



计算机科学

COMPUTER SCIENCE

基于知识图谱与用户兴趣的推荐算法

许天月, 柳先辉, 赵卫东

引用本文

许天月, 柳先辉, 赵卫东. [基于知识图谱与用户兴趣的推荐算法](#)[J]. 计算机科学, 2024, 51(2): 55-62.

XU Tianyue, LIU Xianhui, ZHAO Weidong. [Knowledge Graph and User Interest Based](#)

[Recommendation Algorithm](#) [J]. Computer Science, 2024, 51(2): 55-62.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

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

[基于知识图谱的家政服务课程推荐融合模型](#)

Fusion Model of Housekeeping Service Course Recommendation Based on Knowledge Graph

计算机科学, 2024, 51(2): 47-54. <https://doi.org/10.11896/jsjcx.221200149>

[基于特征拓扑融合的黑盒图对抗攻击](#)

Black-box Graph Adversarial Attacks Based on Topology and Feature Fusion

计算机科学, 2024, 51(1): 355-362. <https://doi.org/10.11896/jsjcx.230600127>

[基于生成式对抗网络和正类无标签学习的知识图谱补全算法](#)

Knowledge Graph Completion Algorithm Based on Generative Adversarial Network and Positive and Unlabeled Learning

计算机科学, 2024, 51(1): 310-315. <https://doi.org/10.11896/jsjcx.230300006>

[基于异质图神经网络预训练的多标签文档分类研究](#)

Pre-training of Heterogeneous Graph Neural Networks for Multi-label Document Classification

计算机科学, 2024, 51(1): 143-149. <https://doi.org/10.11896/jsjcx.230600079>

[基于知识图谱的兴趣捕捉推荐算法](#)

Interest Capturing Recommendation Based on Knowledge Graph

计算机科学, 2024, 51(1): 133-142. <https://doi.org/10.11896/jsjcx.230500133>

基于知识图谱与用户兴趣的推荐算法

许天月¹ 柳先辉² 赵卫东²

1 同济大学电子与信息工程学院 上海 201804

2 同济大学电子与信息工程学院 CAD 研究中心 上海 201804

(1468770549@qq.com)

摘要 为了解决协同过滤推荐算法中存在的冷启动以及数据稀疏性等问题,文中引入了具有丰富语义信息和路径信息的知识图谱。基于其结构特征,将图神经网络应用于知识图谱的推荐算法得到了研究者的青睐。推荐算法的核心在于获取物品特征和用户特征,然而,该方面研究的重点在于更好地表达物品特征,而忽略了用户特征的代表。文中在知识图谱图神经网络的基础上,提出了一种基于知识图谱与用户兴趣的推荐算法。该算法通过引入一个独立的用户兴趣捕获模块,来学习用户历史信息,引入了用户兴趣,使得推荐算法在用户和物品两个方面都得到了良好表征。实验结果表明,在 MovieLens 数据集上,基于知识图谱与用户兴趣的推荐算法实现了数据的充分利用,具有良好的效果,对推荐准确性起到了促进作用。

关键词: 推荐算法;知识图谱;图神经网络;用户兴趣

中图分类号 TP391

Knowledge Graph and User Interest Based Recommendation Algorithm

XU Tianyue¹, LIU Xianhui² and ZHAO Weidong²

1 College of Electronic and Information Engineering, Tongji University, Shanghai 201804, China

2 CAD Research Center, College of Electronic and Information Engineering, Tongji University, Shanghai 201804, China

Abstract In order to solve the problems of cold start and data sparsity in the collaborative filtering recommendation algorithm, the knowledge graph with rich semantic information and path information is introduced in this paper. Based on its graph structure, the recommendation algorithm which applies graph neural network to knowledge graph is favored by researchers. The core of the recommendation algorithm is to obtain item features and user features, however, research in this area focuses on better expressing item features and ignoring the representation of user features. Based on the graph neural network, a recommendation algorithm based on knowledge graph and user interest is proposed. The algorithm constructs user interest by introducing an independent user interest capture module, learning user historical information and modeling user interest, so that it is well represented in both users and items. Experimental results show that on the MovieLens dataset, the recommendation algorithm based on knowledge graph and user interest realizes the full use of data, has good results and promotes the accuracy of recommendation.

Keywords Recommendation algorithm, Knowledge graph, Graph neural networks, User interest

1 引言

推荐系统在信息过载的背景下发挥着尤为重要的作用,被广泛应用于电商、音乐、书籍电台等诸多领域,帮助用户在海量信息中更快地找到感兴趣的商品,并且挖掘用户潜在兴趣,实现商家和用户高层次的交流。知识图谱^[1]是一种具有语义联系与开放性的结构化知识库,可以提供更加丰富的信息,更好地表达商品之间所隐含的关联,被广泛应用于自然语言处理等领域。其引入可以有效解决传统推荐算法的冷启动和数据稀疏性等问题。知识图谱本身的图结构形式,可以与图神经网络巧妙结合,从而提高推荐效果的准确性。

推荐算法的核心内容包含两个部分:物品特征建模和用户特征建模。目前,基于知识图谱的推荐算法的重点在于更好地表达物品特征,用户特征向量的构建相对简单,缺失了关键的用户信息。在推荐过程中,用户对某一产品是否产生兴趣,不仅仅取决于产品本身的特征,还可以根据用户历史行为来推断。历史行为可以辅助挖掘用户潜在的兴趣及深层逻辑。基于知识图谱的算法常常忽略用户交互历史信息,或者在加入用户行为时,用户建模模块与物品建模模块耦合度过高,引入无效信息,产生了大量额外噪声。并且,在实际过程中,每个用户对各产品的特征关注是不同的,从而产品特征需要针对各个用户进行个性化表达。

到稿日期:2022-12-29 返修日期:2023-05-24

基金项目:国家重点研发计划(2022YFB3305700)

This work was supported by the National Key Research and Development Program of China(2022YFB3305700).

通信作者:柳先辉(xianhui_l@163.com)

为了针对每个用户有效提取产品特征,本文结合注意力卷积神经网络 GAT^[2],区分不同用户对关系的偏好程度,利用 KGCN^[3]算法在知识图谱上学习产品特征。为补全用户兴趣特征,同时降低耦合程度,本文设计了一个相对独立的用户历史信息特征提取模块,使用长短期时间序列网络 LSTM^[4],并且在此基础上进行改进,区分不同时刻的重要性,引入注意力机制^[5],对用户行为的深层逻辑进行建模。在更加丰富全面的产品特征和用户特征的基础上进行推荐,以实现更高的推荐准确度。实验结果表明,本文提出的基于知识图谱和用户兴趣的推荐算法在 MovieLens 两个不同大小的数据集上推荐准确度明显高于原始模型 KGCN 算法,且引入注意力机制的改进版本也有进一步的提升效果。由此可见,基于知识图谱和用户兴趣的推荐算法能够实现良好推荐,并有效地改进了 KGCN 算法。

本文的贡献如下:

- 1) 针对用户历史信息缺失的问题,本文设计了独立的用户兴趣模块,对用户历史信息建模,使得模型更加关注用户兴趣信息。
- 2) 针对用户历史行为的时间序列特性以及各个历史行为的重要程度差异性,分别采用 LSTM、注意力机制以及多头注意力机制提取兴趣特征。
- 3) 将知识图谱抽取得到的实体特征与用户兴趣模块提取的用户特征相结合,并应用于推荐算法。

2 相关工作

基于知识图谱的图神经网络推荐算法,通过引入知识图谱,解决了传统推荐算法存在的问题。传统的推荐算法以协同过滤^[6]为主,例如因子分解机 FM^[7]、宽广型网络 Wide&Deep^[8]、神经因子分解机 NFM^[9]、深度因子分解机 DeepFM^[10]等。该类算法除无法对项目属性和用户项目上下文建模外,还存在着冷启动和数据稀疏性的问题。知识图谱的引入可以有效解决该类问题。并且,知识图谱具有复杂的结构和多种类型的实体和关系,便于向推荐系统增加丰富多样的结果,增强可解释性。

知识图谱图神经网络算法充分利用了图谱特征,在基于知识图谱的推荐算法的 3 种主要类别(基于嵌入、基于路径和统一方法^[11-14])中属于统一方法。基于嵌入的方法主要通过 KGE 模块,训练得到图谱中的物品以及关系所对应的 Embedding。基于路径的方法利用知识图谱的结构信息构建用户项目图,基于连通相似性,通过两个物品之间的连接通路以及各跳邻居等信息,得到最优推荐。统一方法则是基于嵌入和基于路径两种方法的结合。知识图谱作为异构图,与图神经网络相结合具有得天独厚的优势,既结合了基于嵌入方法充分利用图谱丰富的语义信息的优点,同时具备基于路径方法有效利用结构信息的优点。

当前,基于知识图谱的图神经网络推荐方式^[15-16]已发展出多种算法。KGCN^[3]通过 GAT,在知识图谱中聚合 item,针对不同的用户,采用注意力机制,考虑到不同关系的影响程度,最终生成不同的 item。KGNN-LS^[17]加入标签平滑项,假设邻接实体的用户相关性标签类似,泛化未观测交互。

KGAT^[18]首先将用户项目交互图和知识图谱融合成一个图,随之也引入了一定的噪声,并且区别于 KGCN,对于所有用户,KGAT 学习到的 item 都是相同的。同时,使用 TransR 模型来正则化实体和关系嵌入。IntentGC^[19]根据不同的关系,将知识图谱拆分成两个同质图,简化了图结构。该模型提出了 vector-wise 这一更高效的卷积方式,过滤无意义信息。AKGE^[20]算法利用 GRU 在子图中聚合结点信息,其缺点在于使用 TransR 预训练实体 Embedding 和距离度量定义。KGLN^[21]提出了一种端到端的图神经网络推荐算法,并且在聚合邻居特征时考虑到了不同实体的影响权重。总结上述算法,基于知识图谱的推荐系统着重解决图简化、多类型关系处理、用户信息与图谱整合 3 个方面。

对于本文如何结合用户兴趣这一重点问题,ATBRG^[22]算法做出了相关探索。其核心目标在于挖掘用户历史行为与目标产品之间的关联,其做法是在知识图谱中,动态构建子图以连接用户历史产品与目标产品,并在该子图上应用图神经网络传递节点信息并聚合。其后借鉴序列化推荐算法 DIN^[23]以及 DIEN^[24]算法思想,将历史行为特征聚合到用户表示中,以得到包含兴趣信息的用户特征。MTBRN^[25]与 ATBRG 类似,解决了用户行为中隐含的深层逻辑问题。它首先在 user-item 共现矩阵上计算得到物品之间的相似度图,并引入知识图谱,随后分别在两个图上得到历史行为链接到目标产品的路径,最后通过双向长短期神经网络得到路径编码,进行 CTR 预测。该方式未能充分利用知识图谱中的邻域节点信息。MIKU^[26]算法采用自适应的方式,分别通过用户的历史行为和知识图谱中的关系路径链接到历史项目信息,构建浅层兴趣和用户深层兴趣,为推荐系统增加了可解释性,并且解决了传统推荐算法中用户信息缺失的问题。KG-AttCNN^[27]算法通过循环神经网络对用户序列进行建模,通过随机游走的方式嵌入知识图谱,其局限性在于提取实体项目信息时未充分利用知识图谱所提供的辅助信息,不能准确表达实体向量。

3 问题定义

将算法定义在电影推荐场景中,则问题可以描述为:现在有一个包含 M 个用户的用户集合 $U = \{u_1, u_2, \dots, u_m\}$ 和包含 N 个物品的物品(电影)集合 $V = \{v_1, v_2, \dots, v_n\}$ 。user-item 二部图由实际过程中用户和物品之间的交互产生,即为交互矩阵 $Y \in R^{M \times N}$ 。在电影等评分推荐系统中,有 $y_{uv} = score_{uv}$,即用户 u 对电影 v 的评分。在电商等系统中,会有 $y_{uv} = 1/0$,即为 1 时,表明用户点击或者购买了该商品;为 0 时,表明用户对该商品不感兴趣。

除了交互数据之外,已获取该系统相应的知识图谱即 G 。 G 由 (h, r, t) 实体-关系-实体三元组构成。 $h \in E, t \in E$,其中 E 为 G 的所有实体集; $r \in R$,其中 R 为 G 的所有关系集。相应地,上文提到的交互图中的物品集合中的任意物品 v ,在 E 中都存在一实体 e 与之对应,使得交互图和知识图谱可结合使用。

给定 user-item 交互矩阵 Y 和相应的知识图谱 G ,目标为:对于任意一个用户 u ,判断该用户对其未交互过商品 v

具有的兴趣程度。最终该问题被转换成计算更精确、更符合实际数据的函数 $\hat{y}_{uv} = f(u, v | \Theta, Y, G)$ 。其中, Θ 为本文通过神经网络需要学习的参数。

4 基于知识图谱和用户兴趣的推荐算法

本文提出了一种基于知识图谱和用户兴趣的推荐算法,如图1所示。该算法包含两大模块:基于图神经网络的知识图谱模块和用户兴趣捕获模块。

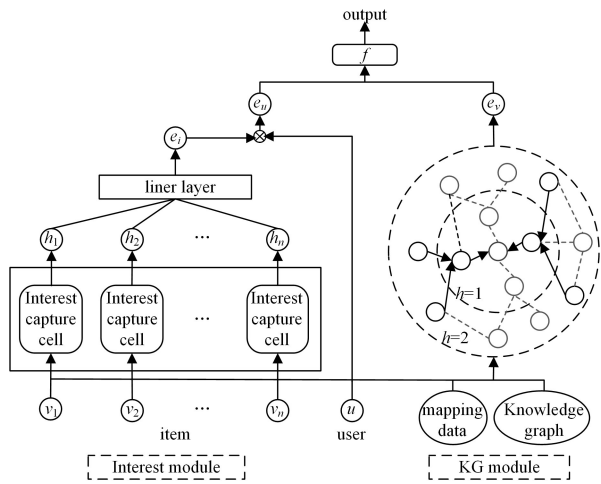


图1 基于知识图谱与用户兴趣的推荐算法

Fig.1 Knowledge graph and user interest based recommendation algorithm

知识图谱模块在知识图谱图上进行信息传递聚合,目的是得到由知识图谱增强的物品特征 e_v 。用户兴趣模块经过兴趣捕获层以及随后的兴趣聚合层进行用户信息融合,目的是得到由历史记录增强的用户特征 e_u 。以两部分作为评分函数的输入,最终可得到用户 u 对未观看过的电影 v 的评分预测。

4.1 知识图谱模块

该模块采用 KGCN 论文中提到的方式,基于 GAT,考虑到不同用户对不同关系的偏好程度,迭代聚合实体邻域信息,最终生成该实体的特征向量,即得到了物品的特征向量。

知识图谱可以作为异构图,将邻居节点的信息聚合到自身,以获取更丰富全面的信息。在聚合过程中,一般认为,不同用户对不同关系的注重程度不一致。例如,在电影场景中,用户 A 更加喜欢某个导演所执导的影片,因此他更侧重“执导”这一关系。而用户 B 更加喜欢某个演员参演的电影,因此 B 更侧重“参演演员”这一关系。我们用 π 来表示这一偏好:

$$\pi_r^u = g(u, r) \quad (1)$$

其中, g 为采用的函数。

那么,对于某个节点 v 来说,其邻域信息可以用其邻居特征的线性组合表示。

$$v_{N(v)}^u = \sum_{e \in N(v)} \pi_{v,e}^u e \quad (2)$$

其中, $N(v)$ 表示 v 节点所有的邻居节点。需要注意的是,式(2)中的偏好值 π 是用户 v 对所有邻居节点的偏好值 π 归一化后的结果,即:

$$\pi_{v,e}^u = \frac{\exp(\pi_{v,e}^u)}{\sum_{e \in N(v)} \exp(\pi_{v,e}^u)} \quad (3)$$

本文同样沿用 KGCN 思路,面对异构图相邻节点数量不一致的情况,采用控制邻居个数的方法,引入超参数 K 。对于任意节点 v ,只选取 K 个邻居聚合特征。最后,得到了 v 的邻域信息 $v_{N(v)}^u$ 。随后,将该节点本身的特征与获得的新信息进行融合,可以采用不同的聚合函数,包括加法聚合、拼接聚合、邻居聚合等方式。最终用得到的新的特征向量来表示该节点信息。

KG 模块的目的在于充分利用知识图谱的结构和语义信息,补充实体本身的特征,从而得到更好的特征向量 e_v 。

4.2 用户兴趣模块

在用户兴趣模块,本文使用循环神经网络,依据 user-item 共现矩阵,针对每一个用户的历史行为捕获用户兴趣,刻画更加细致准确的用户特征。这使得模型不再仅仅依赖静态信息,循环神经网络也为模型引入了动态信息。本文根据用户的好评记录或者购买记录,来预测用户下一时刻所要采取的行动,即给哪个电影好评,点击浏览或者购买哪个物品,以帮助系统更好地做出推荐并且使得用户在更短的时间内发现目标。

4.2.1 捕获历史兴趣

本文采用 LSTM(长短期记忆网络)作为循环神经网络部分。LSTM 引入了门控机制,通过遗忘门、输入门、输出门解决了 RNN 梯度消失和梯度爆炸等问题,结构简洁,效果好,是时序网络中常用的典型模型。




图2 LSTM 细胞单元

Fig.2 LSTM cell unit

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (6)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (7)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = o_t * \tanh(C_t) \quad (9)$$

式(4)对应遗忘门, f_t 决定对上一个细胞状态 C_{t-1} 遗忘的内容。

式(5)~式(7)对应输入门, i_t 决定对当前临时细胞状态 \tilde{C}_t 保留的量,由上一细胞状态留下的状态信息,和当前输入选取的信息共同更新细胞状态为 C_t 。

式(8)、式(9)对应输出门, o_t 决定输出更新后的细胞状态 C_t 的内容, h_t 即为该时刻的输出。

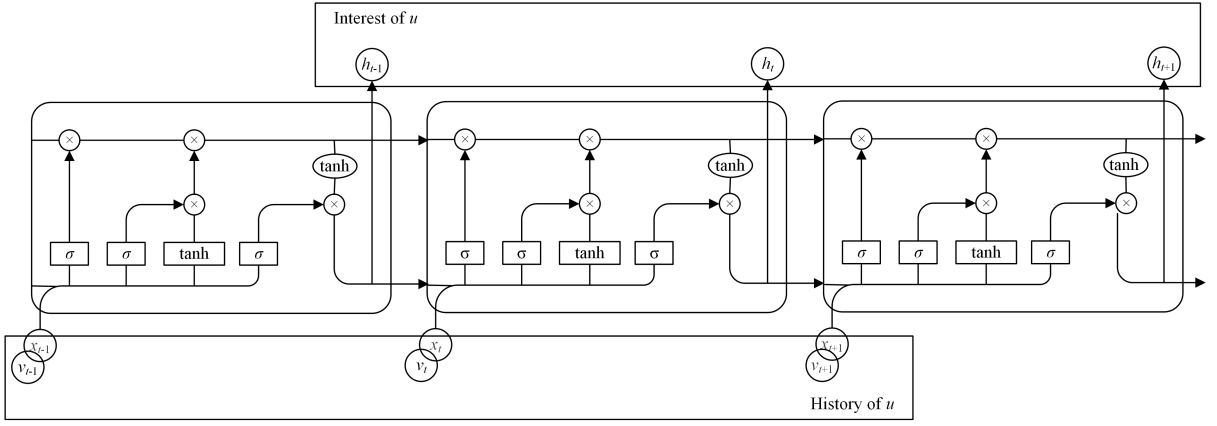


图3 LSTM用户兴趣建模

Fig. 3 User interest modeling with LSTM

进行特征建模前,已抽取用户 u 的历史好评物品时间序列 $\mathbf{H}(u)=[v_1, v_2, \dots, v_n]$ 。

在推荐系统中,有两个主要问题十分重要——冷启动和数据不均匀问题。这两点也对用户兴趣捕获过程有一定的影响。对于不同的用户,在不同的时刻,所产生的历史好评记录数量是不一致的。例如,对于同一个用户 A 来说,刚刚注册账户时,所观看过的影片数量为 0,不存在历史信息;而注册一年后好评过的影视数量为 20。对于不同用户如用户 A 和用户 B ,同在 t 时刻, A 的历史好评记录为 20,即 $N_H=20$;而 B 平时很少观看影视,即与物品之间的交互很少,他的历史好评记录为 4,即 $N_H=4$ 。在输入神经网络捕获用户兴趣之前,引入 f 来解决该问题。

$$\mathbf{H}(u) = \begin{cases} f * [v_r], & N=0 \\ [v_1, v_2, \dots, v_N] \cup (f-N) * [v_r], & 0 < N < f \\ [v_{N-J}, v_{N-J+1}, \dots, v_N], & N \geq f \end{cases} \quad (10)$$

其中, N 即为用户 u 历史好评序列大小 N_H , v_r 可以每次动态生成或者是给定一个初始值。

那么,对 LSTM 模块来说,输入 x_t 即为 v_t ,输出 h_t 即为我们需要的每个时刻的用户兴趣信息,形成用户 u 的兴趣序列 $\mathbf{I}(u)=[h_1, h_2, \dots, h_j]$ 。

4.2.2 兴趣融合

首先将各个历史时刻的兴趣特征聚合起来,有多种方式,常用的有 concat 操作、sum 操作以及 max pooling 等。本文使用一个线性层,以各个特征向量为输入,得到一个 d 维的用户兴趣特征 e_i 。




图4 兴趣聚合结构

Fig. 4 Interest aggregation

最后,将用户特征与得到的兴趣特征相融合,得到最终用户信息 e_u 。

4.3 结合注意力机制的用户兴趣模块

用户兴趣捕获模块的目的在于聚合历史行为特征,用户

历史行为可以表达用户兴趣的转变发展,从而更好地学习用户特征。在该模块,除了使用 LSTM 算法,还尝试使用注意力机制等方法,区别用户历史中各个时刻行为的重要程度。

4.3.1 自注意力机制

在初始模型中,本文使用的基本结构是 LSTM 模块。其对于每一个时刻的历史记录 v_t ,做同样的处理,几乎是无差别对待。但是在实际过程中,各个 v_t 对用户兴趣反映的重要程度是不一致的。比如在购物场景中,用户 A 家中有一个新生儿宝宝,那么 A 用户偏向购买的物品和幼儿抚育相关,如奶粉、玩具、纸尿裤。而在这个过程中,可能偶尔还会购买一个老人用的轮椅,那么轮椅所反映的用户兴趣是占比较小的。

在自注意力机制中,为每个 v_t 分配不同权重 w_t ,降低噪声或者其他因素带来的干扰,以捕获本序列(即针对一个序列,常说的注意力机制发生在两个序列之间,如机器翻译、源语言与目标语言是两个序列)各个元素之间的相关性。

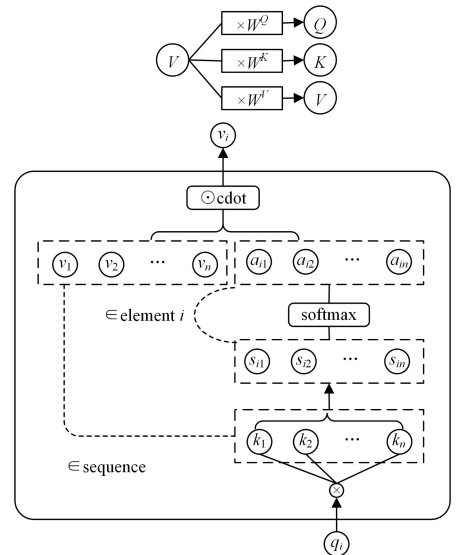


图5 Attention 单元

Fig. 5 Attention unit

每个时刻的输入都看作是 $\langle key, value \rangle$ 对,并且序列中的每个元素还对应一个 $query$ 。即存在 3 个序列,依次是 $\mathbf{Key}=\{k_1, k_2, \dots, k_n\}$, $\mathbf{Value}=\{v_1, v_2, \dots, v_n\}$, $\mathbf{Query}=\{q_1, q_2, \dots, q_n\}$ 。这 3 个序列都可以由给定序列的元素计算得到。那么

在本文的推荐系统中,给定序列为用户当前时刻对应的历史好评物品序列,即 $V = \{v_1, v_2, \dots, v_n\}$ (此处的 v_i 与 Value 序列中的 v_i 不是同一含义)。即:

$$\begin{aligned} \text{Query} &= V * W^Q \\ \text{Key} &= V * W^K \\ \text{Value} &= V * W^V \end{aligned} \quad (11)$$

自注意力机制的目的是为每一个序列元素按照其在序列中的重要程度,重新分配一个 value 值。为了计算该值,首先计算任意元素 i 的 q_i 与序列所有元素(包含自身)

的 k_j 之间的相关性 sim_{ij} ,常用点积相似性、距离相似性或者 cos 相似性来计算相关性;并且归一化得到该元素与任意元素之间的 a_{ij} ,即 attention。元素 i 的注意力权重序列 $a_i = \{a_{i1}, a_{i2}, \dots, a_{in}\}$ 。其最终的值为 a_{ij} 与各个对应元素 v_j 的加权和。

$$a_{ij} = \text{softmax}(sim_{ij}) = \frac{e^{sim_{ij}}}{\sum_{j=1}^N e^{sim_{ij}}} \quad (12)$$

$$v_i = \sum_{j=1}^N a_{ij} \times v_j \quad (13)$$

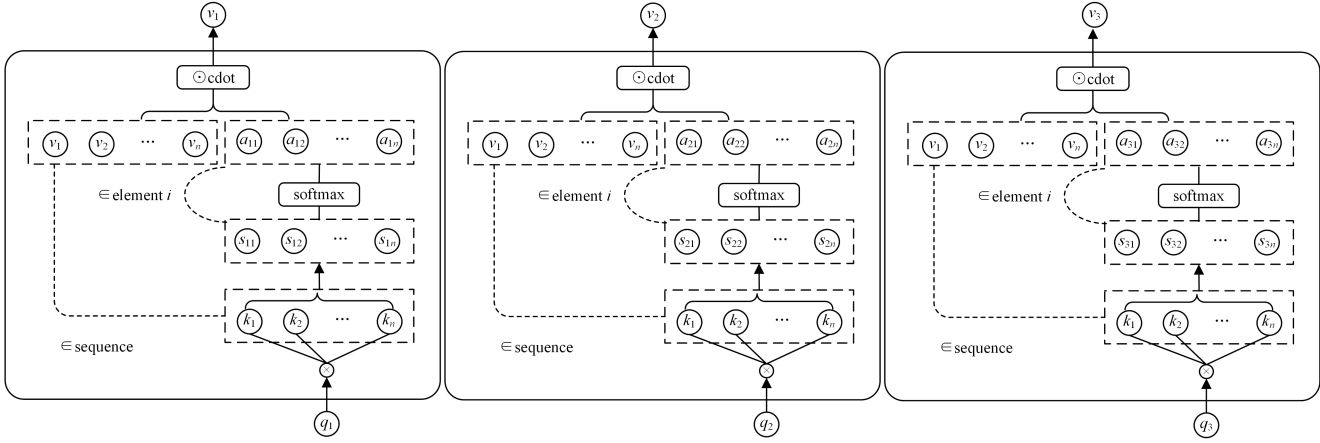


图 6 Attention 用户兴趣建模

Fig. 6 User interest modeling with attention

由此总结出自注意力机制的几个关键步骤:首先计算每一元素 query 值与其他元素 key 值之间的相关性,并且归一化得到该元素与其他元素之间的 attention。然后 attention 与各元素的 value 加权求和得到该元素在序列中可体现其重要性的新的 value。该值对应于初始模型中经由 LSTM 模块得到的 h_t ,即各个时刻的用户兴趣信息。

4.3.2 多头自注意力机制

在自注意力机制的基础上进行扩展,并行计算出多组 ($Query, Key, Value$)。每一组各自计算得到其新的 Value 值,最后将这几组 Value 值对应元素的向量收尾拼接,组成各个元素对应的最终兴趣信息。

$$v_i = \text{concat}(v_i^1, v_i^2, \dots, v_i^{N_{\text{head}}}) \quad (14)$$

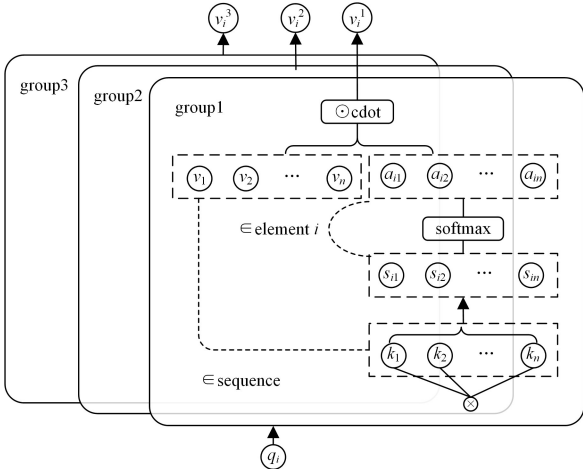


图 7 Multi-head attention 单元

Fig. 7 Multi-head attention unit

5 实验

5.1 数据集

由于本文所改进的算法需要获取当前用户的历史物品交互信息,因此用于实验的数据集需要带有每条点评记录的时间戳。同时,还有相关领域的知识图谱,以及交互物品与知识图谱中实体的对应关系。本文在 MovieLens^[28]数据集上进行测试。

MovieLens 数据集是一个电影评分数据集,由 GroupLens Research 从其电影评分网站上收集并制作整理成可用的评分数据集。该数据集可按大小分为不同的类,分别为 MovieLens100K, MovieLens1M 和 MovieLens20M 等;还可按照是否带有标签、时间先后等进行分类。

本文选取 MovieLens100K 和 MovieLens1M 两个不同大小的数据集进行实验测试。每一个数据集中都包含电影信息、用户信息以及用户-电影评分文件,评分为 1-5 的整数,一般设置分数大于等于 4 的为好评,其余为中差评。本文还重点关注其中的评分时间属性,文件中采用时间戳的形式。

表 1 MovieLens 数据集的相关信息

Table 1 Statistics of MovieLens datasets

Dataset	User	Item	Interaction	timestamp
ML-100K	943	1682	100000	✓
ML-1M	6040	3952	1000209	✓

5.2 实验设置

针对每个数据集,使用的实验参数如下。对于实体和关系的词嵌入,使用随机方式初始化,利用 torch.nn.Embed-

ding,并在后续的训练中重新调整并优化。在实验中,实体和关系的 Embedding 维度设置为 32。并且在训练数据顺序混乱的基础上,随机抽取其中的 80% 作为训练数据。MovieLens100K 设置 batch_size 大小为 32, MovieLens1M 设置 batch_size 大小为 1024。训练过程中使用的优化器为 Adam 优化器, L_1 设置为 5×10^{-4} , L_2 设置为 1×10^{-4} 。

针对用户兴趣模块,设置每个时间节点需要向前捕获的历史好评个数,依次选择 8,10,12 进行实验,将最优测试结果作为最终结果。针对使用多头注意力机制的用户兴趣模块,增加了一个参数即头数量。设置头数量为 2 进行实验,其他参数与上述实验保持一致。

针对 KGCN 的信息聚合模块,每一个迭代将聚合的邻居数量为 8,并采用 sum 的聚合形式。由于 KGCN 的限制,需要尽可能保留每一个实体自身较为丰富的独特局部信息,因此也只进行一次迭代,不再进行二三轮聚合,防止每个实体因具备太多全局特征而降低模型效果。

5.3 基准模型和实验指标

本文在 KGCN 模型,即知识图谱图卷积神经网络推荐算法的基础上,设计独立的用户兴趣捕获模块,以更好地表达用户特征。在实验部分,首先验证用户兴趣对于推荐算法的有效性,以基于知识图谱的推荐算法 KGCN 和 MKR^[29] 为基线,与现有的知识图谱推荐算法进行比较。该部分使用的实验指标为 AUC 和 F1^[3]。在推荐算法中评估模型时,若使用精确率、召回率、TPR 等单个指标,容易出现评估效果不错而实际效果不佳的问题。AUC 综合考虑 TPR 和 FPR 指标,不依赖于分类阈值的选取,更符合真实场景中更加侧重物品之间的相对序列而不关心物品预测分的特点。AUC 可以理解作为一种概率,即随机选取一个正负样本对,用某一算法进行分类预测,对正样本预测值大于对负样本预测值的概率。在推荐算法中,该指标可以有效反映模型在实际情况中的推荐准确度。F1 Score 是统计学中用来衡量二分类模型精确度的一种指标。它同时兼顾了模型的精确率和召回率。

其次,为了充分验证模型在 MovieLens 数据集上相比传统协同过滤推荐算法有更好的效果,将其与 FM, Wide&Deep, DeepFM 模型进行对比。最后,针对知识图谱的加入是否能真正缓解冷启动问题,以序列推荐算法 DIN, HGN^[30], SINE^[31] 为基线进行本数据集上的对比实验。该部分的实验以 AUC 作为验证指标。

5.4 实验结果

对比知识图谱推荐算法的实验结果如表 2 所列。

表 2 对比知识图谱推荐算法的实验结果

Table 2 Experimental results compared with knowledge graph recommendation

methods	ML-100K		ML-1M	
	AUC	F1	AUC	F1
MKR	0.8801	0.8048	0.9060	0.8314
KGCN	0.8896	0.8144	0.8912	0.8188
KGCN_LSTM	0.9139	0.8361	0.9022	0.8283
KGCN_Attention	0.9237	0.8504	0.9118	0.8363
KGCN_MultiAttention	0.9062	0.8322	0.9101	0.8370

5.5 分析和讨论

首先,由实验可得,引入用户兴趣的推荐算法获得了良好

的推荐效果。与仅通过知识图谱获得实体信息的推荐算法相比,本文模型在两个不同的数据集上都有一定的提升效果,展示了兴趣信息对整个系统的显著作用。

由图 8 和图 9 可以得出以下结论:

1) KGCN_LSTM 在两个数据集上的 AUC 值分别为 91.39% 和 90.22%, 比 KGCN 高出 2.43% 和 1.10%; 在 MovieLens100K 上,其利用信息的能力更强,比 MKR 高出 3.38%, 在 MovieLens1M 上较 MKR 效果略有下降,降低了 0.38%。其 F1 值分别为 83.61% 和 82.83%, 比 KGCN 高出 2.17% 和 0.95%, 在 MovieLens100K 上比 MKR 高出 3.33%, 在 MovieLens1M 上较 MKR 降低了 0.31%。这说明结合 LSTM 捕获用户兴趣的推荐算法的性能优于 KGCN, 且对于数据量少的数据集,可更加充分地利用信息。

2) KGCN_Attention 在两个数据集上的 AUC 值分别为 92.37% 和 91.18%, 比 KGCN_LSTM 高出 0.98% 和 0.96%, 并且比 KGCN 高出 3.41% 和 2.06%, 比 MKR 高出 4.36% 和 0.58%。其 F1 值分别为 85.04% 和 83.63%, 比 KGCN_LSTM 高出 1.43% 和 0.80%, 并且比 KGCN 高出 3.60% 和 1.75%, 比 MKR 高出 4.56% 和 0.46%。这说明结合注意力机制相比使用 LSTM 捕获用户兴趣更加优越。

3) KGCN_MultiAttention 在两个数据集上的 AUC 值分别为 90.62% 和 91.01%, 较 KGCN_LSTM 和 KGCN_Attention 效果有所降低,但是分别比 KGCN 高出 1.66% 和 1.89%, 比 MKR 高出 2.61% 和 0.41%。其 F1 值分别为 83.22% 和 83.70%, 比 KGCN 高出 1.78% 和 1.82%, 比 MKR 高出 2.74% 和 0.49%。这说明 LSTM 算法和注意力机制在该模型中的效果优于多头注意力机制。相比基准模型 KGCN 和 MKR, 结合多头注意力机制的推荐算法也有一定的提升效果。




图 8 对比知识图谱推荐算法的 AUC 柱状图

Fig. 8 Histogram of AUC compared with knowledge graph recommendation




图 9 对比知识图谱推荐算法的 F1 柱状图

Fig. 9 Histogram of F1 compared with knowledge graph recommendation

其次,由表3中本文算法对比协同过滤推荐算法和序列化推荐算法的结果可知,知识图谱的加入有效提升了系统的性能,尤其是针对数据量更小的数据集 ML-100K,提升效果更加显著。这验证了知识图谱的引入充分缓解了冷启动等问题,以及结合时间序列表征用户兴趣与知识图谱表征物品特征的模型有效性。

表3 对比协同过滤算法和序列化推荐算法的实验结果

Table 3 Experimental results compared with CF recommendation and sequential recommendation

methods	ML-100K	ML-1M
	AUC	AUC
FM	0.7832	0.8081
Wide&Deep	0.7834	0.8129
DeepFM	0.7865	0.8182
DIN	0.8672	0.9140
HGN	0.7474	0.7367
SINE	0.8532	0.8990
KGCN_LSTM	0.9139	0.9022
KGCN_Attention	0.9237	0.9118
KGCN_MultiAttention	0.9062	0.9101

由表3可得出以下结论:

1)本文提出的推荐算法中性能表现最好的模型是KGCN_Attention,其在 ML-100K 和 ML-1M 数据集上的 AUC 值分别为 92.37% 和 91.18%。

2)本文提出的结合知识图谱与用户兴趣的推荐算法在 ML-100K 和 ML-1M 数据集,相比协同过滤推荐算法 FM, Wide&Deep, DeepFM, AUC 值分别提升了 14.05%, 14.03%, 13.72%。

3)本文提出的结合知识图谱与用户兴趣的推荐算法在 ML-100K 和 ML-1M 数据集上相比序列化推荐算法 DIN 有大幅度下降, AUC 值降低了 0.22%, 但是相比 HGN 和 SINE, AUC 值分别提升了 17.51% 和 1.28%。

通过上述几个实验,证明了引入用户特征对推荐系统的重要性以及知识图谱对推荐系统的重要意义。并且,并非使用越复杂的模型,所取得的效果就越好。其复杂程度如果不是从较为本质的层面做出改进,反而会使得模型变得累赘臃肿,影响模型效果。本模型在精简结构上实现了数据的充分利用,有效提取了用户兴趣特征,降低了模块之间的耦合程度,在提高推荐算法准确性上取得了良好的效果。

结束语 本文介绍了一系列实验模型,在现有的基于知识图谱图神经网络推荐算法的基础上,捕获了用户兴趣信息,改进了算法性能。知识图谱部分的重点在于聚合 item 表示,本文区分了每个用户对不同 item 之间关系的重视程度,使用 GAT 进行学习。通过知识图谱中相连接的实体,不断更新传播,学习实体的表示。而对用户历史行为进行建模,则在一定程度上可以表达用户兴趣的转变发展,更好地学习用户表示。在该模块,使用 LSTM 以及注意力机制等方法探索其可行性,然后对两个模块内容进行综合处理,并对最终效果进行讨论。可以看出,将用户兴趣信息与丰富的实体信息相结合的方式,在推荐算法实现中获得了不错的效果。

此次实验的主要特点为在知识图谱图神经网络的基础

上,充分利用用户历史信息,构造出一个具有综合性和完备性的推荐算法结构。相比之下,该结构可以充分协调利用已有数据,对于处于冷启动阶段,数据量尚且不足的推荐系统有着良好的适用性。本文工作最大的局限性在于,虽然规划完备了整体推荐框架,但是算法的具体实现有待提出更加新颖独特的设计。例如,本文在实体信息建模方面,沿用 KGCN 推荐算法模型,对于图神经网络处理知识图谱的过程还可进行轻量化以及特征聚合等方面的探索。其次,还可密切两模块底层网络的信息交互过程,实现信息互补。本文的另外一个局限性在于,所提算法同时需要相应数据的历史交互信息以及知识图谱数据,因此仅针对不同大小的 MovieLens 数据集进行了测试,下一步的研究目标是整理不同场景如音乐、书籍、商品等领域的数据集,并构建相应的知识图谱,满足实验要求,测试模型效果,并在进一步的实验结果的启发下,在算法上进行更加独创新的改进。

综上所述,本文提出的基于知识图谱与用户兴趣的推荐算法将知识图谱推荐方向和序列化推荐方向相结合,有效解决了用户特征不足和冷启动等问题,表现出了良好的实验性能。当前工作还存在着算法结构和数据集上的局限性,有待我们进一步完善。未来,在该综合性的推荐方向的启发下,我们可以进行更加新颖、完善的探索,不断进步成长。

参考文献

- [1] JI S, PAN S, CAMBRIA E, et al. A survey on knowledge graphs: Representation, acquisition, and applications [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 33(2): 494-514.
- [2] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks [J]. arXiv: 1710.10903, 2017.
- [3] WANG H, ZHAO M, XIE X, et al. Knowledge graph convolutional networks for recommender systems [C] // The World Wide Web Conference. 2019: 3307-3313.
- [4] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural computation, 1997, 9(8): 1735-1780.
- [5] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30: 5998-6008.
- [6] HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering [C] // Proceedings of the 26th International Conference on World Wide Web. 2017: 173-182.
- [7] RENDLE S, GANTNER Z, FREUDENTHALER C, et al. Fast context-aware recommendations with factorization machines [C] // Proceedings of the 34th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2011: 635-644.
- [8] CHENG H T, KOC L, HARMSSEN J, et al. Wide & deep learning for recommender systems [C] // Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. 2016: 7-10.
- [9] HE X, CHUA T S. Neural factorization machines for sparse predictive analytics [C] // Proceedings of the 40th International

- ACM SIGIR Conference on Research and Development in Information Retrieval. 2017;355-364.
- [10] GUO H, TANG R, YE Y, et al. DeepFM: a factorization-machine based neural network for CTR prediction[J]. arXiv:1703.04247, 2017.
- [11] GUO Q, ZHUANG F, QIN C, et al. A survey on knowledge graph-based recommender systems[J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 34(8): 3549-3568.
- [12] ZHANG F, YUAN N J, LIAN D, et al. Collaborative knowledge base embedding for recommender systems[C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016;353-362.
- [13] WANG H, ZHANG F, WANG J, et al. RippletNet: Propagating user preferences on the knowledge graph for recommender systems[C]// Proceedings of the 27th ACM International Conference on Information and Knowledge Management. 2018; 417-426.
- [14] ZHU D L, WEN Y, WAN Z C. Review of Recommendation Systems Based on Knowledge Graph[J]. Data Analysis and Knowledge Discovery, 2021, 5(12): 1-13.
- [15] WU G D, ZHA Z K, TU L J, et al. Research advances in graph neural network recommendation[J]. CAAI Transactions on Intelligent Systems, 2020, 15(1): 14-24.
- [16] WU J, XIE H, JIANG H W. Survey of Graph Neural Network in Recommendation System[J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(10): 2249-2263.
- [17] WANG H, ZHANG F, ZHANG M, et al. Knowledge-aware graph neural networks with label smoothness regularization for recommender systems [C] // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019;968-977.
- [18] WANG X, HE X, CAO Y, et al. Kgat: Knowledge graph attention network for recommendation[C]// Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019;950-958.
- [19] ZHAO J, ZHOU Z, GUAN Z, et al. Intentgc: a scalable graph convolution framework fusing heterogeneous information for recommendation[C]// Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019;2347-2357.
- [20] SHA X, SUN Z, ZHANG J. Hierarchical attentive knowledge graph embedding for personalized recommendation[J]. Electronic Commerce Research and Applications, 2021, 48: 101071.
- [21] LIU H, LI X G, HU L K, et al. Knowledge graph driven recommendation model of graph neural network[J]. Journal of Computer Applications, 2021, 41(7): 1865-1870.
- [22] FENG Y, HU B, LV F, et al. Atbrg: Adaptive target-behavior relational graph network for effective recommendation [C] // Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2020; 2231-2240.
- [23] ZHOU G, ZHU X, SONG C, et al. Deep interest network for click-through rate prediction[C]// Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2018;1059-1068.
- [24] ZHOU G, MOU N, FAN Y, et al. Deep interest evolution network for click-through rate prediction[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2019;5941-5948.
- [25] FENG Y, LV F, HU B, et al. Mtbrn: Multiplex target-behavior relation enhanced network for click-through rate prediction [C]// Proceedings of the 29th ACM International Conference on Information & Knowledge Management. 2020;2421-2428.
- [26] DUAN W J, XIE J, XU X Y, et al. MIKU: Multi-layer User Interest Model Based on Knowledge Graph[J]. Journal of Chinese Mini-Micro Computer Systems, 2022, 43(5): 1006-1012.
- [27] SHEN D D, WANG H T, JIANG Y, et al. A sequence recommend algorithm based on knowledge graph embedding and multiple natural networks[J]. Computer Engineering & Science, 2020, 42(9): 1661-1669.
- [28] HARPER F M, KONSTAN J A. The movielens datasets: History and context[J]. ACM Transactions on Interactive Intelligent Systems (THIS), 2015, 5(4): 1-19.
- [29] WANG H, ZHANG F, ZHAO M, et al. Multi-task feature learning for knowledge graph enhanced recommendation[C]// The World Wide Web Conference. 2019;2000-2010.
- [30] MA C, KANG P, LIU X. Hierarchical gating networks for sequential recommendation[C]// Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019;825-833.
- [31] TAN Q, ZHANG J, YAO J, et al. Sparse-interest network for sequential recommendation[C]// Proceedings of the 14th ACM International Conference on Web Search and Data Mining. 2021; 598-606.



XU Tianyue, born in 1998, master. Her main research interests include knowledge graph and recommender systems.



LIU Xianhui, born in 1979, Ph.D, associate researcher (associate professor). His main research interests include machine learning, data mining and big data, and networked manufacturing.