorithm based on representation learning of knowledge graph[J]. Computer Engineering, 2018, 44(2): 226-232.
- [28] WU L, QUAN C, LI C, et al. A context-aware user-item representation learning for item recommendation[J]. Transactions on Information Systems, 2019, 37(2): 1-29.
- [29] KONG X, MAO M, WANG W, et al. VOPRec: vector representation learning of papers with text information and structural identity for recommendation[J]. IEEE Transactions on Emerging Topics in Computing, 2021, 9(1): 226-237.
- [30] SALAH A, LAUW H W. Probabilistic collaborative representation learning for personalized item recommendation [C]//Proceedings of the 34th Conference on Uncertainty in Artificial Intelligence, Monterey, Aug 6-10, 2018: 998-1008.
- [31] HAN X T, SHI C, ZHENG L, et al. Representation learning with depth and breadth for recommendation using multi-view data[C]//LNCS 10987: Proceedings of the 2nd International Joint Conference on Web and Big Data, Macau, China, Jul 23-25, 2018. Cham: Springer, 2018: 181-188.
- [32] SHI C, HU B, ZHAO X, et al. Heterogeneous information network embedding for recommendation[J]. IEEE Transactions on Knowledge & Data Engineering, 2017, 31(2): 357-370.
- [33] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space[J]. arXiv: 1301.3781, 2013.
- [34] PAGE L, BRIN S, MOTWANI R, et al. The PageRank citation ranking: bringing order to the web[R]. Stanford: Stanford InfoLab., 1999: 161-172.
- [35] MA H, YANG H X, LYU M R, et al. SoRec: social recommendation using probabilistic matrix factorization[C]//Proceedings of the 17th ACM Conference on Information and Knowledge Management, Napa Valley, Oct 26-30, 2008. New York: ACM, 2008: 931-940.
- [36] SHI C, ZHANG Z Q, LUO P, et al. Semantic path based personalized recommendation on weighted heterogeneous information networks[C]//Proceedings of the 24th ACM International Conference on Information and Knowledge Management, Melbourne, Oct 19-23, 2015. New York: ACM, 2015: 453-462.
- [37] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback [C]//Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence, Montreal, Jun 18-21, 2009: 452-461.
- [38] LIU H Z, WU Z H, ZHANG X. CPLR: collaborative pairwise learning to rank for personalized recommendation[J]. Knowledge-Based Systems, 2018, 148: 31-40.
- [39] SHAO L S, ZHANG J, WEI Y, et al. Personalized QoS prediction for Web services via collaborative filtering[C]//Proceedings of the 2007 IEEE International Conference on Web Services, Salt Lake City, Jul 9-13, 2007. Washington: IEEE Computer Society, 2007: 439-446.
- [40] RENDLE S. Factorization machines with libFM[J]. ACM Transactions on Intelligent Systems and Technology, 2012, 3(3): 57.



王雪纯(1996—),女,湖北十堰人,硕士研究生,主要研究方向为表示学习、神经网络、服务计算。

**WANG Xuechun**, born in 1996, M.S. candidate. Her research interests include representation learning, neural networks and service computing.



吕晟凯(2001—),男,湖北襄阳人,主要研究方向为深度学习、个性化推荐系统。

**LYU Shengkai**, born in 2001. His research interests include deep learning and personalized recommendation system.



吴浩(1998—),男,湖北黄冈人,硕士研究生,主要研究方向为表示学习、神经网络、服务推荐。

**WU Hao**, born in 1998, M.S. candidate. His research interests include representation learning, neural networks and service recommendation.



何鹏(1988—),男,江西宜春人,博士,副教授,主要研究方向为面向服务的软件工程、软件质量分析、缺陷预测。

**HE Peng**, born in 1988, Ph.D., associate professor. His research interests include service-oriented software engineering, software quality analysis and defect prediction.



曾诚(1976—),男,湖北武汉人,博士,教授,主要研究方向为服务计算、机器学习、软件工程。

**ZENG Cheng**, born in 1976, Ph.D., professor. His research interests include services computing, machine learning and software engineering.