



计算机科学

COMPUTER SCIENCE

基于全局增强图神经网络的序列推荐

周芳泉, 成卫青

引用本文

周芳泉, 成卫青. [基于全局增强图神经网络的序列推荐](#)[J]. 计算机科学, 2022, 49(9): 55-63.

ZHOU Fang-quan, CHENG Wei-qing. [Sequence Recommendation Based on Global Enhanced Graph Neural Network](#)[J]. Computer Science, 2022, 49(9): 55-63.

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)

[基于文本行匹配的跨图文本阅读方法](#)

Cross-image Text Reading Method Based on Text Line Matching

计算机科学, 2022, 49(9): 139-145. <https://doi.org/10.11896/jsjcx.220600032>

[多层注意力机制融合的序列到序列中国连续手语识别和翻译](#)

Sequence-to-Sequence Chinese Continuous Sign Language Recognition and Translation with Multi-layer Attention Mechanism Fusion

计算机科学, 2022, 49(9): 155-161. <https://doi.org/10.11896/jsjcx.210800026>

[基于值分解的多智能体深度强化学习综述](#)

Overview of Multi-agent Deep Reinforcement Learning Based on Value Factorization

计算机科学, 2022, 49(9): 172-182. <https://doi.org/10.11896/jsjcx.210800112>

[基于 Key-Value 关联记忆网络的知识图谱问答方法](#)

Key-Value Relational Memory Networks for Question Answering over Knowledge Graph

计算机科学, 2022, 49(9): 202-207. <https://doi.org/10.11896/jsjcx.220300277>

[基于多时间尺度时空图网络的交通流量预测模型](#)

Multi-time Scale Spatial-Temporal Graph Neural Network for Traffic Flow Prediction

计算机科学, 2022, 49(8): 40-48. <https://doi.org/10.11896/jsjcx.220100188>

基于全局增强图神经网络的序列推荐

周芳泉 成卫青

南京邮电大学计算机学院 南京 210023

(1219043809@njupt.edu.cn)

摘要 已有基于会话的推荐系统大多根据最后一个点击的项目与当前会话的用户偏好的相关性进行推荐,忽略了在其他会话中可能包含了与当前会话相关的项目转换,这些项目转换可能对用户的当前偏好也有一定的影响,因此需要从局部会话和整体会话的角度来综合分析用户偏好;并且这些推荐系统大多忽略了位置信息的重要性,而与预测位置越近的项目可能与当前用户兴趣的相关性越高。针对这些问题,提出一种基于全局增强的图神经网络的推荐模型(GEL-GNN)。GEL-GNN旨在根据所有会话预测用户的行为,它使用GNN来捕获当前会话的全局和局部之间的关系,使用LSTM来捕获全局层面会话间的关系。首先,通过注意力机制层将用户的偏好表示为基于全局层面和局部层面会话兴趣的组合;然后,使用反向位置信息衡量当前位置和预测位置之间的距离,以便更加准确地预测用户行为。在3个真实的数据集上进行了大量的实验,实验结果表明GEL-GNN优于现有的基于会话的图神经网络推荐模型。

关键词: 基于会话的推荐;图神经网络;注意力机制;位置信息

中图法分类号 TP391

Sequence Recommendation Based on Global Enhanced Graph Neural Network

ZHOU Fang-quan and CHENG Wei-qing

School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

Abstract Most of the existing session based recommendation systems recommend based on the correlation between the last clicked item and the user preference of the current session, and ignore that there may be item transitions related to the current session in other sessions, while these item transitions may also have a certain impact on users' current preferences. Hence, it is indispensable to analyze users' preferences comprehensively from the perspective of local session and global session. Furthermore, most of these recommendation systems ignore the importance of location information, whereas items closer to the predicted location may be more relevant to the current user's interests. To solve these problems, this paper proposes a recommendation model based on global enhanced graph neural network with LSTM (GEL-GNN). GEL-GNN aims to predict the behavior of users according to all sessions, and GNN is employed to capture the global and local relationship of the current session, while LSTM is employed to capture the relationship between sessions at the global level. Firstly, users' preferences are to be translated as a combination of conversation interests based on global and local levels through the attention mechanism layer. Then, the distance between the current position and the predicted position is measured with the reverse position information, so that user behavior can be predicted more accurately. A number of experiments are conducted on three real data sets. Experimental results show that GEL-GNN is superior to the existing session-based graph neural network recommendation models.

Keywords Session-based recommendations, Graph neural network, Attention mechanism, Position information

1 引言

随着互联网的飞速发展和信息技术的进步,网络上的资源正在爆炸式增长,加剧了信息过载问题。用户对信息的需求得到了很大的满足,但在面对如此庞大的信息量时,常常感到束手无策。用户无法从中找到真正需要和感兴趣的信息,

对信息的利用率不但没有增长,反而有所降低。推荐技术成为解决信息过载问题最有效的方法之一。传统的推荐方法通常依赖于用户简介和长期历史交互信息,但是运用在现实场景中可能表现不佳,存在着数据稀疏和冷启动问题;并且传统的推荐算法往往是对单用户实体进行建模,忽略了用户的社交关系对用户兴趣偏好产生的影响。因此,基于会话(Ses-

到稿日期:2021-07-08 返修日期:2021-10-18

基金项目:国家自然科学基金(61170322);江苏省研究生教育教学改革课题(JGZZ19_038)

This work was supported by the National Natural Science Foundation of China(61170322) and Postgraduate Education Reform Project of Jiangsu Province(JGZZ19_038).

通信作者:成卫青(chengweiq@njupt.edu.cn)

sion)的推荐近年来引起了广泛的关注,它根据给定的匿名行为序列,按时间顺序预测下一个感兴趣的项目。

会话指用户在一段时间内的浏览(或其他操作)行为,可表示为一个浏览序列,浏览对象称为物品(Item),超过一定的时间间隔,会产生下一个会话,因此,每个用户的会话数量是不固定的。由于具有很高的实用价值,会话已成为当前人们研究的热点,并有多项基于会话的推荐方案被提出。会话的应用领域十分广泛,其在电子商务、社交网络、视频音乐推荐^[1]等领域都有所应用。例如,亚马逊网站、京东、淘宝网站为用户推荐商品^[2-3],MovieLens 推荐电影的功能^[4-5]等。

基于会话的推荐的早期研究大致分为两类,即基于相似性^[6]的和基于链^[7]的。前者严重依赖当前会话中项目的共现信息,而忽略了顺序行为模式。后者推断用户对所有物品的所有可能的选择顺序,在应用于项目数量很大的现实世界时可能会遇到难以解决的计算问题。

近年来,大多数研究^[8-11]将递归神经网络(Recurrent Neural Network, RNN)应用于基于会话的推荐系统,但是RNN模型通常适合处理用户会话比较长的情况。在基于会话的推荐系统中,会话大多是匿名的且数量众多,同时会话点击中涉及的用户行为通常是有限的,如果一个会话中没有足够的用户行为,就很难从每个会话中准确地预测每个用户的表示。同时,这些方法也很容易忽略远距离用户行为操作之间的复杂转换。另外,一些方法通过使用循环神经网络和记忆网络,按照时间顺序提取会话的成对项目转换信息来推断匿名用户的偏好。然而,一个会话可能包含用户的多个选择甚至噪声,因此它们可能不足以生成所有正确的依赖关系,导致这些依赖关系在嵌入时无法对项目转换模式的复杂内在顺序进行建模。

此外,几乎所有已有研究都只基于当前会话对用户偏好建模,而忽略了来自其他会话的有用的项目转换模式,并且主要基于目标会话中的信息进行推荐,未显式地建模其他会话中的协同信息。针对此不足,本文提出一种基于全局增强图神经网络的推荐模型(Recommendation Model Based on Global Enhanced Graph Neural Network with LSTM, GEL-GNN)。该模型能够从全局的角度捕获所有会话之间的关系,同时能够捕获当前会话整体和局部之间的关系,从而不仅能够推断出用户当前会话的长短期兴趣,而且可以推断出不同用户间的兴趣爱好是否具有关联性;此外,模型使用位置信息,能够捕获用户点击序列的顺序关系,从而实现更为准确的推荐。

本文的主要贡献如下:

(1)以往基于会话的推荐只根据当前会话对用户偏好建模,而忽略了来自其他会话的有用的项目转换模式;本文采用了LSTM,将会话序列全部传入到LSTM,先判断会话与会话间是否存在相关性,并存储用户的长期偏好,同时将会话图送入图神经网络中训练,捕获会话内部的相关性,再将二者的输出同时传入注意力机制层,从全局和局部的角度对用户兴趣进行建模,使得预测结果更加准确。

(2)加入了位置信息,考虑了用户序列的前后顺序,能够更准确地判断用户兴趣的变化过程,从而得到更为准确的推荐

结果。GNN和LSTM部分并行进行,提高了系统的效率。

(3)在电商领域3个公开的数据集上进行了大量的实验,结果表明,GEL-GNN模型在各项指标上均优于与之比较的9个基准模型。

2 相关工作

2.1 传统的推荐方法

传统的推荐方法主要分为基于内容的推荐方法、协同过滤的推荐方法以及混合推荐方法。虽然传统的推荐方法可以实现推荐任务,并且融合多源异构辅助信息(多源异构信息即包含用户行为信息和个性化需求信息的图像、文本等)的混合推荐方法在一定程度上可以缓解冷启动、稀疏矩阵的问题,但是辅助信息往往具有多模态、数据异构、大规模、数据稀疏和分布不均匀等复杂特征,在处理存在融合多源异构信息的数据时混合推荐方法仍然面临着严峻挑战^[12-13]。

矩阵分解^[14]是推荐系统的一般方法,但由于它的用户偏好不考虑最终结果,仅仅由用户点击了的序列提供,因此不太适合基于会话的推荐。基于项目的邻域方法^[15]中,项目相似性是根据同一会话中的共现来计算的。这些方法通常忽略了项目的顺序,并且仅基于最后一次点击来生成预测。

随后,基于马尔可夫链的序列预测方法应运而生。Shani等^[16]提出了马尔可夫决策过程(Markov Decision Processes, MDP),对基于会话的推荐系统提出推荐项目。Rendle等^[17]为每两次相邻点击之间的顺序行为建模,并为每个序列提供更准确的预测。然而,基于马尔可夫链模型的主要不足在于它们独立地组合了过去的组件,这种独立性假设过于强烈,限制了预测精度。

2.2 基于深度学习的会话推荐算法

深度学习技术在近几年被广泛用于各个领域,并且取得了非常有前景的效果。受到自然语言领域最新进展^[18]的启发,一些专家开始将这个领域的知识运用到用户行为推荐的问题中。Hidasi等^[8]提出了GRU4REC模型,首次将RNN网络应用于基于会话的推荐。该工作采用多层门控循环单元(Gated Recurrent Unit, GRU)对项目交互序列进行建模。Tan等^[9]通过数据扩充并考虑用户行为的时移来增强模型。Tuan^[19]等将会话点击与内容特性(如项目描述和项目类别)结合起来,使用三维卷积神经网络生成用户行为推荐的操作。Li等^[11]提出NARM,将注意力机制引入堆栈GRU编码器,以获取更具代表性的项目转换信息,用于基于会话的推荐。Liu等^[19]提出的基于注意力的短时记忆网络(Short-Term Attention/Memory priority, STAMP),可以在不使用RNN的情况下捕捉用户当前的兴趣。NARM和STAMP都通过使用注意力机制来强调最后一次点击的重要性。Wu等^[20]提出了一个门控模型(SR-GNN)来学习会话图上的项目嵌入,然后通过将每个学习到的项目嵌入与关注度相结合,得到一个代表性的会话嵌入。该关注度是根据每个项目与最后一个项目的相关性计算得到的。该模型考虑了来自其他会话的有用的项目转换模式,但是,仅通过计算每个项目和最后一个项目之间的相对重要性来学习整个会话的表示,其性能在很大程度上依赖于最后一个项目与当前会话的用户偏好的相关性,

忽略了用户兴趣会随时发生较大的变化;并且位置信息的丢失对最后推荐结果的准确性造成了一定的影响。相比之下,本文提出的模型学习所有会话的项目转换信息,以增强当前会话的学习,同时考虑了位置信息,因此可以得到更为精确的推荐结果。

2.3 基于图神经网络的推荐算法

图神经网络指在图上构建神经网络模型并进行分析的方法,该类方法已经被广泛开发和探索了十多年,近年发展更为迅速。如今,神经网络已被用于生成图形结构数据的表示,如社交网络和知识库。word2vec^[21]也随之得到了拓展。Perozi等设计了一种无监督算法 DeepWalk^[22]来学习基于随机行走的图节点的表示。随后,Tang等提出无监督网络嵌入算法 LINE^[23]以及 node2vec^[24]。另一方面,经典的神经网络 CNN 和 RNN 也部署在图形结构的数据上。Duvinaud等^[25]介绍了一种卷积神经网络,它直接对任意大小和形状的图形进行操作。一种可扩展的方法^[26]通过谱图卷积的局部近似来选择卷积结构,这是一种有效的变体,也可以直接对图进行操作。

然而,这些方法只能在无向图上实现。无向图无法准确描述项目的流入和流出,因此图神经网络引入了有向图表示法。Wang等^[27]将基于自回归移动平均(Auto-Regression and Moving Average Model, ARMA)过滤器的图卷积层集成到图神经网络(Graph Neural Network, GNN)中,它可以通过建模为图结构数据的一系列会话来捕获项目之间的复杂转换,每个会话都使用关注网络来表示当前兴趣的组

成和该会话的全局偏好。

Liu等^[28]提出了一种基于递归神经网络的新模型 Mixing-RNN,其能够捕获时间和上下文变化进行项目推荐。Huang等^[29]提出了一种名为 TNAM 的新颖模型,该模型可以准确地捕获用户对商品标签的特别关注。Song等^[30]提出了基于动态图注意力神经网络的推荐系统。Wu等^[31]提出了双图注意力网络来协作学习双重社会效应的表示。Mu等^[32]提出了一种新颖的模型:用于神经社交推荐的图注意力网络。Tao等^[33]提出了一个新的多模态图注意力网络,它可以消除个人利益对模态粒度的关注。Yuan等^[34]开发了一种时空双图注意力网络,该网络可以联合建模动态情境和用户的顺序行为,以进行智能查询-POI(Point Of Interest)匹配;此外,该团队还提出了一种新颖的双图注意力网络,以捕获两种类型的查询-POI相关性。

本文中基于 GNN 的训练部分,是基于有向图的训练,将每个项目上的出度与入度用邻接矩阵表示,能够更好地表达用户的点击顺序,通过 GNN 来获得物品间的转移关系;在此基础上,还将会话序列输入 LSTM 层,捕获整体会话间的关系,从整体和局部分析用户的兴趣偏好,从而可以得到更为准确的预测。

3 基于全局增强的图神经网络模型

本节将图神经网络应用于基于会话的推荐方法中,提出一种基于全局增强的图神经网络的推荐模型(GEL-GNN),如图 1 所示。

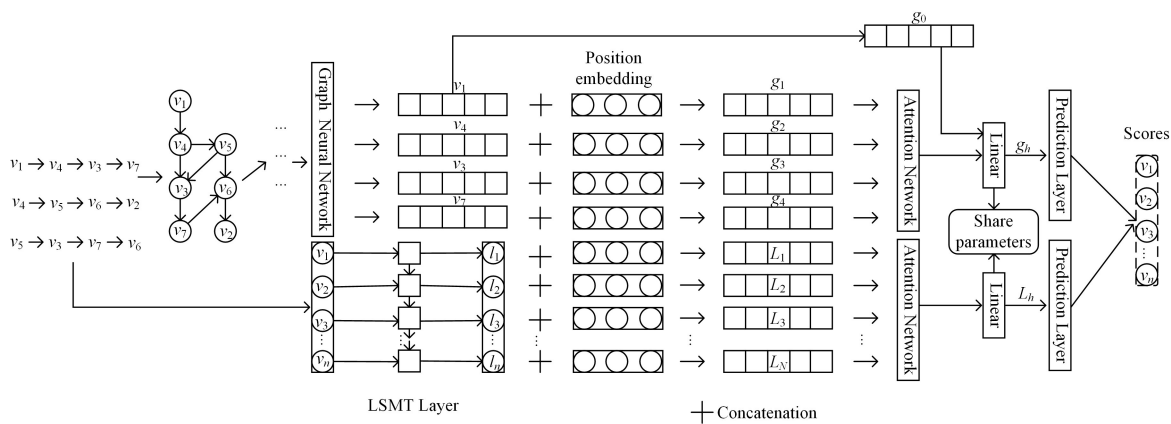


图 1 GEL-GNN 模型 workflow

Fig. 1 Workflow of the proposed GEL-GNN

该模型主要由 5 部分构成。

(1)图神经网络模块:为会话构造有向图,且能够自动提取会话图中的特征,可推断出当前会话中用户的长短期偏好。

(2)LSTM 模块:长短期记忆人工神经网络,是 RNN 的一种特殊类型,主要是为了解决长序列训练过程中的梯度消失和梯度爆炸问题。简单来说,就是相比普通的 RNN,LSTM 能够在更长的序列中有更好的表现,可以学习长期依赖信息,从而能够推断出用户基于全局的长期偏好。

(3)位置向量模块:通过位置向量模块,利用反向位置信息,可以捕获当前位置距离预测位置的远近,位置越近代表

权重越大,与用户当前兴趣可能更相近。

(4)注意力机制模块:本文采用软注意力机制(Soft Attention)。软注意力机制是指在选择信息的时候,不是从 N 个信息中只选择 1 个,而是计算 N 个输入信息的加权平均,采取“软性”选择机制,只是最相关的信息抽取得多一些。然后将加权平均值输入神经网络中进行计算。通过该模块的计算,可以得出每次点击的项目的得分,得分越高的项目,用户下一个点击的可能性越大。

(5)预测模块:将图神经网络模块与 LSTM 模块通过注意力机制层得到的得分进行融合后传入 softmax 函数,得到最终结果。

3.1 问题描述

基于会话的推荐一般仅基于用户当前会话中的交互数据来预测用户下一次进行交互的项目,无需访问长期偏好。下面给出本文的符号定义。

设 $V = \{v_1, v_2, \dots, v_m\}$ 表示由 m 个项目组成的项目集合,其中的项目是所有会话中涉及的所有唯一项目组成的集合;令匿名会话 $S = \{v_{s,1}, v_{s,2}, \dots, v_{s,n}\}$,其中 $v_{s,i} \in V$ 表示会话中用户的点击项,基于会话的推荐的目标是预测下一次的点击,即对于会话 S 来说, $v_{s,n+1}$ 是预测的下一次点击。GEL-GNN 模型的目标是根据用户当前会话 $S = \{v_{s,1}, v_{s,2}, \dots, v_{s,n}\}$ 中交互的信息,融合 LSTM 中会话之间存在的交互信息,预测用户下一次交互的项目 $v_{s,n+1}$,因此,对每个输入的会话, GEL-GNN 模型都会输出所有可能项目的概率 $\hat{\mathbf{y}}$ 。其中,向量 $\hat{\mathbf{y}}$ 的元素值是相应项的推荐分数, $\hat{\mathbf{y}}$ 中分数最高的项目将是推荐的候选项目。由于推荐人通常会为用户提出多个建议,因此一般从 $\hat{\mathbf{y}}$ 中选择前 n 个项目供推荐。

3.2 工作流程

GEL-GNN 从全局的角度捕获所有会话间的关系,同时捕获当前会话的整体和局部之间的关系,并使用反向位置信息,实现更为准确的推荐。GEL-GNN 分别从会话图和会话序列中学习项目嵌入,图 1 给出了 GEL-GNN 模型的工作流程。

(1) 基于会话图捕获当前会话内部用户的兴趣,即通过在当前会话中建模成对的项目转换来学习会话级项目嵌入,每次用户的点击序列构成一次会话,将其送入 GNN 进行训练,捕获当前会话内部用户的兴趣;

(2) 学习全局级项目嵌入向量,即将所有会话序列传入 LSTM^[35] 层学习全局级项目嵌入向量;

(3) 将 GNN 层的输出和 LSTM 层的输出分别与位置嵌入向量(Position Embedding)进行拼接,将结果送入注意力机制层;

(4) 采用了一种会话感知的注意力机制来递归地合并全局图上每个节点的邻接嵌入,通过注意力机制计算出每一次用户点击的项目的权重值;

(5) 将图神经网络模块的得分与 LSTM 模块的得分融合后送入预测层,经过 softmax 函数之后,得到每个项目的最终得分,得分越高,用户点击的可能性越大。

3.3 图神经网络模块

GNN 的第一部分是从所有的会话中构造一个有意义的图。每个会话序列 s 被建模为一个有向图 $G_s = (\gamma, \epsilon_s)$ 。在会话图中,每个节点代表一个项目 $v_{s,i} \in V$ 。每条边 $(v_{s,i-1}, v_{s,i}) \in \epsilon_s$ 代表在会话 s 中,用户在点击完 $v_{s,i-1}$ 之后点击了 $v_{s,i}$ 。由于许多项目可能会在序列中重复出现,因此为每个边分配了一个归一化的权重,该权重的计算方法是边的出现次数除以该边的起始节点的外倾角。将每个项目 $v \in V$ 嵌入到一个统一的嵌入空间中,节点向量 $\mathbf{v} \in \mathbb{R}^d$ 表示通过图神经网络学习的项目 v 的潜在向量,其中 d 是维数。基于节点向量,每个会话 s 可以由嵌入向量 \mathbf{S} 表示,嵌入向量 \mathbf{S} 由该图中使用的节点向量组成。

图神经网络可以在考虑丰富节点连接的情况下自动提取

会话图中的特征,因此它十分适合基于会话的推荐。会话图中,节点向量的计算公式为:

$$\mathbf{a}'_{s,i} = \mathbf{A}_{s,i} [\mathbf{v}_1^{-1}, \dots, \mathbf{v}_n^{-1}]^T \mathbf{H} + \mathbf{b} \quad (1)$$

$$\mathbf{z}'_{s,i} = \sigma(\mathbf{W}_z \mathbf{a}'_{s,i} + \mathbf{U}_z \mathbf{v}_i^{-1}) \quad (2)$$

$$\mathbf{r}'_{s,i} = \sigma(\mathbf{W}_r \mathbf{a}'_{s,i} + \mathbf{U}_r \mathbf{v}_i^{-1}) \quad (3)$$

$$\tilde{\mathbf{v}}'_i = \tanh(\mathbf{W}_o \mathbf{a}'_{s,i} + \mathbf{U}_o (\mathbf{r}'_{s,i} \odot \mathbf{v}_i^{-1})) \quad (4)$$

$$\mathbf{v}'_i = (1 - \mathbf{z}'_{s,i}) \odot \mathbf{v}_i^{-1} + \mathbf{z}'_{s,i} \odot \tilde{\mathbf{v}}'_i \quad (5)$$

其中, $\mathbf{H} \in \mathbb{R}^{d \times 2d}$ 控制权重, \mathbf{b} 为模型的全局偏置, $\mathbf{z}_{s,i}$ 和 $\mathbf{r}_{s,i}$ 分别是重置门和更新门, $[\mathbf{v}_1^{-1}, \dots, \mathbf{v}_n^{-1}]$ 是会话 s 的节点向量列表, $\sigma(\cdot)$ 是 sigmoid 方法, \odot 是逐元素乘法运算符, $\mathbf{v}_i \in \mathbb{R}^d$ 代表节点 $v_{s,i}$ 的潜在向量,连接矩阵 $\mathbf{A}_s \in \mathbb{R}^{n \times 2n}$ 决定了在会话图中节点之间交互的方式, $\mathbf{A}_{s,i} \in \mathbb{R}^{1 \times 2n}$ 是 \mathbf{A}_s 中对应于节点 $v_{s,i}$ 的两列块。

3.4 LSTM 层模块

LSTM(Long Short-Term Memory)的工作原理类似于 GRU,但两者又有所区别:LSTM 有 3 个输入 x_t, h_{t-1}, c_{t-1} 和两个输出 h_t, c_t ;而 GRU 有两个输入 x_t, h_{t-1} 和一个输出 h_t ,输出即状态。GRU 参数更少,训练速度更快,相比之下需要的数据量更少,如果有足够的训练数据,LSTM 的效果可能优于 GRU。LSTM 层中节点向量的计算公式为:

$$\mathbf{i}'_{s,i} = \sigma(\mathbf{W}_i \mathbf{a}'_{s,i} + \mathbf{U}_i \mathbf{v}_i^{-1}) \quad (6)$$

$$\mathbf{f}'_{s,i} = \sigma(\mathbf{W}_f \mathbf{a}'_{s,i} + \mathbf{U}_f \mathbf{v}_i^{-1}) \quad (7)$$

$$\mathbf{o}'_{s,i} = \sigma(\mathbf{W}_o \mathbf{a}'_{s,i} + \mathbf{U}_o \mathbf{v}_i^{-1}) \quad (8)$$

$$\tilde{\mathbf{c}}'_{s,i} = \tanh(\mathbf{W}_c \mathbf{a}'_{s,i} + \mathbf{U}_c \mathbf{v}_i^{-1}) \quad (9)$$

$$\mathbf{c}'_{s,i} = \mathbf{f}'_{s,i} \odot \mathbf{c}'_{s,i-1} + \mathbf{i}'_{s,i} \odot \tilde{\mathbf{c}}'_{s,i} \quad (10)$$

$$\mathbf{v}'_i = \mathbf{o}'_{s,i} \odot \tanh(\mathbf{c}'_{s,i}) \quad (11)$$

其中, $\mathbf{i}_{s,i}$ 和 $\mathbf{f}_{s,i}$ 分别是输入门和遗忘门,其作用是对状态进行更新; $\mathbf{o}_{s,i}$ 是输出门; $\tilde{\mathbf{c}}_{s,i}$ 用来存储中间状态; $\mathbf{c}_{s,i}$ 是最终输出状态。

LSTM 内部主要有 3 个阶段。

(1) 忘记阶段。这个阶段主要是对上一个节点传进来的输入进行选择性的忘记。简单来说,就是“忘记不重要的,记住重要的”。具体来说,就是将通过计算得到的 $\mathbf{f}_{s,i}$ 作为忘记门控,来控制上一个状态的 $\mathbf{c}'_{s,i-1}$ 哪些需要保留,哪些需要遗忘。

(2) 选择记忆阶段。这个阶段将此阶段的输入有选择性地“记忆”,主要是对输入 $\mathbf{a}'_{s,i}$ 进行选择记忆。重要的着重记录,不重要的则少记。当前的输入内容由前面计算得到的 $\tilde{\mathbf{c}}'_{s,i}$ 表示。而选择的门控信号则是由 $\mathbf{o}'_{s,i}$ 来进行控制。将上面两步得到的结果相加,即可得到传输给下一个阶段的 $\mathbf{c}'_{s,i}$ 。

(3) 输出阶段。这个阶段决定哪些将会被当成当前状态的输出,主要通过 $\mathbf{o}'_{s,i}$ 来进行控制,并且还对上一阶段得到的 $\mathbf{c}'_{s,i}$ 通过一个 tanh 激活函数进行缩放。

3.5 位置向量模块

在计算会话表示时,考虑了位置信息的重要性。由于会话中最近的一次点击行为和用户当前兴趣的相关性更大,越靠近末尾的物品应该越重要,因此加入了反向位置信息。由于会话的长度是不固定的,前向位置信息无法衡量当前物品和预测物品之间的距离,但反向位置信息可以,因此 GEL-GNN 模型采用的是反向位置信息。位置信息的嵌入向量

定义为: $\mathbf{P}=[\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_l]$, 其中, $\mathbf{p}_i \in \mathbb{R}^d$ 是具体位置 i 的位置向量, l 是当前会话的长度。位置信息通过连接和非线性变换进行整合:

$$\mathbf{g}_i = \sum_{j=1}^n \alpha_j \mathbf{v}_j \quad (12)$$

$$\mathbf{L}_i = \sum_{j=1}^n \alpha_j \mathbf{L}_j \quad (13)$$

$$\mathbf{g}_h = \mathbf{W}_3([\mathbf{g}_0, \mathbf{g}_i] \parallel \mathbf{p}_{i-i+1}) + \mathbf{b}_2 \quad (14)$$

$$\mathbf{L}_h = \mathbf{W}_3([\mathbf{L}_i \parallel \mathbf{p}_{i-i+1}]) + \mathbf{b}_2 \quad (15)$$

其中, \mathbf{g}_i 和 \mathbf{L}_i 分别是 GNN 层和 LSTM 层的输出; \mathbf{g}_h 和 \mathbf{L}_h 分别是结合了位置向量后经过 Attention 层传入 Linear 层的输入; $\mathbf{g}_0 = \mathbf{v}_{s,n}$, 代表用户当前会话最后一次点击的项目; \mathbf{b}_2 为当前层的偏置项。

3.6 注意力机制层模块

考虑到嵌入中的信息优先级可能不同, 本文进一步采用软注意机制来更好地表示会话偏好。

$$\alpha_i = \mathbf{q}^T \sigma(\mathbf{W}_1 \mathbf{v}_n + \mathbf{W}_2 \mathbf{v}_i + c) \quad (16)$$

其中, 参数 $\mathbf{q} \in \mathbb{R}^d$, \mathbf{W}_1 和 $\mathbf{W}_2 \in \mathbb{R}^{d \times d}$ 控制嵌入向量的权重, c 是注意力机制的偏置项。

3.7 预测模块

在获得每个会话的嵌入之后, GNN 层通过乘以它的嵌入 \mathbf{v}_i 和会话表示 \mathbf{g}_h 来计算每个候选项 $v_i \in V$ 的分数, 定义为:

$$\hat{\mathbf{z}}_{g,i} = \mathbf{g}_h^T \mathbf{v}^i \quad (17)$$

LSTM 层通过乘以它的嵌入 \mathbf{L}_i 和会话表示 \mathbf{L}_h 来计算每个候选项 $v_i \in V$ 的分数, 定义为:

$$\hat{\mathbf{z}}_{l,i} = \mathbf{L}_h^T \mathbf{L}^i \quad (18)$$

接着, 将 GNN 层的得分和 LSTM 层的得分融合, 传入 softmax 函数, 得出预测结果:

$$\hat{\mathbf{y}} = \text{softmax}(\hat{\mathbf{z}}) \quad (19)$$

其中, $\hat{\mathbf{z}} \in \mathbb{R}^d$ 是融合得分后所有项目的推荐分数, $\hat{\mathbf{y}} \in \mathbb{R}^d$ 表示在会话 s 中节点出现下一次点击的概率。

本文的损失函数定义为基于预测和事实的交叉熵函数:

$$L(\hat{\mathbf{y}}) = -\sum_{i=1}^n \mathbf{y}_i \log(\hat{\mathbf{y}}_i) + (1 - \mathbf{y}_i) \log(1 - \hat{\mathbf{y}}_i) \quad (20)$$

经过大量实验证明后, 本文选择相对较少的训练步骤, 以防止过拟合。

4 实验结果与分析

本节首先描述了实验中使用的数据集、比较方法和评估指标, 然后将提出的 GEL-GNN 与其他方法进行了比较, 最后对不同实验环境下的 GEL-GNN 进行了详细的分析。

4.1 实验数据集

本文使用了 3 个基准数据集, 即 Diginetica^[4], Tmall^[5] 和 Nowplaying^[6]。特别地, Diginetica 集来自 2016 年的 CIKM 杯, 由典型的交易数据组成。Tmall 数据集来自 IJCAI-15 竞赛, 其中包含天猫在线购物平台上的匿名用户购物日志。Nowplaying 的数据集来自文献[26], 它描述了用户的音乐侦听行为。

接下来对这 3 个数据集进行预处理, 过滤掉所有长度为 1 的会话和在两个数据集中出现次数小于 5 的项目。通过分割输入序列来生成序列和相应的标签。例如, 对于会话 $S =$

$\{v_{s,1}, v_{s,2}, \dots, v_{s,n}\}$, 通过序列分割预处理生成序列和相应的标签, 即 $([v_{s,1}], v_{s,2}), ([v_{s,1}, v_{s,2}], v_{s,3}), \dots, ([v_{s,1}, v_{s,2}, \dots, v_{s,n-1}], v_{s,n-1})$, 用于数据集的训练和测试。训练集和测试集中的正样本表示用户最终点击的项目与模型预测结果一致; 负样本表示用户最终点击的项目与模型预测结果不一致。预处理后, 数据集统计信息如表 1 所列。其中, #click 表示不同数据集中所有点击的次数; #train 表示训练集中的记录条数; #test 表示测试集中的记录条数; #items 表示不同数据集中的物品总数; avg. len 表示不同数据集中会话序列的平均长度。

表 1 数据集统计数据

Table 1 Statistics of datasets used in experiment

Datset	Diginetica	Tmall	Nowplaying
#click	982962	818479	1367963
#train	719470	351268	825304
#test	60858	25898	89824
#items	43097	40728	60417
avg. len.	5.12	6.69	7.42

4.2 对比模型

将本文方法与经典方法以及最先进的模型进行了比较。9 个基线模型如下。

POP: 从训练集中推荐了 top-N 个经常出现的训练项目。

Item-KNN: 根据当前会话项目和其他项目之间的相似性进行项目推荐。

FPMC: 结合了矩阵分解和一阶马尔可夫链来捕捉顺序效果和用户偏好, 是推荐的经典混合模型。

GRU4Rec: 基于 RNN 的模型, 使用 GRU 来模拟用户序列, 利用会话并行的小批量训练过程来模拟用户动作序列。

NARM: 在 GRU4Rec 的基础上进行了改进, 在 RNN 中加入了注意力机制。

STAMP: 一种新颖的短期记忆优先模型, 采用注意力层来取代以前工作中的所有 RNN 编码器, 用于捕捉用户对先前点击的长期偏好以及会话中最后一次点击的当前兴趣, 完全依靠当前会话中最后一项的自我注意力来捕捉用户的短期兴趣。

CSRMR: 利用记忆网络来研究最新的 m 个会话, 以便更好地预测当前会话的意图。

FGNN: 最近提出的推荐模型, 通过加权注意力机制图层来学习项目嵌入, 并且通过抽取图形特征来学习会话的下一项推荐项目。

SR-GNN: 最近提出的基于会话的图神经网络推荐模型, 使用门控 GNN 层生成项目的潜在向量, 以此来获得项目嵌入, 然后类似于 STAMP^[8], 通过自注意机制层捕捉会话中最后一次点击的当前兴趣, 以计算基于会话的推荐的会话级嵌入, 最后通过传统的注意力网络表示每个会话。

4.3 实验结果度量标准

本文采用如下 3 个指标对实验结果进行度量。

P@10 (Precision): 被广泛用作预测精度的衡量标准。P@10 表示前 10 项中正确推荐项目所占的比例。

P@20: P@20 表示前 20 项中正确推荐项目所占的比例。

MRR: 平均排序倒数 (Mean Reciprocal Rank)。考虑推荐

排名的顺序,其中较大的 MRR 值表示正确的推荐在排名列表的顶部。 $MRR@N$ 的计算公式为:

$$MRR@N = \frac{1}{N} \sum_{i \in M} \frac{1}{rank_i} \quad (21)$$

其中, N 表示推荐总数; M 表示前 N 个推荐物品中正确推荐物品的集合; $rank_i$ 表示物品 i 在 N 个推荐列表中的排名。

4.4 实验参数设定

为使实验结果公平公正,所有基线模型的参数设置均一致。3 个数据集潜在向量的维数 $d=100$ 。此外,在验证集上选择其他超参数,该验证集是训练集中随机的 10% 的子集。所有参数都使用均值为 0、标准差为 0.1 的高斯分布进行初始化。Adam 算法优化模型参数被用于优化这些参数,其中初始学习率 l 被设置为 0.001,并且每 3 个时期后将衰减 0.1。此外,训练每一批次数据输入的大小和 L2 惩罚分别设置为

100 和 10^{-5} ,迭代次数为 30。

4.5 实验结果分析

4.5.1 与基线模型比较

GEL-GNN 和 9 个基线模型在 3 个真实数据集上的实验结果如表 2 所列。每一列的最佳结果以粗体突出显示。其中,GL-GNN 即下文中的 GEL-GNN-Without-P,它与 GEL-GNN 的唯一区别是没有加入位置向量,但它的性能与 9 个基线模型相比均有一定的提升;而在 GL-GNN 的基础上加入位置向量之后,GEL-GNN 的性能相较 GL-GNN 会有一些的提升。与基线模型相比,GEL-GNN 在 Diginetica 上的表现比 SR-GNN 平均高出 2.18%,在 Tmall 上平均高出 5.08%,在 Nowplaying 上平均高出 2.58%。可以观察到,GEL-GNN 在所有 3 个数据集上以两个指标 ($N=10$ 和 $N=20$) 一致地实现了最佳性能,从而验证了本文所提方法的有效性。

表 2 GEL-GNN 与基线模型在 3 个数据集上的性能对比

Table 2 Performance comparison between GEL-GNN and basic model on three datasets

Dataset Methods	Diginetica				Tmall				Nowplaying			
	P@10	P@20	MRR@10	MRR@20	P@10	P@20	MRR@10	MRR@20	P@10	P@20	MRR@10	MRR@20
POP	0.76	1.18	0.26	0.28	1.67	2.00	0.88	0.90	1.86	2.28	0.83	0.86
Item-KNN	25.07	35.75	10.77	11.57	6.65	9.15	3.11	3.31	10.96	15.94	4.66	4.91
FPMC	15.43	22.14	6.20	6.66	13.10	16.06	7.12	7.32	5.28	7.36	2.68	2.82
GRU4Rec	17.93	30.79	7.73	8.22	9.47	10.93	5.78	5.89	6.74	7.92	4.40	4.48
NARM	35.44	48.32	15.13	16.00	19.17	23.30	10.42	10.70	13.6	18.59	6.62	6.93
STAMP	33.98	46.62	14.26	15.13	22.63	26.47	13.12	13.36	13.22	17.66	6.57	6.88
CSRM	36.59	50.55	15.41	16.38	24.54	29.46	13.62	13.96	13.20	18.14	6.08	6.42
FGNN	37.72	50.58	15.95	16.84	20.67	25.24	10.07	10.39	13.89	18.78	6.8	7.15
SR-GNN	38.42	51.26	16.89	17.78	23.41	27.57	13.45	13.72	14.17	18.87	7.15	7.47
GL-GNN	38.99	51.88	17.26	18.05	24.60	29.27	13.90	14.23	14.30	19.02	7.41	7.71
Improve/%	1.5	1.2	2.2	1.5	5.1	6.2	3.3	3.7	0.9	0.8	3.6	3.2
GEL-GNN	39.03	52.13	17.23	18.12	24.89	29.36	13.94	14.25	14.44	19.07	7.42	7.74
Improve/%	1.6	1.7	2.0	3.4	6.3	6.5	3.6	3.9	1.9	1.1	3.8	3.6

在传统方法中,POP 的表现最差,它只推荐出现最频繁的 N 个项目;与 POP 相比,FPMC 利用一阶马尔可夫链和矩阵分解,在 3 个数据集上均显示了其有效性;Item-KNN 在 Diginetica 和 Nowplaying 数据集上取得了传统方法中的最佳结果,但是需要注意的是,它只应用项目之间的相似性,而不考虑会话中项目的时间顺序,因此无法捕获项目之间的顺序转换。

基于神经网络的方法,如 NARM 和 STAMP,优于传统方法,证明了在这一领域采用深度学习的潜力。短期/长期记忆模型,如 GRU4REC 和 NARM,使用循环单位来捕捉用户的总体兴趣,而 STAMP 通过利用最后点击的项目来改善短期记忆。NARM 和 STAMP 明显优于 GRU4REC。NARM 将 RNN 和注意力机制相结合,使用 RNN 最后的隐藏状态作为用户的主要偏好,结果表明,直接使用 RNN 对会话序列进行编码对于基于会话的推荐可能是不够的,因为 RNN 只模拟了会话中相邻项目之间的单向项目转换。完全基于注意力的方法 STAMP 在 Tmall 上取得了比 NARM 更好的性能,它在会话的最后一个项目上引入了自注意力机制来模拟短期兴趣,这一结果证明了在会话编码的不同项目上分配不同的注意力权重有效性。与 RNN 相比,尽管 STAMP 忽略了会话中项目的时间顺序,但是它加入了注意力机制,能够很好地捕获目标物品和用户兴趣的长/短期记忆的相关性。SR-GNN

进一步考虑了会话中项目之间的转换,从而将每个会话建模为图形,可以捕捉用户单击之间更复杂和隐含的联系。而 NARM 和 GRU4REC 明确地对每个用户建模,并通过分离的会话序列获得用户表示,忽略了项目之间可能的交互关系。

CSRM 在 Diginetica 和 Tmall 上的表现比 NARM 和 STAMP 好。它显示了使用来自其他会话的项目转换的有效性,并且还显示了 CSRM 所使用的具有有限时隙的存储器网络的缺点;此外,CSRM 将其他会话视为一个整体,而没有将相关的项目转换与在其他会话中编码的不相关的项目转换区分开来。所有的基线方法中,基于 GNN 的方法在 Diginetica 和 Nowplaying 数据集上表现更好。通过将每个会话序列建模为一个子图并应用 GNN 对项目进行编码,SR-GNN 和 FGNN 证明了在基于会话的推荐中应用 GNN 的有效性。这表明图形建模将比序列建模、RNN 或集合建模、注意力机制建模更适合于基于会话的推荐。

这些方法明确地模拟了用户的全局行为偏好,并考虑了用户之前的动作和下一次点击之间的转换,从而获得了优于这些传统方法的性能。然而,它们的性能仍然不如本文提出的方法。

GEL-GNN 不仅考虑了会话中的全局和局部偏好,还考虑了基于所有会话的全局偏好,从而对用户的偏好分析更为精准。此外,该模型还考虑了位置向量,在计算会话表示时

考虑到位置信息的重要性,加入了反向位置信息,越靠近末尾的物品应该越重要。由于会话的长度是不固定的,前向位置信息无法衡量当前物品和预测物品之间的距离,但反向位置信息可以,因此,GEL-GNN 模型对于建模会话行为更有效。

此外,GEL-GNN 采用软注意机制来生成一个会话表示,该会话表示可以自动选择最重要的项目转换,并忽略当前会话中有噪声和无效的用户行为。相反,STAMP 只使用最后一次单击的项目和以前的操作之间的转换,这可能是不够的。其他 RNN 模型,如 GRU4REC 和 NARM,在传播过程中也

不能选择有影响的信息,它们使用所有以前的项目来获得一个代表用户一般兴趣的向量。当用户的行为是无目的的,或者他的兴趣在当前会话中快速漂移时,传统的模型对于处理嘈杂的会话是无效的。

本文提出的方法 GEL-GNN 在所有 3 个数据集上都优于 SR-GNN,具体结果如图 2 所示。与标准 GNN 和模糊神经网络不同,本文提出的方法集成了来自全局上下文(即其他会话)和当前会话的信息,并且还集成了相对位置信息,从而获得更好的性能。




图 2 GEL-GNN 与对比模型的性能对比

Fig. 2 Performance comparison between GEL-GNN and comparison models

4.5.2 与不同连接方式的比较

本文对不同连接方式进行了大量的实验比较。GEL-GNN 方法在构建图中项目之间的连接关系方面是灵活的,为了评估每个会话图中项目之间的关系,将如下 5 种不同的连接方式与 GEL-GNN 模型以及基线模型 SR-GNN 进行了对比。

GEL-GNN-TRANS: 将会话序列传入 LSTM 层改为将会话序列传入 Transformer 层。

GEL-GNN-CONC: 将 GNN 层和 LSTM 层的结果传入各自

的 Attention 层之后,将各自的结果进行融合,传入 Linear 层。

GEL-GNN-DI-LINEAR: 将 GNN 层和 LSTM 层的结果传入各自的 Attention 层之后,分别传入各自的 Linear 层。

GEL-GNN-Multi-Head: 将 GNN 层的结果传入 Attention 层,将 LSTM 的结果传入 Multi-Head-Attention 层。

GEL-GNN-Without-P(GL-GNN): 与 GEL-GNN 唯一的差别是没有加入位置向量。

实验对比结果如图 3 所示。




图 3 不同连接方式的性能比较

Fig. 3 Performance comparison of different connection schemes

可以看出,与将 Attention 层的结果进行融合后传入 Linear 层的 GEL-GNN-CONC 模型以及将 Attention 层的结果分别传入不同 Linear 层的 GEL-GNN-DI-LINEAR 模型相比,GEL-GNN 模型性能更高;而 GEL-GNN-Multi-Head 将 LSTM 传入 Multi-Head 的性能也比直接传入 Attention 的性能降低了很多;加入位置向量的 GEL-GNN 模型与没有加入位置向量的 GEL-GNN-Without-P 相比,性能也有所提升。由此可见,本文提出的模型在整体性能表现上要优于其他方式。

4.5.3 位置向量的不同嵌入方式的比较

本文对位置向量的嵌入方式进行了大量的比较实验。GEL-GNN 模型是通过封装了一个 class 类来调用位置向量;

而下文提到的 3 种加入位置向量的方式是通过改变注意力机制,把原有的 soft-aware attention 改为 position-aware attention。将这 3 种方式和本文提出的 GEL-GNN 模型以及基线模型 SR-GNN 进行了对比,结果如表 3 所列。3 种位置向量的嵌入方式都是将注意力机制层改为 position-aware attention,不同之处为:

GEL-GNN-Att1:GNN 和 LSTM 共用位置向量和权重计算方式;

GEL-GNN-Att2:GNN 和 LSTM 不共用权重计算方式;

GEL-GNN-Att3:GNN 和 LSTM 使用不同的位置向量,且不共用权重计算方式。

表 3 位置向量不同嵌入方式的性能对比

Table 3 Performance comparison of embedding method with different position vectors

Dataset Methods	Diginetica				Tmall				Nowplaying			
	P@10	P@20	MRR@10	MRR@20	P@10	P@20	MRR@10	MRR@20	P@10	P@20	MRR@10	MRR@20
SR-GNN	38.42	51.26	16.89	17.78	23.41	27.57	13.45	13.72	14.17	18.87	7.15	7.47
GEL-Att1	38.37	51.36	16.73	17.62	23.83	28.12	13.32	13.62	14.70	20.16	6.88	7.23
GEL-Att2	38.26	51.44	16.70	17.61	23.95	28.47	13.46	13.73	14.74	20.11	6.83	7.18
GEL-Att3	37.98	51.26	16.64	17.55	24.06	28.80	13.23	13.50	14.61	19.93	6.83	7.19
GEL-GNN	39.03	52.13	17.23	18.12	24.89	29.36	13.94	14.25	14.44	19.07	7.42	7.74

通过表 3 可以看出,在 3 个数据集上,这 3 种方式的表现都不如本文提出的 GEL-GNN 模型,GEL-GNN 在 3 个数据集上发挥稳定,都超过了基线模型 SR-GNN,从而验证了本文提出模型的有效性。

结束语 出于隐私和数据保护的考虑,用户个人信息和历史交互记录往往是不公开的,因此在用户个人信息未知,只有当前正在进行的会话中的用户历史行为可用的情况下,基于会话的推荐是必不可少的。通过基于会话的推荐,可以推断出用户的长短期偏好,并且能够捕获项目间的复杂关系和转换。本文提出了一种基于全局增强的图神经网络的序列推荐模型 GEL-GNN。GEL-GNN 通过 GNN 层将当前会话序列转换成会话图,构建一个基于当前会话的全局图;将所有会话序列传入 LSTM 层构建一个基于所有会话的网络;然后组合基于当前会话的全局上下文信息和基于所有会话的全局上下文信息,以增强项目的特征呈现,实现方法是将 GNN 层的输出和 LSTM 层的输出分别与位置嵌入向量进行拼接,将结果送入注意力机制层。通过结合反向位置向量和会话信息,使该模型能够更好地学习每个项目的贡献,从而可以更好地预测用户的下一步动作。实验结果表明,GEL-GNN 在 3 个真实数据集上显著优于 9 个基线模型。

参考文献

- [1] SCHEDL M,ZAMANI H,CHEN C W, et al. Current challenges and visions in music recommender systems research[J]. International Journal of Multimedia Information Retrieval,2018,7(2): 95-116.
- [2] GE Y,ZHAO S,ZHOU H, et al. Understanding Echo Chambers in E-commerce Recommender Systems[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. China: ACM, 2020: 2261-2270.
- [3] BERNARDI L,KAMPS J,KISELEVA J, et al. The Continuous Cold Start Problem in e-Commerce Recommender Systems[J]. Computer Science,2015,92(2):28002-28007.
- [4] KUMAR P,THAKUR R S.Recommendation system techniques and related issues:a survey[J]. International Journal of Information Technology,2018,10(4):495-501.
- [5] LI Z,ZHAO H,LIU Q, et al. Learning from history and present: Next-item recommendation via discriminatively exploiting user behaviors[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London: ACM,2018:1734-1743.
- [6] 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. Hong Kong: ACM,2001:285-295.
- [7] SHANI G,HECKERMAN D,BRAFMAN R I, et al. An MDP-based recommender system[J]. Journal of Machine Learning Research,2005,6(9):1265-1295.
- [8] HIDASI B,KARATZOGLOU A,BALTRUNAS L, et al. Session-based Recommendations with Recurrent Neural Networks [J]. arXiv:1511.06939,2015.
- [9] TAN Y K,XU X,LIU Y. Improved recurrent neural networks for session-based recommendations[C]//Proceedings of the 1st workshop on deep learning for recommender systems. Boston: ACM,2016:17-22.
- [10] TUAN T X,PHUONG T M. 3D convolutional networks for session-based recommendation with content features [C] // Proceedings of the eleventh ACM conference on recommender systems. New York, NY, USA: ACM. 2017:138-146.
- [11] LI J,REN P,CHEN Z, et al. Neural attentive session-based recommendation[C]//Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. Singapore: ACM, 2017:1419-1428.

- [12] TSAI C H, BRUSILOVSKY P, RAHDARI B. Exploring User-Controlled Hybrid Recommendation in a Conference Context [C]//Joint Proceeding of the ACM IUI 2019 Workshops. Los Angeles:[s. n.],2019:1-6.
- [13] QIAN Y,ZHANG Y,MA X,et al. EARS:Emotion-aware recommender system based on hybrid information fusion[J]. Information Fusion,2019,46:141-146.
- [14] MNIH A,SALAKHUTDINOV R R. Probabilistic matrix factorization[J]. Advances in Neural Information Processing Systems,2007,20:1257-1264.
- [15] KOREN Y,BELL R. Advances in collaborative filtering[Z]. Recommender Systems Handbook,2015:77-118.
- [16] SHANI G,HECKERMAN D,BRAFMAN R I,et al. An MDP-based recommender system[J]. Journal of Machine Learning Research,2005,6(1):1265-1295.
- [17] RENDLE S,FREUDENTHALER C,SCHMIDT-THIEME L. Factorizing personalized markov chains for next-basket recommendation[C]// Proceedings of the 19th International Conference on World Wide Web. 2010:811-820.
- [18] SUTSKEVER I,VINYALS O,LEQ V. Sequence to sequence learning with neural networks[C]// Advances in Neural Information Processing Systems. 2014:3104-3112.
- [19] LIU Q,ZENG Y,MOKHOSI R,et al. STAMP: short-term attention/memory priority model for session-based recommendation[C]// Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London: ACM,2018:1831-1839.
- [20] WU S,TANG Y,ZHU Y,et al. Session-based recommendation with graph neural networks[C]// Proceedings of the AAAI Conference on Artificial Intelligence. USA: AAAI, 2019: 346-353.
- [21] MIKOLOV T,SUTSKEVER I,CHEN K,et al. Distributed representations of words and phrases and their compositionality [C]//Advances in Neural Information Processing Systems. USA:MIT Press,2013:3111-3119.
- [22] 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. New York:ACM,2014:701-710.
- [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. Italy:ACM,2015:1067-1077.
- [24] 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. United States:ACM,2016:855-864.
- [25] DUVENAUD D,MACLAURIN D,AGUILERA-IPARRAGUIRRE J,et al. Convolutional networks on graphs for learning molecular fingerprints[J]. arXiv:1509.09292,2015.
- [26] KIPF T N,WELLING M. Semi-supervised classification with graph convolutional networks[J]. arXiv:1609.02907,2016.
- [27] WANG H,XIAO G,HAN N,et al. Session-Based Graph Convolutional ARMA Filter Recommendation Model[J]. IEEE Access,2020,8:62053-62064.
- [28] LIU E,CHU Y,LUAN L,et al. Mixing-RNN:a recommendation algorithm based on recurrent neural network[C]// International Conference on Knowledge Science, Engineering and Management. Athens:Springer,2019:109-117.
- [29] HUANG R,WANG N,HAN C,et al. TNAM:A tag-aware neural attention model for Top-N recommendation[J]. Neurocomputing,2020,385:1-12.
- [30] SONG W,XIAO Z,WANG Y,et al. Session-based social recommendation via dynamic graph attention networks[C]// Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining. Australia:ACM,2019:555-563.
- [31] WU Q,ZHANG H,GAO X,et al. Dual graph attention networks for deep latent representation of multifaceted social effects in recommender systems[C]// The World Wide Web Conference. USA:ACM,2019:2091-2102.
- [32] MU N,ZHA D,HE Y,et al. Graph Attention Networks for Neural Social Recommendation[C]// 2019 IEEE 31st International Conference on Tools with Artificial Intelligence(ICTAI). Portland:IEEE,2019:1320-1327.
- [33] TAO Z,WEI Y,WANG X,et al. MGAT:Multimodal Graph Attention Network for Recommendation[J]. Information Processing & Management,2020,57(5):102277.
- [34] YUAN Z,LIU H,LIU Y,et al. Spatio-Temporal Dual Graph Attention Network for Query-POI Matching[C]// Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. China:ACM,2020:629-638.
- [35] GREFF K,SRIVASTAVA R K,KOUTNÍK J,et al. LSTM:A search space odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems,2016,28(10):2222-2232.



ZHOU Fang-quan, born in 1997, post-graduate. Her main research interests include personalized recommendation and so on.



CHENG Wei-qing, born in 1972, Ph.D., professor, is a member of China Computer Federation. Her main research interests include network measurement, distributed algorithms, data mining and so on.