

基于异质信息网络表示学习与注意力神经网络的推荐算法



赵金龙 赵中英

山东科技大学计算机科学与工程学院 山东 青岛 266590

(zhaojinlongchn@foxmail.com)

摘要 推荐系统能够有效解决信息过载等问题,得到了国内外众多学者的广泛关注。真实世界中的应用场景往往可以建模成异质信息网络,因此基于异质信息网络表示学习的推荐算法成为了近年来的研究热点。然而,当前的研究工作仍然存在异质信息提取缺乏深度、节点的复杂关系发掘不充分等问题。为解决这些问题,文中提出了基于异质信息网络表示学习与注意力神经网络的推荐算法。首先,提出了保持语义关系与结构拓扑的异质信息网络表示方法;然后,设计了基于元路径的随机游走策略来获取异质信息网络中的节点序列,对序列过滤并生成用户和项目在不同元路径下的表示向量;最后,设计了基于注意力神经网络的推荐算法,将上述向量输入注意力神经网络,深入挖掘表示向量之间的关系以实现有效的推荐。在两个真实数据集上进行实验并与3种主流的算法进行比较,结果表明,所提算法在MAE与RMSE这2个推荐指标方面都有提升,最高提升了8.9%。

关键词: 异质信息网络;表示学习;元路径;注意力神经网络;推荐算法

中图法分类号 TP181

Recommendation Algorithm Based on Heterogeneous Information Network Embedding and Attention Neural Network

ZHAO Jin-long and ZHAO Zhong-ying

School of Computer Science and Engineering, Shandong University of Science and Technology, Qingdao, Shandong 266590, China

Abstract Recommendation system, as a very effective technique to solve the information overload, has received a great deal of attention from researchers. However, the real application of recommending systems can be modeled as heterogeneous networks with multi-typed nodes and relations. Thus, heterogeneous network embedding based recommendation becomes a very hot research topic in recent years. However, most of the existing studies do not fully explore the auxiliary information and complex relations which are valuable for enhancing recommending performance. To address the above problems, a recommendation algorithm based on heterogeneous information network embedding and attention neural network is proposed. First, this paper proposes a heterogeneous information network embedding method that maintains semantic relationship and topological structure simultaneously. Then, it designs a meta-path based random walk strategy to extract node sequences from heterogeneous information networks. All the sequences are filtered and then employed to learn the embeddings for each user and item in different meta-paths. At last, this paper presents a recommendation algorithm based on attention neural network with the above embeddings as input. The attention network composed of attention layers and hidden layers is able to explore the complex relationships and hence enhance the performance of recommendation. To verify the effectiveness of the proposed method, this paper conducts experiments on two kinds of real-world datasets and makes a comparison with three competitive algorithms. The results show that the proposed algorithm improves the recommending performance in terms of MAE and RMSE, with a maximum increase of 8.9%.

Keywords Heterogeneous information networks, Representation learning, Meta-path, Attention neural network, Recommendation algorithm

1 引言

互联网、移动互联网等信息技术的快速发展在方便人们获取信息的同时也带来了严重的信息过载问题。作为解决信

息过载问题的有效技术之一,推荐算法引起了学术界与工业界的共同关注,并被广泛应用于电子商务^[1-2]、社交网络^[3-4]、音视频^[5]等领域。例如,阿里、京东等电商平台的商品推荐,腾讯、Facebook等社交平台的好友推荐,Spotify的音乐推荐等。

到稿日期:2020-08-31 返修日期:2020-11-06 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(62072288,61702306);山东省自然科学基金(ZR2018BF013)

This work was supported by the National Natural Science Foundation of China(62072288, 61702306) and Natural Science Foundation of Shandong Province(ZR2018BF013).

通信作者:赵中英(zzysuin@163.com)

主流的推荐算法可以分为3类^[6]:基于内容的推荐算法^[7]、协同过滤推荐算法^[8]与混合推荐算法^[9-10]。基于内容的推荐算法根据项目、用户以及用户与项目之间的交互行为等信息进行推荐^[11],其缺点是无法挖掘用户与项目的潜在特征;协同过滤是应用得较广泛的推荐算法,可分为基于用户的协同过滤^[12]和基于项目的协同过滤^[13],二者都是通过寻找相似用户或相似项目来进行推荐的;混合推荐算法则是有机结合上述两种算法的优点,旨在提高推荐算法的鲁棒性,从而拓展推荐方法的应用场景。混合推荐算法根据不同类型可以分为加权型、切换型、交叉型、特征组合型、瀑布型、特征递增型与元层次型等^[6]。

上述推荐算法已成功应用于诸多领域,但是仍没有充分挖掘推荐系统中丰富的辅助信息,导致推荐的精度不高。而异质信息网络能够有效地对上述辅助信息进行建模,因此基于异质信息网络表示学习^[14]的推荐算法引起了国内外学者的广泛关注。

HeteRec^[15]是最早提出的基于异质信息网络建模的推荐方法,旨在考虑异质信息网络中的语义信息来提高推荐的准确率。HeteroMF^[16]则将传统的矩阵分解算法与异质信息网络相结合,其本质是上下文相关的矩阵分解模型。该模型既考虑了实体的一般潜在因素,又考虑了实体所涉及的上下文潜在因素。

Yan等^[17]在过滤低质量语义信息的同时充分挖掘有用的标签信息来进行推荐。虽然该算法使用了辅助信息,但是仍没有考虑节点间关系的异质性。Luo等^[18]提出了基于异质关系分析的社会化协同过滤算法,但是忽略了不同关系在异质信息网络中的辩证统一性。Niu等^[19]提出了基于异质注意力的循环神经网络模型。该模型将文本数据和关系网络进行融合,用于短期文本推荐。

综上所述,虽然学术界与工业界已经在异质信息网络表示学习的推荐算法方面进行了大量研究与应用,但是仍然存在以下亟待解决的问题:1)对异质信息网络中的信息提取缺乏深度;2)缺少对异质信息网络中节点表示之间的深层次关系的针对性挖掘。为解决上述问题,本文提出了基于异质信息网络表示学习与注意力神经网络的推荐算法,主要贡献如下:

(1)提出了保持语义关系与结构拓扑的异质信息网络表示学习方法。首先采用基于元路径的随机游走策略生成节点序列,然后保留同质节点,实现语义与拓扑信息的同时表示。

(2)提出了基于异质信息网络表示学习与注意力神经网络的推荐算法。以元路径方式提取节点序列生成表示向量,实现异质信息网络表示。设计注意力神经网络,将不同元路径的表示向量进行融合;同时,挖掘网络中用户与项目之间的非线性关系,以实现更精准的推荐。

(3)在Douban Movie, Yelp等真实数据集上进行实验,并与主流的推荐算法进行了比较分析,实验结果表明,本文提出的推荐算法可以有效提升推荐精度。

2 相关工作

2.1 异质信息网络及其表示

网络是对现实世界的抽象表示,由节点和链接关系(边)

组成。异质信息网络是一种特殊的网络,由不同类型的节点、链接关系和属性信息组成,具有大规模、异质性和动态性等特点。

如何应用异质信息网络成为了一个新的研究课题。针对这一问题,网络表示学习通过特定算法将网络中的节点表示为向量,可以有效提取网络信息并在链接预测^[20]、节点分类^[21]等任务中进行应用。为更好地捕获节点和链接的信息,提高表示向量的质量,研究者们提出了一系列异质信息网络表示学习的方法。

PTE^[22](Predictive Text Embedding)从文本数据出发,提出了一种半监督的异质文本表示方法。该算法将异质文本网络划分为3个不同的子网络。目标函数保留了二阶相似度,目的是使网络中相近的节点通过表示后更为相似。最后使用改进的Line^[23](Large-scale Information Network Embedding)算法优化3个不同的子网络,以得到最终的文本表示。

元路径^[24]这一概念被提出较早,因其能更好地提取网络中的模式信息而被学者们广泛研究。其最初被应用于相似性搜索^[25]的任务,而后被应用于异质信息网络表示学习等领域。HINE^[26](Heterogeneous Information Network Embedding)算法在给定元路径的条件下,通过拟合两个节点之间的路径条数或元路径中的节点个数,来训练异质信息网络的表示向量。

神经网络因其优异的非线性映射能力和表征能力被广泛研究与应用,基于神经网络的异质信息网络表示方法迅速发展。Metapath2vec(Meta-path to Vector)^[27]是对DeepWalk^[28]算法在异质信息网络中的拓展和改进,能够挖掘不同类型节点之间的语义与结构关系。应用基于元路径的随机游走策略在不同节点之间构建异质邻域,并通过SkipGram^[29]模型对语义关系与结构关系相近的节点进行建模,从而得到相应的节点表示。Metapath2vec算法要求元路径必须是对称的,且每次只能利用一条元路径的信息。HNE^[30](Heterogeneous Network Embedding)将异质信息网络中的不同节点映射到相同维度的空间中学习表示向量。HIN2Vec^[31](Heterogeneous Information Network to Vector)是一种基于神经网络的异质信息网络表示方法,该方法研究不同类型节点之间的关系和网络结构,能同时学习网络中的节点表示与元路径表示,同时应用基于多任务学习的方法把不同关系的丰富信息和网络结构联合表示到节点向量中。

2.2 基于异质信息网络表示学习的推荐算法

异质信息网络表示方法领域的深入研究给推荐算法与其结合提供了坚实的理论基础,因此基于异质信息网络表示学习的推荐算法迅速发展。

元路径^[24]也同样应用在基于异质信息网络表示学习的推荐算法中。Yu等^[32]提出结合用户隐式反馈信息的推荐算法,该算法使用潜在特征来表示用户和项目在不同元路径中的链接,定义具有潜在特征的推荐模型并使用贝叶斯排序评估该模型。LGRec^[33]在异质信息网络中结合标签信息进行推荐,首先使用共同注意力机制对用户和项目的局部信息进行建模,其次通过多标签分类捕捉全局信息,最后将异质网络中的局部信息与全局信息相结合进行推荐。SemRec^[34]提出

加权异质信息网络的概念,并通过设置元路径的权值约束来灵活地集成异质信息,以得到更好的推荐性能。

为了更好地表示异质信息网络的高阶语义信息,并且更有效地融合异质信息进行推荐,Zhao等^[35]提出基于异质信息网络元结构融合的推荐算法。该算法以元结构为单位,使用矩阵分解生成用户和项目的潜在特征。Group Lasso作为正则项的目的是去除无用元结构的对应特征。该算法使用因子分解机进行训练和评分预测。

3 问题定义

定义1(异质信息网络) 给定图 $G=(V,E)$,其中 V 为对象集合; E 为链接集合;存在对象类型映射 $\phi:V\rightarrow A$ 与链接类型映射 $\psi:E\rightarrow R$ 。图中的每个对象 $v\in V$ 属于特定对象类型集合 A ,表示为 $\phi(v)\in A$;每个链接 $e\in E$ 属于特定链接类型集合 R ,表示为 $\psi(e)\in R$ 。如果在一个信息网络中对象类型的数量 $|A|>1$ 或链接类型数量 $|R|>1$,那么这样的信息网络称为异质信息网络。

定义2(网络模式) 给定网络 $G=(V,E)$,则 G 的网络模式可以定义为 $T_G=(A,R)$,网络模式即由对象类型 A 的节点和链接类型 R 的边所构成的图。

网络模式可以明确网络中的对象类型以及对象类型之间

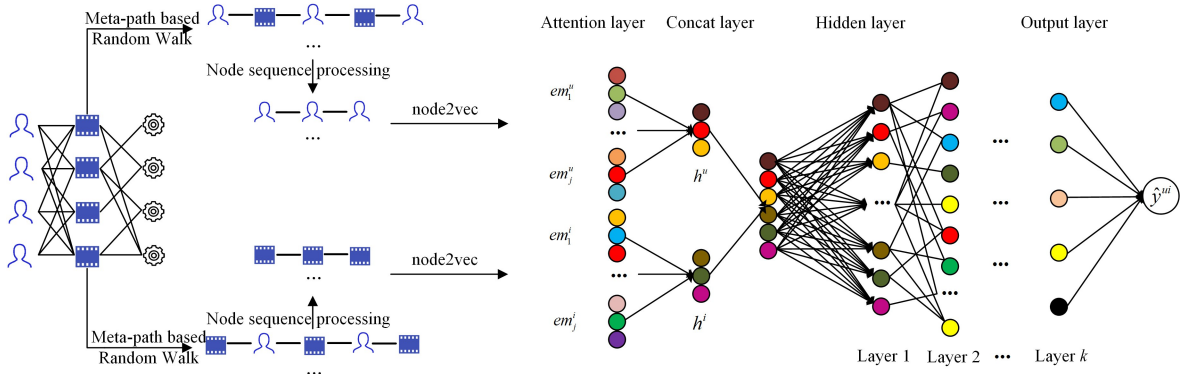


图1 基于异质信息网络表示学习与注意力神经网络的推荐框架

Fig. 1 Recommendation framework based on heterogeneous information network embedding and attention neural network

4.1 基于元路径的表示方法

本节中的节点序列获取与序列处理流程主要参考HERec^[36]中的第4.1节。为验证本文方法的先进性,在实验部分将本文方法与HERec进行了对比。

4.1.1 基于元路径的随机游走

给定异质信息网络 $G=(V,E)$,以元路径 MP 为约束,通过基于元路径的随机游走策略来生成相应的节点序列。随机游走的概率如式(1)所示:

$$P(v_{m+1}|v_m, MP) = \begin{cases} \frac{1}{|N^{A_{t+1}}(v_m)|}, & (v_{m+1}, v_m) \in E \text{ 且 } \phi(v_{m+1}) = A_{t+1} \\ 0, & \text{其他} \end{cases} \quad (1)$$

其中, v_m 表示 A_t 类型的节点; $N^{A_{t+1}}(v_m)$ 表示在节点 v_m 的邻域节点中节点类型为 A_{t+1} 的数量。

以图2为例,对于元路径 $A\rightarrow B\rightarrow A$,通过基于元路径的随机游走得到元路径实例: $A_2\rightarrow B_2\rightarrow A_4\rightarrow B_3\rightarrow A_3$ 等若干

的关系。因此,在网络模式的基础上,给出元路径的定义。

定义3(元路径) 给定异质信息网络 $G=(V,E)$ 与网络模式 $T_G=(A,R)$,元路径是链接两个不同对象之间的序列。即在节点类型 A_1 到 A_{t+1} 之间定义一套组合关系 $R_1\cdots R_t$ 。将其形式化表示为: $MP:A_1 \xrightarrow{R_1} A_2 \xrightarrow{R_2} \cdots \xrightarrow{R_t} A_{t+1}$ 。

问题定义:基于异质信息网络的推荐。给定异质信息网络 $G=(V,E)$ 及元路径 MP ,其中用户节点 $u\in V$ 、项目节点 $i\in V$ 。用户 u 对项目 i 的评分为 \hat{y}^{ui} 。因此,本文的目标是对任意一个用户 $u\in V$ 预测该用户对其未评分的任一项目 i 的评分 \hat{y}^{ui} 。该推荐问题可以形式化表示为预测函数 $\hat{y}^{ui}=F(G, MP; \theta)$,其中 θ 表示可学习的参数。

4 基于异质信息网络表示学习与注意力神经网络的推荐算法

基于异质信息网络表示学习与注意力神经网络的流程如下:在异质信息网络中给定元路径进行基于元路径的随机游走生成节点序列,进行序列处理并使用异质信息网络表示方法生成相应的表示向量;注意力神经网络将不同元路径下的用户表示和项目表示进行融合并生成推荐结果。整体推荐框架如图1所示。

条。对于元路径 $B\rightarrow A\rightarrow B$,通过基于元路径的随机游走得到元路径实例 $B_2\rightarrow A_4\rightarrow B_4\rightarrow A_3\rightarrow B_1$ 等若干条。




图2 基于元路径的随机游走

Fig. 2 Meta-path based random walk

4.1.2 节点序列处理

首先,确定序列实例中首个节点的类型,将本序列中不属于该类型的节点删除,即可将节点序列过滤为同一类型。

以图3为例,元路径实例 $A_2\rightarrow B_2\rightarrow A_4\rightarrow B_3\rightarrow A_3$ 通过节点序列处理可以得到序列 $A_2\rightarrow A_4\rightarrow A_3$ 。元路径实例 $B_2\rightarrow$

A4→B4→A3→B1 通过节点序列处理后得到序列 B2→B4→B1。




图3 节点序列处理

Fig. 3 Node sequence processing

4.1.3 生成表示向量

将节点序列输入 node2vec^[37]算法生成相应节点的表示向量。设 $f(v)$ 是将节点 v 映射为表示向量的映射函数,对于网络中的每个节点 v , N_v 表示节点 v 的邻居集合,目标函数如式(2)所示:

$$\max_f \sum_{v \in V} \log P_r(N_v | f(v)) \quad (2)$$

通过 SGD^[38] (Stochastic Gradient Descent) 优化目标函数得到不同类型元路径下的用户表示 em^u 和项目表示 em^i ,如图4所示。




图4 基于 node2vec 的表示向量生成

Fig. 4 Embedding generation based on node2vec

本文基于元路径随机游走的用户与项目表示向量生成算法如算法1所示。

算法1 基于元路径的表示方法

输入:异质信息网络 $G=(V,E)$;元路径集 MP ;表示向量维度 d

输出:不同元路径下的用户表示 em^u 和项目表示 em^i

1. 给定网络 $G=(V,E)$
2. FOR 元路径集 MP 中的不同元路径 MP_m
3. 给定元路径 MP_m , 遵循式(1)在网络中进行随机游走
4. 节点序列处理,生成节点序列 ns
5. 调用 node2vec 算法,优化目标函数式(2)
6. $em_m^u, em_m^i = \text{SGD}(ns, d)$
7. END FOR
8. RETURN em^u, em^i

对算法1进行分析,得到该算法的时间复杂度为 $O(|MP|d(|U|+|I|))$,其中 $|MP|$ 表示元路径的数量, d 表示向量维度, $|U|$ 为用户构成网络中节点的数量, $|I|$ 为项目构成网络中节点的数量。

node2vec 算法的时间复杂度为 $O(d(|V|))$,其中 $|V|$ 表示网络中节点的数量。本文构建的异质信息网络中用户节点和项目节点的占比最大,如果忽略网络中其他少数节点,那么本文算法与 node2vec 算法的时间复杂度的差别最终取决于 $|MP|$,即元路径的数量,并且生成元路径时可以改进并行处理,提高算法效率。

4.2 基于注意力神经网络的推荐算法

基于注意力神经网络的推荐算法旨在得到用户对项目的

评分,其形式化表示如式(3)所示:

$$\hat{y}^{ui} = \text{Pre}(em_i^1 \cdots em_m^u \cdots em_j^i, em_i^1 \cdots em_m^i \cdots em_j^i), m \in [1, j] \quad (3)$$

其中, $\text{Pre}()$ 为评分预测函数; em_m^u 为用户 u 在第 m 条元路径的表示向量; em_m^i 为项目 i 在第 m 条元路径的表示向量; j 表示元路径类型的数量; \hat{y}^{ui} 表示用户对项目的预测评分值。

基于注意力机制将不同元路径下的节点表示向量进行融合,如式(4)所示:

$$\begin{aligned} h_m^t &= \tanh(W_1 em_m^t + b_1), t \in \{u, i\} \\ a_{MP_m} &= \frac{\exp(w_m)}{\sum_{m=1}^j \exp(w_m)} \end{aligned} \quad (4)$$

其中, W 表示权重矩阵; b 表示偏置矩阵; h_m^t 为类型为 t 的节点在第 m 条元路径的表示向量; a_{MP_m} 为第 m 条元路径的权重。

因此,得到异质信息网络的用户表示 h^u 和项目表示 h^i ,如式(5)所示:

$$h^t = \sum_{m=1}^j a_{MP_m} \times em_m^t, t \in \{u, i\} \quad (5)$$

将用户表示 h^u 和项目表示 h^i 进行拼接,经过隐藏层后生成预测结果,如式(6)所示:

$$\hat{y}^{ui} = \sigma(\mathbf{H}g_k(\cdots g_2(\mathbf{W}_2(h^u \oplus h^i) + b_2) \cdots) + b_k) \quad (6)$$

其中, \oplus 表示拼接层的拼接操作, k 表示隐藏层的层数。 W_k 表示第 k 层的权重矩阵, b_k 表示第 k 层的偏置矩阵, g_k 表示第 k 层的激活函数, H 表示输出层的权重矩阵。

基于注意力神经网络的算法的损失函数如式(7)所示:

$$L = \frac{1}{n} \sum_{k=1}^n (y_k^{ui} - \hat{y}_k^{ui})^2 \quad (7)$$

其中, n 为训练集数量, \hat{y}^{ui} 表示用户 u 对项目 i 的预测评分值, y^{ui} 表示用户 u 对项目 i 的真实评分值。基于注意力神经网络的推荐算法如算法2所示。

算法2 基于注意力神经网络的推荐算法

输入:不同元路径下的用户表示 em^u 和项目表示 em^i

输出:用户对项目的评分 \hat{y}^{ui}

1. FOR epoch in Epochs
2. 使用式(4)分别计算不同元路径下的用户表示 em^u 和项目表示 em^i 的注意力权重
3. 使用式(5)得到用户表示 h^u 和项目表示 h^i
4. 使用式(6)得到用户 u 对项目 i 的预测评分值 \hat{y}^{ui} 。
5. 通过最小化式(7)优化算法参数
6. END FOR
7. RETURN \hat{y}^{ui}

5 实验与结果

5.1 数据集

本文在3个真实的数据集上进行实验。Douban Movie 数据集中包含用户对电影的评论和评分、用户类型以及电影属性等信息; Yelp 数据集包含商业公司的属性和用户对公司的评分等信息。MovieLens 数据集包含用户、电影以及用户对电影的评分。由于 MovieLens 数据集网络模式只包含用户

和项目,因此本文只给出 Douban Movie 与 Yelp 数据集的网络模式,分别如图 5 和图 6 所示。




图 5 Douban Movie 数据集的网络模式

Fig. 5 Network schema of Douban Movie dataset

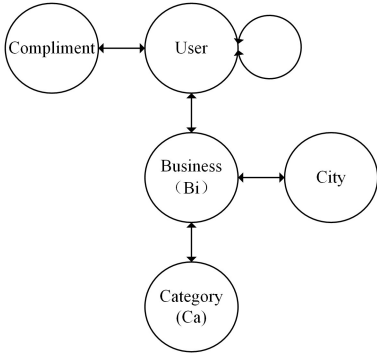


图 6 Yelp 数据集的网络模式

Fig. 6 Network schema of Yelp dataset

本文实验选取的元路径如表 1 所列。

表 1 元路径列表

Table 1 Lists of meta-paths

Dataset	Meta-paths
Douban Movie	UMU, UMAMU, UMTMU, MUM, MAM, MTM
Yelp	UBU, UBCaBU, UBCiBU, BUB, BCaB, BCiB

本文将数据集的 80% 划分为训练集,其余 20% 作为测试集。数据集的统计信息如表 2 所列。

表 2 数据集信息

Table 2 Dataset information

Dataset	Relations	Count	Node type	Count
Douban-movie	User-Movie	1 068 278	User	13 367
	Movie-Actor	33 587	Movie	12 677
	Movie-Actor	33 587	Actor	6 311
	Movie-Type	27 668	Type	38
Yelp	User-Bi	198 397	User	16 239
	Bi-City	14 267	Bi	14 284
	Bi-Ca	40 009	City	47
Movie-Lens	Bi-Ca	40 009	Ca	511
	User-Item	1 000 209	Item	3 706

5.2 评价指标

参考基于异质信息网络的推荐算法^[34,36],本文将平均绝对误差(Mean Absolute Error, MAE)^[39]、均方根误差(Root Mean Square Error, RMSE)^[39]作为误差评价指标。

平均绝对误差 MAE:用于度量两个连续变量之间的差异,即用户对项目的实际评分与预测评分之间的平均绝对误差,如式(8)所示:

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (8)$$

均方根误差 RMSE:代表观测值与真实值偏差的平方和与观测次数比值的平方根,如式(9)所示:

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (9)$$

为验证本文方法的可扩展性,使用 HR(Hit Ratio)和 NDCG(Normalized Discounted Cumulative Gain)作为召回推荐评价指标。

命中率 HR:是常用的召回率指标,表示每个用户 Top-K 列表属于测试集的个数占所有测试集的比率。

归一化折损累计增益 NDCG:是常用的召回率指标,考虑位置与归一化的推荐结果相关性指标。

5.3 对比方法

将本文算法与 5 种对比算法进行比较。

(1)SemRec^[34]。该方法通过设置元路径权值约束来集成异质信息。实验中使用多条元路径并进行权重正则化。

(2)HERec^[36]。该算法使用基于元路径的随机游走生成用户与项目的表示,结合改进的矩阵分解算法实现推荐。实验设置遵循实验中的最优参数并采用个性化非线性融合函数。

(3)概率矩阵分解(Probabilistic Matrix Factorization, PMF)^[40]。该方法将用户和项目之间的关系分解为几个相关因素的线性组合。

(4)BPR(Bayesian Personalized Ranking)^[41]。基于矩阵分解的排序算法,通过成对方法来优化矩阵分解。

(5)NCF(Neural Collaborative Filtering)^[42]。该方法将神经网络与协同过滤相结合,通过神经网络来学习交互函数以替代矩阵分解中的内积交互。实验设置中未进行模型预训练。

5.4 实验设置及结果分析

得到最优实验结果时的参数设置如下:node2vec 算法表示向量维度 $d=128$;隐藏层激活函数为 ReLU 函数,层数 $k=5$,所对应的每层的维度为[256,128,64,32,8];训练中的 $Epochs=300$, $batchsize=256$,学习率为 0.001。

本文算法与对比算法 SemRec, HERec, PMF 在 Douban Movie 和 Yelp 数据集上进行多次实验并取平均值,实验结果如表 3 所列。

表 3 对比算法在 Douban Movie, Yelp 数据集上的实验结果

Table 3 Experimental results of the comparative methods on the

Method	Douban Movie and Yelp datasets			
	Douban Movie		Yelp	
	MAE	RMSE	MAE	RMSE
PMF	0.5741	0.7641	1.0791	1.4816
SemRec	0.5695	0.7399	0.9176	1.1771
HERec	0.5519	0.7053	0.8475	1.1117
Ours	0.5486	0.6815	0.8044	1.0132

从表 3 可以看出,本文算法在 MAE 与 RMSE 这 2 个评价指标上均得到优于对比算法的结果。在 Douban Movie 数据集上将本文算法与 HERec 进行比较,MAE 与 RMSE 分别

提升了 0.6% 和 3.4%。在 Yelp 数据集上将本文算法与 HERec 进行比较, MAE 与 RMSE 分别提升了 5.1% 和 8.9%。结果表明,本文算法可以有效提升推荐算法的精度。总结得出以下结论:

(1) 基于异质信息网络表示学习的推荐算法在 MAE 与 RMSE 指标上均优于传统的推荐算法。即证明基于异质信息网络表示学习的推荐算法可以有效结合异质信息并提升推荐精度。

(2) 与同样使用元路径提取异质信息的 SemRec 算法、HERec 算法相比,本文算法的结果均优于上述两种算法。这证明本文算法中的注意力神经网络可以有效提取表示向量之间的潜在特征,挖掘用户、项目之间的非线性交互关系,生成准确的推荐结果。

对实验方法进行拓展,使用 MovieLens 数据集进行 Top-K 的召回推荐。MovieLens 并不能直接应用于本文方法,因此使用该数据集中的用户 ID 与项目 ID 生成表示向量作为基于注意力神经网络推荐方法的输入,并采用留一法进行召回推荐。K 取值为 10,评价指标选取 HR@10 与 NDCG@10。实验结果如表 4 所列。

表 4 Top-K 指标在 MovieLens 数据集中的实验结果

Table 4 Experimental results of Top-K metrics on MovieLens

Method	MovieLens dataset	
	HR@10	NDCG@10
BPR	0.6819	0.4117
NCF	0.7053	0.4266
Ours	0.7248	0.4243

从表 4 可以看出,本文算法在 HR 与 NDCG 指标上得到全面优于 BPR 算法的结果。与 NCF 算法相比,命中率 HR 有显著提升,但 NDCG 还存在一定差距。总结得出以下结论:

(1) 本文算法全面优于贝叶斯个性化排序(BPR),原因在于注意力神经网络与贝叶斯算法相比具有更强的信息挖掘能力。

(2) 与基于神经网络的 NCF 相比,本文算法采用的注意力机制可以有效提高神经网络推荐算法的命中率。

5.5 参数分析

本节分析表示维度、迭代次数和隐藏层数对实验结果的影响,并得出如下结论。

(1) 表示维度。选取多个不同维度进行实验,实验结果如图 7 所示。Douban Movie 数据集在较小维度时误差没有明显下降,但是在维度 $d=32$ 后实验误差随表示维度的增大有明显下降。而 Yelp 数据集在维度较小时的敏感性较大,但随着维度的增大实验结果误差逐渐趋于平稳,产生该结果是由两种数据集的差异所导致的。Douban Movie 数据集中包含的信息量大于 Yelp 数据集,较小的维度并不能准确表示相应节点,因此 Douban Movie 数据集在小维度时误差下降不明显,而 Yelp 数据集随着维度的增大误差下降明显。




图 7 维度对实验结果的影响

Fig. 7 Influence of dimensions on the experimental results

(2) 迭代次数。对于不同的数据集以及不同应用任务,迭代次数的设置不同,因此对该参数进行实验分析,结果如图 8 所示。在 Douban Movie 和 Yelp 数据集中可明显观察到,随着迭代次数的增加,算法的推荐误差逐渐减小,并在 300 之后趋于稳定。这表明在训练中迭代次数在一定范围内(本文设置为 400)的增加可以有效利用数据中的信息来提高算法的拟合能力,但超出范围后容易发生过拟合现象,从而造成实验结果变差。




图 8 迭代次数对实验结果的影响

Fig. 8 Influence of epochs on the experimental results

(3) 隐藏层数。设 k 的初始值为 3, 依次增加, 得到的实验结果如图 9 所示。经过 node2vec 生成表示向量, 即表示已经对网络中的信息进行过滤与提取, 因此注意力神经网络中的隐藏层不需要设置很深的层数即可得到较好的实验结果。




图 9 隐藏层数 k 对实验结果的影响

Fig. 9 Influence of the number of hidden layers k on experimental results

结束语 本文提出了基于异质信息网络表示学习与注意力神经网络的推荐算法。首先, 针对推荐算法异质信息提取缺乏深度的问题, 提出结合语义关系与结构拓扑的异质信息网络表示算法, 以元路径为约束获得相应序列可以有效提取异质信息; 对序列进行类型过滤并调用 node2vec 算法生成表示向量, 可以对异质信息进行集成和使用。针对缺少挖掘向量间的隐含关系的问题, 设计基于注意力神经网络的推荐算法。注意力神经网络中的注意力层将不同元路径下的表示向

量进行融合,生成用户表示和项目表示;隐藏层可以有效挖掘用户与项目间的非线性关系,完成准确的推荐。在 Douban Movie 和 Yelp 真实数据集上与 3 个主流算法进行对比实验,在 MovieLens 数据集上与两个 Top-K 推荐算法进行对比实验,实验结果显示,本文算法的推荐精度最高提升了 8.9%,证明了该算法的有效性。

本文中元路径的选择与使用同样也存在着人工设置的问题,未来将研究自动学习元路径的算法以及探索比元路径更加高效准确的异质信息提取方法。

参 考 文 献

- [1] SARWAR B, KARYPIS G, KONSTAN J, et al. Analysis of recommendation algorithms for e-commerce[C]// Proceedings of the 2nd ACM Conference on Electronic Commerce. Association for Computing Machinery, 2000:158-167.
- [2] SCHAFER J B, KONSTAN J A, RIEDL J. E-commerce recommendation applications[J]. Data Mining and Knowledge Discovery, 2001, 5(1/2):115-153.
- [3] YE M, YIN P, LEE W C. Location recommendation for location-based social networks[C]// Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems. Association for Computing Machinery, 2010:458-461.
- [4] SONG Y, ZHANG L, GILES C L. Automatic tag recommendation algorithms for social recommender systems [J]. ACM Transactions on the Web, 2011, 5(1):1-31.
- [5] DAVIDSON J, LIEBALD B, LIU J, et al. The YouTube video recommendation system[C]// Proceedings of the fourth ACM Conference on Recommender Systems. Association for Computing Machinery, 2010:293-296.
- [6] ZHOU C H, SHEN J J, LI Y, et al. Review of classical recommendation algorithms[J]. Computer Science and Application, 2019, 9(9):1803-1817.
- [7] PAZZANI M J, BILLSUS D. Content-based recommendation systems[M]. The Adaptive Web. Berlin: Springer, 2007: 325-341.
- [8] LINDEN G, SMITH B, YORK J. Amazon.com recommendations: Item-to-item collaborative filtering [J]. IEEE Internet Computing, 2003, 7(1):76-80.
- [9] CHOI K, YOO D, KIM G, et al. A hybrid online-product recommendation system: Combining implicit rating-based collaborative filtering and sequential pattern analysis[J]. Electronic Commerce Research and Applications, 2012, 11(4):309-317.
- [10] HAO R F, ZHANG G M, CHENG Y Q. Socialized Matrix Factorization Recommendation Algorithm with User Rating Preference Confidence[J]. Journal of Chongqing University of Technology (Natural Science), 2020, 34(11):138-146.
- [11] PAZZANI M J. A framework for collaborative, content-based and demographic filtering [J]. Artificial Intelligence Review, 1999, 13(5/6):393-408.
- [12] LUO H, NIU C, SHEN R, et al. A collaborative filtering framework based on both local user similarity and global user similarity[J]. Machine Learning, 2008, 72(3):231-245.
- [13] SARWAR B, KARYPIS G, KONSTAN J, et al. Item-based collaborative filtering recommendation algorithms [C]// Proceedings of the 10th international conference on World Wide Web. Association for Computing Machinery, 2001:285-295.
- [14] SHI C, LI Y, ZHANG J, et al. A survey of heterogeneous information network analysis[J]. IEEE Transactions on Knowledge and Data Engineering, 2016, 29(1):17-37.
- [15] SHI C, ZHOU C, KONG X, et al. Heterocom: a semantic-based recommendation system in heterogeneous networks[C]// Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Association for Computing Machinery, 2012:1552-1555.
- [16] JAMALI M, LAKSHMANAN L. HeteroMF: recommendation in heterogeneous information networks using context dependent factor models[C]// Proceedings of the 22nd International Conference on World Wide Web. Association for Computing Machinery, 2013:643-654.
- [17] YAN B, ZHANG L, GUO L, et al. Personalized Recommendation Based on Tag Semantics in the Heterogeneous Information Network[C]// China Conference on Wireless Sensor Networks. Springer, 2019:224-235.
- [18] LUO C, PANG W, WANG Z, et al. Hete-CF: Social-based collaborative filtering recommendation using heterogeneous relations[C]// 2014 IEEE International Conference on Data Mining. IEEE, 2014:917-922.
- [19] NIU Y Q, MENG Y Y, NIU Q F. Text Recommendation Based on Heterogeneous Attention Recurrent Neural Network [J]. Computer Engineering, 2020, 46(10):52-59.
- [20] CAO B, LIU N N, YANG Q. Transfer learning for collective link prediction in multiple heterogenous domains[C]// Proceedings of the 27th International Conference on Machine Learning. Omnipress, 2010:159-166.
- [21] JACOB Y, DENOYER L, GALLINARI P. Learning latent representations of nodes for classifying in heterogeneous social networks[C]// Proceedings of the 7th ACM International Conference on Web Search and Data Mining. Association for Computing Machinery, 2014:373-382.
- [22] TANG J, QU M, MEI Q. Predictive text embedding through large-scale heterogeneous text networks[C]// Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Association for Computing Machinery, 2015:1165-1174.
- [23] TANG J, QU M, WANG M, et al. Line: Large-scale information network embedding[C]// Proceedings of the 24th International Conference on World Wide Web. International World Wide Web Conferences Steering Committee, 2015:1067-1077.
- [24] SUN Y, HAN J. Mining heterogeneous information networks: principles and methodologies[J]. Synthesis Lectures on Data Mining and Knowledge Discovery, 2012, 3(2):1-159.
- [25] 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.
- [26] CHEN Y, WANG C. HINE: Heterogeneous information network embedding[C]// Proceedings of the International Conference on Database Systems for Advanced Applications. Springer, 2017: 180-195.
- [27] 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. Association for Computing Machinery, 2017: 135-144.
- [28] 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. Association for Computing Machinery, 2014: 701-710.
- [29] GUTHRIE D, ALLISON B, LIU W, et al. A closer look at skip-gram modelling[C]// Proceedings of the 5th International Conference on Language Resources and Evaluation, 2006: 1222-1225.
- [30] CHANG S, HAN W, TANG J, et al. Heterogeneous network embedding via deep architectures[C]// Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Association for Computing Machinery, 2015: 119-128.
- [31] FU T, LEE W C, LEI Z. Hin2vec: Explore meta-paths in heterogeneous information networks for representation learning[C]// Proceedings of the 2017 ACM Conference on Information and Knowledge Management. Association for Computing Machinery, 2017: 1797-1806.
- [32] YU X, REN X, SUN Y, et al. Recommendation in heterogeneous information networks with implicit user feedback[C]// Proceedings of the 7th ACM Conference on Recommender Systems. Association for Computing Machinery, 2013: 347-350.
- [33] HU B, SHI C, ZHAO W X, et al. Local and global information fusion for top-n recommendation in heterogeneous information network[C]// Proceedings of the 27th ACM International Conference on Information and Knowledge Management. Association for Computing Machinery, 2018: 1683-1686.
- [34] 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.
- [35] ZHAO H, YAO Q, LI J, et al. Meta-graph based recommendation fusion over heterogeneous information networks[C]// Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Association for Computing Machinery, 2017: 635-644.
- [36] SHI C, HU B, ZHAO W X, et al. Heterogeneous information network embedding for recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 31(2): 357-370.
- [37] 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. Association for Computing Machinery, 2016: 855-864.
- [38] BOTTOU L. Large-scale machine learning with stochastic gradient descent[C]// Proceedings of COMPSTAT' 2010. 2010: 177-186.
- [39] WILLMOTT C J, MATSUURA K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance[J]. Climate Research, 2005, 30(1): 79-82.
- [40] MNH A, SALAKHUTDINOV R R. Probabilistic matrix factorization[C]// Proceedings of the Twenty-First Annual Conference on Neural Information Processing Systems. Curran Associates, 2007: 1257-1264.
- [41] 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. 2009: 452-461.
- [42] HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering [C]// Proceedings of the 26th International Conference on World Wide Web. International World Wide Web Conferences Steering Committee, 2017: 173-182.



ZHAO Jin-long, born in 1995, postgraduate. His main research interests include network representation learning and recommendation system.



ZHAO Zhong-ying, born in 1983, associate professor, is a senior member of China Computer Federation. Her main research interests include social network analysis and data mining.