

结合动态多阶门控 GNN 和超图卷积的自监督会话推荐^①



沈学利, 赵国阳

(辽宁工程技术大学 软件学院, 葫芦岛 125105)
通信作者: 赵国阳, E-mail: 1205978100@qq.com

摘要: 针对现有基于图神经网络的会话推荐方法中缺乏对高阶特征的提取和利用以及数据稀疏性的问题, 提出一种结合动态多阶门控图神经网络 (GGNN) 和超图卷积的自监督会话推荐模型 (SDMHC-GNN). 首先, 利用不同的图结构将会话序列建模为 3 个不同的视图: 会话视图、超图视图和关系视图, 会话视图使用动态多阶门控图神经网络、稀疏自注意力和稀疏全局注意力机制生成局部顺序会话表示, 超图视图使用超图卷积和软注意力机制生成高阶会话表示, 关系视图使用图卷积和稀疏交叉注意力机制生成会话关系表示; 其次, 通过自监督学习对不同的会话表示之间的互特征最大化; 最后, 通过意向邻居协作模块对当前会话表示进行过滤和增强. 在 Diginetica 和 Tmall 两个公开数据集上进行多次实验, 并与先进基线模型比较, 实验结果表明所提出模型的性能优于基线模型, 证明了该模型的有效性.

关键词: 会话推荐; 动态多阶门控图神经网络; 超图卷积; 稀疏交叉注意力机制; 自监督学习

引用格式: 沈学利, 赵国阳. 结合动态多阶门控 GNN 和超图卷积的自监督会话推荐. 计算机系统应用, 2025, 34(4): 90-103. <http://www.c-s-a.org.cn/1003-3254/9804.html>

Self-supervised Session Recommendation Incorporating Dynamic Multi-level Gated GNN and Hypergraph Convolution

SHEN Xue-Li, ZHAO Guo-Yang

(Software College, Liaoning Technical University, Huludao 125105, China)

Abstract: Considering the lack of extraction and utilization of higher-order features and data sparsity in current graph neural network-based session recommendation methods, a self-supervised session recommendation incorporating dynamic multi-level gated graph neural network (GGNN) and hypergraph convolution (SDMHC-GNN) is proposed. Firstly, different graph structures are used to model the session sequence into three different views: session view, hypergraph view, and relational view. The session view uses dynamic multi-level gated graph neural networks, sparse self-attention, and sparse global attention mechanisms to generate local sequential session representations. The hypergraph view uses hypergraph convolution and soft attention mechanisms to generate higher-order session representations. The relational view uses graph convolution and sparse cross-attention mechanisms to generate session relational representations. Secondly, the mutual features among different session representations are maximized by self-supervised learning. Finally, the current session representation is filtered and enhanced by the intentional neighbor collaboration module. Multiple experiments are conducted on two public data sets, Diginetica and Tmall, and compared with advanced baseline models. The experimental results indicate that the performance of the proposed model is superior to that of the baseline model, proving the effectiveness of the model.

① 基金项目: 国家自然科学基金面上项目 (62173171)

收稿时间: 2024-09-16; 修改时间: 2024-10-10; 采用时间: 2024-10-23; csa 在线出版时间: 2025-02-26

CNKI 网络首发时间: 2025-02-27

Key words: session recommendation; dynamic multi-level gated graph neural network; hypergraph convolution; sparse cross-attention mechanism; self-supervised learning

随着互联网上的信息爆炸式的增长,许多在线互联网平台面临着信息过载的问题,推荐系统(recommendation system, RS)^[1]的存在恰好可以有效地缓解这一问题,它可以从海量的信息中有效地识别出来用户感兴趣的文本、图片、视频和语音等^[2]。目前的推荐系统大多是依据用户过去的历史行为进行交互,然而在实际情况中,许多用户在没有登录的情况下观看视频或购物,使得他们的历史交互足迹对于传统的推荐系统并不适用^[3,4]。因此,基于会话的推荐(session-based recommendation, SBR)应运而生。与依赖于用户历史数据的传统推荐方法不同^[5],SBR模型利用匿名用户会话期间生成的项目短序列来推荐下一个用户可能感兴趣的项目,在天猫、淘宝、京东、抖音、微博、小红书等在线购物平台和网络社交软件中都有着广泛的应用。

目前,基于图神经网络的模型相比于其他方法普遍具有更好的性能^[6]。但这些方法也有许多不足之处,如:

(1) 对高阶表示的学习不足。基于GNN的方法一味地增加GNN深度虽然可以增强对高阶表示的学习,但深度GNN遭受过平滑^[7]和梯度消失的问题,这使得所有节点收敛到相同的值。

(2) 对跨会话的信息利用和交互不足。基于GNN的方法从单一的会话来提取用户偏好,而忽略了从多个维度对会话序列进行长期依赖建模来捕获不同会话级间项目的复杂高阶长期依赖关系,无法对用户的兴趣偏好进行全面、充分和长期地挖掘。

(3) 缺乏对数据稀疏性的处理。由于会话序列通常是短序列,可以利用的交互信息非常有限,基于GNN的方法不能充分挖掘其中的信息,其往往受到数据稀疏性的影响。

针对上述不足和问题,本文提出了结合动态多阶门控图神经网络和超图卷积的自监督会话推荐模型(SDMHC-GNN)。此模型从会话图、超图和关系图3个不同的维度对会话序列进行建模,从多个维度来捕获不同会话级间项目的复杂高阶长期依赖关系。其次,通过自监督学习对不同视图学习到的会话表示之间的互信息最大化,缓解数据稀疏性对推荐性能的影响,从而

提高模型的推荐准确性,本文主要贡献如下。

(1) 采用动态多阶门控图神经网络^[8]对会话图进行处理,在避免过平滑和梯度消失问题的前提下,可以有效地提取会话项目的高阶特征。

(2) 增加超图视图,并采用超图卷积提取超图中复杂的项目转换关系,并通过软注意力机制给不同的节点分配相应的权重,从而有针对性的捕获和利用会话中非相邻项目的高阶特征。

(3) 在关系视图中,采用稀疏交叉注意力机制加强会话关系表示与其他级别表示的潜在联系,有效地将跨会话的信息融入了会话关系表示中。目标表示并对会话关系表示做了降噪处理,消除噪声项对推荐准确性和有效性的影响。

(4) 采用自监督学习,使超图编码器学习到的高阶表示与另两个编码器学习到的会话表示相互获取新信息,使自监督信号的信息量增多,从而缓解数据稀疏性对推荐结果的影响。

(5) 在两个公开数据集上的实验结果表明,SDMHC-GNN的推荐性能相比于基线模型具有一定的优越性。

1 相关工作

1.1 基于传统方法的会话推荐

在SBR系统的早期,推荐主要是基于流行或共同出现的项目。然而,随着人们认识到会话数据中串行性的重要,研究者引入马尔可夫链来解决SBR中的串行性建模问题。Shani等人^[9]是最早提出在SBR中使用马尔可夫决策过程来学习项目转移概率的研究团队之一。随后,Rendle等人^[10]提出FPMC,将马尔可夫链与矩阵分解相结合,同时捕获时间信息和用户的长期偏好,在SBR中获得了更好的性能。该方法在后续进行了改进和扩展,如纳入时空信息、上下文信息等^[11],进一步提高了该模型的有效性。即使马尔可夫链的独立性假设很强,但基于马尔可夫链的方法忽略了会话序列间的转移模式和交互作用整体间的时间依赖性,难以捕捉复杂的高阶序列关系。

1.2 基于深度学习的会话推荐

近期,伴随着深度学习技术的迅猛进展,该技术已

被广泛应用于会话推荐领域.文献[12]中的 GRU4Rec (gated recurrent unit for recommendation) 模型, 在 SBR 中第 1 次引入循环神经网络 (recurrent neural network, RNN), 并采用门控循环单元 (gated recurrent unit, GRU) 建模会话中物品的顺序行为. 文献[13]中的 NARM (neural attentive recommendation machine), 采用门控循环单元提取序列信息, 并采用注意力机制捕获用户的偏好. 文献[14]中的 HRNN (hierarchical recurrent neural network), 是一种个性化分层递归神经网络的会话模型. 其在 GRU4Rec 模型上增加了用户级的门控循环单元, 用于模拟用户会话中的信息, 并追踪用户在会话过程中的变化, 以更好地反映出用户兴趣的演变. 尽管循环神经网络在捕获连续动作序列的相关性上有着显著优势, 然而依赖 RNN 的方法往往过分强调邻近元素间的序列依赖性, 导致在处理远程依赖学习上存在困难, 并且难以对繁杂的项目转换逻辑进行建模.

1.3 基于图神经网络的会话推荐

如今, 在会话推荐系统中基于 GNN (graph neural network)^[15]的方法已经成为主流. 由于 GNN 可以捕获项目之间复杂的依赖关系, 所以非常适合用于会话推荐系统. SR-GNN^[16]模型首次将门控图神经网络 (GGNN) 用于 SBR, 在学习短期偏好的同时选择性地保留长期偏好信息. 虽然 GNN 有选择地保留关于长期项目的信息, 但由于 GNN 固有的层数限制, 其捕获长期偏好的能力因此受限. GC-SAN^[17]模型通过使用 GNN 作为局部信息编码器并添加自注意力机制来提高模型对长期依赖的学习能力, 从而解决了这一限制. GCE-GNN^[18]从会话和全局图级别学习会话表示, 并为全局图节点学习引入了会话感知的注意力机制, 该机制递归地合并全局图上每个节点的相邻嵌入. DHCN (dual channel hypergraph convolutional network)^[19]是第 1 个将超图^[20]应用于 SBR 的推荐模型. 它使用超图卷积来捕获项目配对转换关系之外的高阶信息, 并引入自监督学习来解决会话的数据稀疏性问题. MGIR^[21]通过学习多方面独立于会话的全局项目关系来增强会话表示. 同时, Li 等人^[22]将项目之间的显式和隐式关系解耦, 提出了一种双图神经网络 (dual graph neural network, DGNN) 来分别提取特征, 从而大幅提高了性能. 在基于 GNN 的 SBR 模型中, 多图模型比单图模型具有显著的优势. Qiao 等人^[23]将会话内和会话间的信息有效集成并考虑了会话相似性, 提出了一种双通道多稀疏图注意力网

络 (bi-channel multiple sparse graph attention network, MSGAT) 来利用当前会话以外的信息, 以及减少会话数据中不相关信息对预测的负面影响. 尽管基于 GNN 的方法取得了很好的效果, 但上述方法只能捕获单一会话内相邻项目的低阶成对转换关系和会话关系的低阶信息, 而忽略了会话间和非相邻项目之间的高阶转换和依存关系, 这导致模型只能捕获到非常有限的用户意图.

1.4 自监督学习

自监督学习 (self-supervised learning, SSL)^[24,25]并不需要大量的有标签数据, 它可以通过依据数据自身的特点和结构生成自监督信号来进行监督和训练. 对比学习是自监督学习的一种, 用自我监督的方式学习数据的特征. 对比学习根据所设计的正样本与负样本以及对比损失函数, 将正负样本进行对比, 通过对比学习样本的特征, 使正样本在嵌入空间的向量表示更加靠近. 一些研究将对比学习应用于推荐系统中^[26], 取得了非常好的效果. 文献[19]中的 DHCN (dual channel hypergraph convolutional network), 设计了一种双通道超图卷积网络, 利用 SSL 对比两个通道的样本特征, 并将 SSL 整合到模型训练中, 以作为辅助任务来提高推荐性能. 后来, 文献[27]中的一种协同训练模型 COTREC (self-supervised graph co-training framework for session-based recommendation), 通过两个非对称的图编码器得到复杂的正样本和负样本, 并将自监督学习整合到图训练中, 来获得更多有价值的信息, 以缓解会话数据的稀疏性.

受到上述方法的启发, 本文采用动态多阶门控图神经网络来捕获会话项目的局部顺序高阶特征, 准确地捕获用户的意图, 同时利用稀疏交叉注意力机制来增强会话关系表示. 并设计了一种将超图编码器学习到的用户兴趣高阶表示与另两个编码器学习到的用户兴趣表示进行对比学习的新型辅助任务, 以生成自监督信号, 有效地缓解了数据稀疏性的问题.

2 SDMHC-GNN 模型

2.1 总体框架

模型由 6 部分组成: 局部顺序会话表示学习部分、高阶会话表示学习部分、会话关系表示学习部分、自监督学习部分、意向邻居协作模块和预测层. 首先通过会话图、关系图和超图对会话序列进行建模,

得到会话数据的3个不同视图.在会话图分支中采用动态多阶门控图神经网络从局部会话顺序的图结构中提取到多阶的顺序特征,得到会话中的局部多阶顺序语义信息.接着使用稀疏自注意力机制来对图中不同节点的重要性进行动态分配,再使用稀疏全局注意力机制来对提取到的局部多阶顺序特征进行降噪处理,从而获得局部顺序会话表示;在超图分支中,超图卷积有效地捕捉超图中不同节点的复杂转换关系和重要的高阶信息,再通过软注意力机制强调超图中不同节点的重要性.从而捕捉到了蕴含丰富的语义信息和复杂的关系模式的高阶会话表示;在关系图分支中,图卷积网络从会话关系图结构中捕获不同会话间和其中项目之间的关联信息,为了加深3种不同会话表示的潜在联系和减少噪声对会话关系表示学习的影响,设计了会话关系表示增强器,利用局部顺序会话表示和高阶

会话表示通过稀疏交叉注意力机制来更好的学习会话关系表示.从多个视角处理会话数据可以提供额外的上下文信息,能够全面、有效地理解用户与项目的交互行为.针对数据稀疏性问题,将局部顺序会话表示和会话关系表示融合并与高阶会话表示进行对比学习,使会话局部顺序特征、会话关系特征和会话高阶特征各自相互获取新的信息,进行了会话数据增强,并将推荐任务与对比学习任务进行联合优化.此外,经过对比学习后的两个会话表示作为意向邻居协作模块输入,对当前的会话表示进行过滤和增强.最后,基于增强后的会话表示和局部顺序会话表示进行预测,得到最终的概率推荐列表.

本节首先介绍了基于会话推荐的符号和定义,然后分别介绍了上述模型的6个部分.SDMHC-GNN模型的总体框架如图1所示.




图1 SDMHC-GNN 模型框架

2.2 符号和定义

将数据集中的会话集合表示为 $S = \{s_1, s_2, s_3, \dots, s_o\}$, 其中 o 表示会话总数.在这个数据集中,所涉及的项目集合为 $V = \{v_1, v_2, v_3, \dots, v_n\}$, 其中 n 表示集合中项目的总数.每个会话 s_t 都是由匿名用户在一段时间内与项目交互产生的.在这种情况下,将时刻 t 处的会话定义为 $s_t = \{v_{s,1}, \dots, v_{s,k}, \dots, v_{s,m}\}$, 其中 m 代表当前会话的长度, $v_{s,k} \in V$ 表示在当前会话 s 中用户 k 点击的项目.因此, SBR 的目标是基于一个长度为 m 的连续点击项目序列来预测下一个潜在的点击项目 $v_{s,m+1}$.即通过会

话推荐模型计算出用户与每一个项目进行交互的概率 $y = \{y_1, y_2, \dots, y_n\}$, 选择交互概率的 $\text{top-}k$ 作为会话 s 的推荐项目列表.

定义1. 会话图: $G_s = (V, E)$, 其中 V 表示项目顶点集合, E 表示连接项目的边集合.边的方向由项目的点击顺序确定并带有一个相应权重.

定义2. 超图: $G_h = (V, E)$, 其中 V 表示 n 个唯一顶点的集合, E 表示超边集合.每条超边连接两个或多个顶点并带有一个相应权重.

定义3. 关系图: $G_r = (S, E)$, 其中 S 表示会话顶点

集合, E 表示关系边集合. 两个会话之间存在共现项才会被连接, 并根据共现项占两会话项目总数的比例, 赋予边相应的权重.

2.3 局部顺序会话表示学习部分

2.3.1 动态多阶门控图神经网络

本文引入了一种可学习的位置编码, 可以捕获节点的时间位置信息, 结合位置编码的嵌入表示如下:

$$X_t = (V_t \parallel P_t) \quad (1)$$

其中, $V_t \subseteq V$ 表示与 G_s 顶点集中的 s_t 相关的顶点嵌入, P_t 表示与该顶点对应的位置嵌入, $\parallel$ 表示拼接. 前文中, $v_i \in V_t$, $p_i \in P_t$, $x_i \in X_t$. $v_i, p_i \in R^{d \times 1}$, $x_i \in R^{2d \times 1}$.

传统的 GGNN^[28], 随着 GGNN 层数的增加, 模型捕获高阶邻居信息的能力增强, 但也会导致过度平滑的问题^[7]. 为了更好地捕获 G_s 中的高阶特征, 本文使用动态多阶门控图神经网络^[8]来处理 G_s 中带有位置信息的节点. 在会话 s 中, 对于每个项目 $x_{s,k}$ 使用向量 $x_{s,k}^l \in R^{1 \times 2d}$ 代表该项目的嵌入表示, 并将其初始化为 $x_{s,k}^0 \in R^{1 \times 2d}$. $A_s^{(in),q}$ 和 $A_s^{(out),q}$ 分别代表输入边和输出边的 q 阶邻接矩阵, $x_{s,k}^{q,l} \in R^{1 \times 2d}$ 表示会话 s 中的项目 $x_{s,k}$ 经过 l 次更新之后得到的 q 阶表示. 更新过程如下.

首先, 聚合相邻节点的信息:

$$\rho_{s,k}^{(out),q,l} = [x_{s,1}^{l-1}, x_{s,2}^{l-1}, \dots, x_{s,n}^{l-1}] (A_{s,k}^{(out),q})^T \quad (2)$$

$$\rho_{s,k}^{(in),q,l} = [x_{s,1}^{l-1}, x_{s,2}^{l-1}, \dots, x_{s,n}^{l-1}] (A_{s,k}^{(in),q})^T \quad (3)$$

$$\rho_{s,k}^{q,l} = W_1 [\rho_{s,k}^{(out),q,l} \parallel \rho_{s,k}^{(in),q,l}] + b_1 \quad (4)$$

其中, $x_{s,k}^{l-1} \in R^{1 \times 2d}$ 表示在会话 s 中项目 $x_{s,k}$ 经过 $l-1$ 次更新后的多阶表示, 它是利用软注意力机制给每一阶表示分配相应权重, 再对所有阶进行动态融合得到的. $[x_{s,1}^{l-1}, x_{s,2}^{l-1}, \dots, x_{s,n}^{l-1}] \in R^{n \times 2d}$ 表示会话 s 在第 $l-1$ 次更新步骤中全部项目的多阶表示. $A_{s,k}^{(out),q} \in R^{1 \times n}$ 和 $A_{s,k}^{(in),q} \in R^{n \times 1}$ 分别代表 $x_{s,k}$ 对应的 $A_s^{(out),q}$ 和 $A_s^{(in),q}$ 的第 k 行向量. $W_1 \in R^{2d \times 4d}$ 为可学习的参数矩阵, $b_1 \in R^{1 \times 2d}$ 为偏置项.

其动态融合过程如下:

$$\alpha_{s,k}^{q,l} = \sigma(W_2 x_{s,k}^{q,l}) \quad (5)$$

$$x_{s,k}^l = \sum_{q=1}^Q \alpha_{s,k}^{q,l} x_{s,k}^{q,l} \quad (6)$$

其中, $\sigma(\cdot)$ 表示 Sigmoid 函数. $\alpha_{s,k}^{q,l}$ 表示会话 s 中项目的 q 阶表示所占多阶表示的比例, $x_{s,k}^l$ 是会话 s 中的项目

$x_{s,k}$ 经过 l 次更新之后得到的多阶表示, $W_2 \in R^{1 \times 2d}$ 为可学习的参数矩阵.

其次, 计算更新门和重置门:

$$z_{s,k}^{q,l} = \sigma(W_3 \rho_{s,k}^{q,l} + W_4 x_{s,k}^{l-1}) \quad (7)$$

$$r_{s,k}^{q,l} = \sigma(W_5 \rho_{s,k}^{q,l} + W_6 x_{s,k}^{l-1}) \quad (8)$$

其中, $z_{s,k}^{q,l}$ 和 $r_{s,k}^{q,l}$ 分别代表在第 l 次更新步骤中的更新门和重置门. $W_3, W_4, W_5, W_6 \in R^{2d \times 2d}$ 为可学习的参数矩阵.

最后, 计算候选隐藏状态, 并更新为新的隐藏状态:

$$\tilde{x}_{s,k}^{q,l} = \tanh(W_7 \rho_{s,k}^{q,l} + W_8 (r_{s,k}^{q,l} \odot x_{s,k}^{l-1})) \quad (9)$$

$$x_{s,k}^{q,l} = (1 - z_{s,k}^{q,l}) \odot x_{s,k}^{l-1} + z_{s,k}^{q,l} \odot \tilde{x}_{s,k}^{q,l} \quad (10)$$

其中, $\odot$ 表示逐元素乘积. $W_7, W_8 \in R^{2d \times 2d}$ 为可学习的参数矩阵.

此外, 本文使用软注意力机制来聚合所有节点向量作为初始的局部顺序会话表示:

$$H_t^g = \sum_{i=1}^n \sigma(W_9 h_n + W_{10} h_i) h_i \quad (11)$$

其中, $H_t = [h_1, \dots, h_i, \dots, h_n]$ 表示动态多阶 GGNN 的输出结果, h_n 是最后一个点击项目的嵌入. $W_9, W_{10} \in R^{2d \times 2d}$ 为可学习的参数矩阵.

2.3.2 稀疏自注意力机制

在 SBR 中, 会话序列中的最后一项代表着用户的短期偏好, 但这其中可能包含着噪声信号, 比如由于用户的误操作, 可能会出现与其长期兴趣不符的点击行为, 这阻碍了精确的偏好学习. 为了消除会话序列中最后一项噪声引起的潜在的兴趣偏差, 本文在序列末尾引入一个空白节点作为附加节点, 该节点不包含有关当前会话的信息. 利用稀疏自注意力机制使目标节点结合项目图中其他节点的积极且有价值的信息, 同时最大限度地减少了噪声信息的影响.

$$\hat{H}_t = (H_t \parallel t_n) \quad (12)$$

其中, $t_n \in R^{2d \times 1}$ 表示额外的目标节点, $\hat{H}_t \in R^{(n+1) \times 2d}$ 表示新的潜在嵌入表示.

使用多头稀疏注意机制^[29]同时关注来自不同子空间的信息并对会话表示进行去噪处理. 模型中使用的自适应稀疏自注意机制包括 3 个主要步骤: 首先, 与传统的自注意力机制 $Q=K=V$ 不同, 本文在 Q 上引入了

一个线性投影. 它使自注意力机制有效地区分 Q 、 K 和 V , 增强其处理和适当权衡信息的能力.

$$Q = \text{ReLU}(W_{11}\hat{H}_t) \quad (13)$$

其中, $W_{11} \in R^{2d \times 2d}$ 为可学习的参数矩阵. Q 表示线性投影后的查询向量.

第2步, 计算控制 entmax 函数稀疏度的参数 α_s :

$$\alpha_s = \sigma(W_{12}t_n + b_2) + 1 \quad (14)$$

其中, $W_{12} \in R^{1 \times \frac{2d}{h}}$ 为可学习的参数矩阵, $b_2 \in R^{\frac{2d}{h}}$ 为偏置项, h 为多头注意力机制中头的数量.

最后, 计算注意力得分:

$$\text{SAtt}(Q, K, V) = \alpha_s - \text{entmax} \left(\frac{QK^T}{\sqrt{\frac{2d}{h}}} \right) V \quad (15)$$

$$H_{\text{SAtt}}^i = \text{SAtt}(QW_Q^i, KW_K^i, VW_V^i) \quad (16)$$

$$H_{\text{SAtt}} = (H_{\text{SAtt}}^1 \parallel H_{\text{SAtt}}^2 \parallel \dots \parallel H_{\text{SAtt}}^h) \quad (17)$$

其中, $W_Q^i, W_K^i, W_V^i \in R^{\frac{2d}{h} \times 2d}$ 为投影矩阵.

接下来, 通过加入位置级的前馈网络进一步增强稀疏自注意力机制的非线性.

$$\text{SGAT}_s(\hat{H}_t) = \max(0, W_{13}H_{\text{SAtt}} + b_3)W_{14} + b_4 \quad (18)$$

其中, $W_{13}, W_{14} \in R^{2d \times 2d}$ 为可学习的参数矩阵, $b_3, b_4 \in R^{1 \times 2d}$ 为偏置项.

自注意力机制的最终输出:

$$H_t^s, t_n^s = \text{SGAT}_s(\hat{H}_t) \quad (19)$$

其中, $H_t^s \in R^{n \times 2d}$ 表示经过自注意力机制后新的会话表示, $t_n^s \in R^{1 \times 2d}$ 表示更新后的目标节点表示.

2.3.3 稀疏全局注意力机制

利用更新后的目标表示和新的潜在会话表示对先前学习到的局部顺序会话表示 H_t^g 作降噪处理:

$$\alpha_g = \sigma(W_{15}t_n + b_5) + 1 \quad (20)$$

$$\beta_i^g = \alpha_g - \text{entmax}(W_{18}\text{ReLU}(W_{16}H_t^s + W_{17}t_n^s + b_6))H_t^g \quad (21)$$

$$H_{\text{GAtt}} = \sum_{i=0}^n \beta_i^g h_{t,i}^g \quad (22)$$

其中, $W_{16}, W_{17} \in R^{2d \times 2d}$, $W_{15}, W_{18} \in R^{1 \times 2d}$ 为可学习的参数矩阵, $b_5, b_6 \in R^{1 \times 2d}$ 为偏置项. β_i^g 表示经过全局注

意力机制后的得分, $h_{t,i}^g \in H_t^g$ 表示初始的局部顺序会话表示.

最后, 结合来自全局和目标视角的信息来生成最终的局部顺序会话表示:

$$H_c = \text{SELU}(W_{19}((H_{\text{SAtt}} \parallel H_{\text{GAtt}})) + b_7) \quad (23)$$

其中, $W_{19} \in R^{d \times 4d}$ 为可学习的参数矩阵, $b_7 \in R^{1 \times d}$ 为偏置项.

2.4 高阶会话表示学习部分

超图卷积定义如下:

$$X_h^{(l+1)} = D^{-1}HW_hB^{-1}H^T X_h^{(l)} \quad (24)$$

其中, $H^T X_h^{(l)}$ 实现节点到超边的信息聚合, 再通过预乘关联矩阵 H 来聚合超边到节点的信息.

通过多个超图卷积层后, 对每层获得的项目嵌入进行平均, 得到最终的项目嵌入:

$$X_h = \frac{1}{L+1} \sum_{l=0}^L X_h^{(l)} \quad (25)$$

其中, L 为超图卷积的次数.

将反向位置嵌入与学习到的项目表示进行衔接. 在会话 s 中第 k 个物品表示为:

$$x_{s,k}^* = \tanh(W_{20}[v_{s,k} \parallel p_{s,m-k+1}] + b_8) \quad (26)$$

其中, $W_{20} \in R^{d \times 2d}$ 为可学习的参数矩阵, $b_8 \in R^{1 \times d}$ 为偏置项.

超图的会话表示可以通过聚合该会话中项目的表示来得到. 本文使用软注意力机制来生成超图的高阶会话表示:

$$\alpha_{s,k} = f^T \sigma(W_{21}x_s^* + W_{22}x_{s,k}^* + c) \quad (27)$$

$$H_t^h = \sum_{k=1}^m \alpha_{s,k} x_{s,k}^* \quad (28)$$

其中, x_s^* 表示当前会话 s 的嵌入, $x_{s,k}^*$ 表示会话 s 中第 k 个项目的嵌入, $f, c \in R^{1 \times d}$, $W_{21}, W_{22} \in R^{d \times d}$ 为可学习的参数.

2.5 会话关系表示学习部分

2.5.1 图卷积网络

由于 G_r 不包含具体项目的信息, 首先使用会话中跨会话项目的平均嵌入作为初始关系表示 R^0 . 再通过图卷积学习会话关系表示:

$$R^{l+1} = D_r^{-1}(A_r + I)R^l \quad (29)$$

其中, $D_r, A_r, I \in R^{o \times o}$ 分别表示度矩阵、邻接矩阵和单位矩阵。 o 为 G_r 中会话节点的数量, l 为图卷积的层数。

2.5.2 稀疏交叉注意力机制

为了消除会话间信息中的潜在噪声和增强会话关系表示与其他级别表示的潜在联系, 本文提出了一种稀疏交叉注意力机制, 其利用会话内目标信息和高阶会话信息对会话关系表示进行有针对性的过滤和增强。

$$\alpha_r = \sigma(W_{23}t_n + b_9) + 1 \quad (30)$$

$$H_{RAH} = \alpha_r - \text{entmax}(W_{26}\text{ReLU}(W_{24}H_t^h + W_{25}t_n + b_1^r))R^{l+1} \quad (31)$$

其中, $W_{24}, W_{25}, W_{26} \in R^{2d \times 2d}$ 为可学习的参数矩阵, $b_9 \in R^{1 \times 2d}$ 为偏置项。

2.6 自监督学习

自监督学习包括对比学习和生成学习^[30]。介于对比学习在 SBR 中被广泛应用, 并作为辅助任务来增强模型的性能。因此, 本文使用对比学习来完成自监督任务。首先, 将局部顺序会话表示与会话关系表示相加, 与超图的高阶会话表示进行对比学习实现数据增强。采用 In-foNCE^[31] 将正负样本之间的二元交叉熵损失作为模型的学习目标, 其定义如下:

$$H_t^u = H_c + H_{RAH} \quad (32)$$

$$L_s = -\log \sigma(f_D(\theta_i^h, \theta_i^u)) - \log \sigma(1 - f_D(\tilde{\theta}_i^h, \theta_i^u)) \quad (33)$$

其中, $\tilde{\theta}_i^h$ 是 θ_i^h 行列变化顺序得到的负样本, f_D 为鉴别函数, 通过两个向量之间的点积对输入向量之间的一致性进行评分, 最大化不同视图中学习到的会话表示之间的互信息。

2.7 意向邻居协作模块

本文使用 INC 模块来进一步过滤和增强当前会话表示。将经过对比学习后的两个会话表示输入到 INC 模块中, INC 模块从关系图 G_r 中选择与当前会话有连接 top- N 会话节点作为相似候选会话 S_{si} 。其次, 该模块计算当前会话表示 h_{si}^t 与每个相似候选会话的会话表示 H_{si} 之间的相似度分数 $SIScore$:

$$H_{si} = H_t^u + H_t^h \quad (34)$$

$$SIScore = \frac{h_{si}^t \top h_{si}^j}{\|h_{si}^t\| \|h_{si}^j\|} \quad (35)$$

其中, H_{si} 表示相似会话的潜在表示, $j = \{1, 2, \dots, N\}$ 表示相似会话的标记。本文选取相似度分数最高的 R ($R \leq N$) 个相似候选会话的会话表示作为当前会话的辅助表示。

对于选取的 R 个相似候选会话的会话表示的融合过程如下:

$$\tau_j = \frac{\exp(SIScore)}{\sum_{j=1}^R \exp(SIScore)} \quad (36)$$

$$\tilde{H}_{si} = \sum_{j=1}^R \tau_j h_{si}^j \quad (37)$$

其中, τ_j 表示每个相似候选会话在 R 个相似候选会话集中的重要程度, $\tilde{H}_{si}$ 表示增强后的会话表示。

2.8 预测层

为了提高预测能力, 会话的最终表示为: $H_f = H_c + \tilde{H}_{si}$ 。由于 SBR 中存在长尾问题, 这意味着推荐系统偏向于为用户推荐热门的项目, 而忽略了那些不太受欢迎的项目。受文献^[32]的启发, 本文对所有的项目嵌入项进行 L_2 归一化处理, 以减少热门项目和长尾项目之间的差距。然后, 对于每个项目 $v_k \in V$, 可以获得它被点击的概率:

$$\hat{y}_k = \text{Softmax}(h_{f,k}^T v_k) \quad (38)$$

其中, $H_f = \{h_{f,1}, \dots, h_{f,k}, \dots, h_{f,n}\}$, $v_k \in R^{1 \times d}$ 是项目的嵌入。将真实值和预测值的交叉熵定义为模型的损失函数:

$$L_1 = -\sum_{k=1}^m y_k \log(\hat{y}_k) + (1 - y_k) \log(1 - \hat{y}_k) \quad (39)$$

其中, y 为真实项的 one-hot 编码向量, 最后推荐任务与自监督学习任务结合得到总损失函数:

$$L = L_1 + \beta L_s \quad (40)$$

其中, β 为调整自监督任务大小的超参数。

本文模型在数据集 Diginetica 和 Tmall 上训练过程的损失收敛曲线如图 2 所示。其中 Loss 表示模型每个训练轮次的平均批处理损失。在训练的初始阶段, 模型在两个数据集上 Loss 逐轮下降, 模型性能也随之逐步提升。随后, 模型在 Tmall 和 Diginetica 数据集上的 Loss 分别第 8 轮和第 10 轮时趋于稳定, 开始收敛, 模型的推荐性能也达到了最佳。由于 Diginetica 的数据规模相比于 Tmall 较为庞大, 其最终收敛 Loss 的数值也较高。

3 实验与分析

3.1 数据集与预处理

本文在 Diginetica 和 Tmall 两个常用数据集进行

实验,来验证SDMHC-GNN模型的有效性。Diginetica数据集源自2016年CIKM挑战赛,涵盖了某电子商务平台6个月期间的用户点击行为记录;而Tmall数据集则是由IJCAI-15大赛提供,其中收录了在我国最大电商平台天猫上匿名用户的购物行为信息。对于数据预处理,本文过滤掉会话长度为1且项目出现次数少于5次的数据。两个数据集详细的数据统计如表1所示。




图2 损失收敛曲线

表1 数据集统计

统计项	Diginetica	Tmall
训练集	719 470	351 268
测试集	60 858	25 898
点击次数	982 961	818 479
项目数	43 097	40 728
会话平均长度	5.12	6.69

3.2 评价指标

本文实验采用了 $Precision@K$ (简称 $P@K$) 与 $MRR@K$ 两种评测标准来对模型性能进行量化分析,其中 K 值在设定为 20。

$P@K$ 作为衡量预测准确性的重要指标,反映了推荐列表前 K 项中准确推荐的商品比例,数值越高表明模型效果越显著。具体的计算方式如下:

$$P@K = n_{hit}/N \quad (41)$$

其中, N 为样本总数, n_{hit} 表示前 K 个推荐项目中正确推荐项目的数量。

$MRR@K$ 指的是在推荐列表中,被正确推荐的物品所对应的平均倒数名次。若推荐列表中,正确推荐的物品排列越靠前,其数值便会越高,反映出推荐效果更佳,这也体现了推荐系统的优越性。其计算表达式为:

$$MRR@K = \frac{1}{N} \sum_{i \in R} \frac{1}{rank(i)} \quad (42)$$

其中, N 代表所有样本的总量, R 指的是在前 K 个推荐项目中所包含的正确推荐项目的数目,而 $rank(i)$ 指的是商品 i 在最终推荐列表里所占的序位。

3.3 实验环境与参数设置

本文模型采用 Python 3.8.19 为开发语言,使用 PyTorch 2.2.2 框架实现,采用 Adam 作为优化器。实验所用硬件的操作系统为 Windows 10,处理器为 Intel(R) Core (TM) i5-12600KF@3.70 GHz,显卡为 NVIDIA GeForce RTX 3060Ti 8 GB,运行内存为 16 GB。将训练次数和训练批次大小分别设置为 30 和 512,初始学习率设置为 $1E-3$ 且在每 5 个周期之后,学习率衰减为原来的 0.1,嵌入维度设置为 100,正则化的权重设置为 $1E-5$,使用标准差为 0.1 的高斯分布初始化参数。

3.4 基线模型

为更好地验证 SDMHC-GNN 模型的有效性,本文从传统的、基于注意力机制的和基于 GNN 的模型中选择以下具有代表性的基线模型与 SDMHC-GNN 模型进行比较。

- (1) POP: 一种基于热门商品推荐的传统模型。
- (2) FPMC^[10]: 结合马尔可夫链和矩阵分解的混合模型。
- (3) GRU4Rec^[12]: 是第 1 个基于 RNN 的 SBR 模型,并利用 GRU 对会话序列进行建模和推荐的模型。
- (4) NARM^[13]: 借助注意力机制对 RNN 进行强化,从而更加明确地揭示了用户在当前会话中的具体意图。
- (5) SR-GNN^[16]: 使用 GGNN 作为编码器来捕获项目动作之间的交互。
- (6) FGNN^[33]: 是一种基于 GNN 的 SBR 模型,主要通过学习项目之间的固有顺序来生成用于推荐的会话级表示。
- (7) GCE-GNN^[18]: 分别在会话级图和全局级图上应用不同级别的图卷积网络以学习会话表示。
- (8) DHCN^[19]: 作为首个将超图技术应用于 SBR 领域的模型,它依托于超图的独有属性,能够精准地捕捉到超越常规转换关系的深层信息,同时通过自监督学习策略,有效缓解了数据的稀疏性问题。
- (9) MSGAT^[23]: 构建了会话和关系视图,将会话内和会话间的信息有效集成并考虑了会话相似性。

3.5 实验结果及分析

3.5.1 对比实验

在 Diginetica 和 Tmall 两个数据集上对基线模型和本文模型进行测试, 结果如表 2 所示, SDMHC-GNN 在两个常用数据集上的结果均优于基线模型并取得了较大的提升. 根据表 2 的结果给出以下分析.

表 2 模型性能比较结果 (%)

模型	Diginetica		Tmall	
	$P@20$	$MRR@20$	$P@20$	$MRR@20$
POP	1.18	0.28	2.00	0.90
FPMC	22.14	6.66	16.06	7.32
GRU4Rec	30.79	8.22	10.93	5.89
NARM	48.32	16.00	23.30	10.70
SR-GNN	50.73	17.59	27.75	13.72
FGNN	50.58	16.84	25.24	10.39
GCE-GNN	54.22	19.04	33.42	15.42
DHCN	53.66	18.51	31.42	15.05
MSGAT	<u>66.97</u>	<u>26.91</u>	<u>42.74</u>	<u>21.35</u>
SDMHC-GNN	68.92	30.92	44.28	22.54
Improvement (%)	2.91	14.90	3.60	5.57

(1) 在传统的 SBR 模型中, POP 是性能最差的一个, 因为它只推荐频繁出现的项目, 而没有很好地利用会话信息来建模用户的时间顺序行为. FPMC 模型融合了矩阵分解与马尔可夫链的推荐策略, 然而在 SBR 场景下, 由于缺乏用户个体信息, 其表现受到了显著限制.

(2) 相比于传统的 SBR 模型, 深度学习技术的融入使得 SBR 模型得以发展, 通过融合循环神经网络 (RNN) 以及注意力机制等先进技术, SBR 模型的性能得到了显著增强. GRU4Rec 作为首个将 RNN 应用于 SBR 领域的尝试, 证明了其在序列构建上的出众能力. 而 NARM 模型则是对 RNN 的进一步拓展, 它采纳了注意力机制以更精确地把握用户需求, 进而提高了性能指标, 并证实了注意力机制在提升模型效果上的重要作用. 但是上述模型只基于用户行为的显式交互来建模, 忽略了会话中项目之间的隐含联系.

(3) 为了克服上述问题, 随后的研究利用各类图来建模会话数据, 并采用不同的图卷积来捕获会话中项目之间的隐式联系. SR-GNN 通过将会话信息转化为图形结构, 并借助 GNN 技术来掌握配对间的转换规律, 从而实现了性能的提升. 而 FGNN 模型的表现超过了 SR-GNN 和 GRU4Rec, 这一成果凸显了会话级别信息的重要性. GCE-GNN 利用构建会话网络和整体关联网络的方式, 突出了不同会话数据之间的关联价值. 该

网络结构显著提高了性能指标, 证实了增加额外图层级设计的有效性和实用性. 而 DHCN 则通过采用超图来捕捉更为复杂的转换逻辑, 并引入自监督学习策略, 以减轻数据稀疏问题对推荐系统效果的不良影响. MSGAT 通过对会话图和关系图建模, 利用稀疏注意力机制对两个图级的会话表示进行降噪. 此外, 该模型有效地利用了会话内、外信息来计算意图相似性, 并使用相似的会话过滤和增强当前会话表示. MSGAT 的性能明显优于以上模型, 验证了会话外信息以及稀疏注意力机制的有效性. 但 MSGAT 缺乏对高阶特征的捕获和利用, 以及对会话稀疏性的处理不足, 使其的性能不如本文所提出的 SDMHC-GNN 模型.

(4) 本模型相比于最优的基线模型 MSGAT, 本模型在 Diginetica 数据集中, $P@20$ 与 $MRR@20$ 两项指标分别实现了 2.91 个百分点和 14.90 百分点的增长; 而在 Tmall 数据集上, $P@20$ 与 $MRR@20$ 指标分别获得了 3.60 个百分点及 5.57 百分点的提升. 证明了本模型可以有效地提取并利用高阶特征, 以及缓解数据稀疏性对推荐性能的影响. 特别是在 Diginetica 数据集中 $MRR@20$ 指标上的优势尤为明显, 这可能是由于 Diginetica 相比于 Tmall 具有更大数据规模, 所含有的会话间信息也更加丰富, 所以可能更适用于高阶关系的建模. 其次, 是由 $MRR@K$ 指标本身的性质决定. $MRR@K$ 相对于 $P@K$ 更关注最终推荐列表中项目的排名, 而不是推荐整体的准确性, 第 1 个推荐正确的项目出现在靠前的位置, $MRR@K$ 就能获得较高的分数.

3.5.2 消融实验

为了验证 SDMHC-GNN 中各部分的贡献, 设计了 4 个不同的变体在以上两个数据集上与 SDMHC-GNN 进行对比实验.

(1) SDMHC-GNN: 本文所提出的模型.

(2) SDMHC-GNN-1: SDMHC-GNN 去掉动态多阶门控图神经网络, 换成普通的门控图神经网络.

(3) SDMHC-GNN-2: SDMHC-GNN 去掉稀疏交叉注意力机制, 换成普通的自注意力机制.

(4) SDMHC-GNN-3: SDMHC-GNN 去掉超图编码器分支.

(5) SDMHC-GNN-4: SDMHC-GNN 去掉自监督学习任务.

实验结果如图 3、图 4 所示, 当把动态多阶门控图神经网络替换为普通的门控图神经网络时, 模型的性

能有所下降,这是因为普通的 GGNN 缺乏对高阶特征的提取和利用且过多层的 GGNN 会造成过平滑和梯度消失的问题,也证明了动态多阶 GGNN 可以更好地提取和利用会话项目的高阶特征和复杂的依赖关系;和 SDMHC-DNN-2 相比,原模型 SDMHC-DNN 的性能有了一定的提升,说明了稀疏交叉注意力机制相比于普通的自注意力机制能加强本级会话表示与其他级别会话表示的潜在联系并给不相关项的权重赋予 0,对本级会话表示进行了有效降噪,从而更加准确地进行推荐;当去掉超图编码器分支后,原模型的性能降低了,

这说明超图编码器分支可以捕获到会话中非相邻项目的高阶特征,有助于模型更好地做出预测;把原模型去掉自监督学习任务后,原模型的性能显著降低了.这有可能是由于将未去噪的超图会话表示与去噪的会话图和关系图会话表示直接融合,导致最终生成的会话表示中含有噪声项,对预测的准确性造成了影响.同时,这也说明了对比学习能将不同会话表示的互特征最大化,从而有效地消除噪声对推荐性能的影响,以及在一定程度上缓解了会话数据的稀疏性,增强模型的可解释性,提高了预测的准确性.




图3 数据集 Diginetica 中的消融实验




图4 数据集 Tmall 中的消融实验

3.5.3 动态多阶门控图神经网络阶数分析

为研究动态多阶门控图神经网络中阶数对模型性能的影响,在本研究中,固定其他变量,将阶数 q 的选取界限设定为集合 $\{1, 2, 3, 4, 5, 6, 7\}$. 实验结果如图 5、图 6 所示,观察可发现,随着阶数 q 的逐步上升,模型在两组数据集上的评估指标均呈现出增长趋势. 具体

来看,在 Diginetica 数据集中,当阶数 q 等于 2 时,模型的性能达到顶峰;而在 Tmall 数据集中,模型在阶数 q 为 4 时展现出最优性能.然而,当阶数 q 继续增加时,模型的表现开始逐渐走低.过小的 q 值无法充分提取会话项目的高阶特征,太大的 q 值导致了模型的过拟合,以至于模型的性能下降.




图5 数据集 Diginetica 中动态多阶 GGNN 阶数大小分析




图6 数据集 Tmall 中动态多阶 GGNN 阶数大小分析

3.5.4 超图卷积深度分析

为探讨超图编码器中不同层数的超图卷积对模型效果的作用, 本文在维持其他设定不变的前提下, 对超图卷积的层数进行了调整, 分别设定为1层、2层、3层、4层以及5层. 通过观察图7和图8, 发现在

Diginetica 数据集中, 当超图卷积的层数定为1时, 模型展现出最优性能. 在 Tmall 数据集上, 超图卷积的层数设置为2, 模型的性能达到最佳. 之后, 随着层数的增加, 模型的性能开始下降. 这是由于过多层的图卷积导致了过平滑问题.




图7 数据集 Diginetica 中超图卷积深度分析




图8 数据集 Tmall 中超图卷积深度分析

3.5.5 自监督学习参数分析

在自监督学习任务中, 本文提出引入一个新的参数 β , 用以控制自监督学习的强度. 探究该参数 β 对推荐系统性能的具体影响时, 保持其他设定不变, 将参数 β 的数值限定在 $\{0.001, 0.002, 0.005, 0.01, 0.02, 0.05, 0.1\}$ 这一区间内. 根据表3和表4的实验数据, 可以观察到, 在初始阶段, 随着 β 值的逐步上升, 模型在两个不同数据集上的评估指标均呈现出上升的趋势. 具体到 Diginetica 数据集, 当 β 取值为 0.01 时, 模型展现出最优性能; 而在 Tmall 数据集上, 模型在 β 值为 0.005 时达到最高性能. 但此后再随着 β 的增加会使正负样本之间的对比过于严格, 这限制了模型的表达能力, 也不能使模型更好地学习到有效的特征表示, 导致模型的性能逐步下降.

表3 在指标 $P@20$ 下自监督学习参数大小分析 (%)

数据集	0.001	0.002	0.005	0.01	0.02	0.05	0.1
Diginetica	67.48	68.39	68.38	68.92	65.65	60.14	56.13
Tmall	41.32	42.33	44.28	42.57	36.84	27.69	22.07

表4 在指标 $MRR@20$ 下自监督学习参数大小分析 (%)

数据集	0.001	0.002	0.005	0.01	0.02	0.05	0.1
Diginetica	27.72	27.88	28.31	30.92	29.41	24.64	23.40
Tmall	22.03	22.24	22.54	21.77	19.47	15.09	12.81

3.5.6 会话推荐实例分析

为了直观地展示 SDMHC-GNN 模型在实际推荐中的可用性和可信性, 本文从 Diginetica 和 Tmall 的测试集中随机各选取一个会话实例来进行实例分析. 从 Diginetica 和 Tmall 中选取的会话实例的长度分别为 8 和 18.

为了更好地体现本文模型在实际推荐中的有效性和准确性, 本文选取了两个具有代表性的方法 DHCN 和 MSGAT 与本文模型进行对比. DHCN 是首个基于自监督学习并融合超图神经网络的会话推荐模型, 而 MSGAT 是推荐性能最好的基线模型.

前 20 个推荐结果如表5、表6所示, 可以观察到: 在数据集 Diginetica 的实例中, MSGAT 和本文模型 SDMHC-GNN 分别第 10 个位序和第 2 个位序预测到了真实值 33107 号项目, 而 DHCN 没有推荐 33107 号项目. 在 Tmall 数据集的实例中, 只有本文模型 SDMHC-GNN 在第 1 个位序上成功的预测了真实值 20875 号项目. 这说明了本文所提出的模型 SDMHC-GNN 在实际推荐中具有较好的可用性和可信性, 以及在推荐准确性方面的优越性.

表5 数据集 Diginetica 中的实例分析

内容		项目编号
会话	实例	20725→26213→33926→35375→39447→40980→42723→43036
	真实值	33107
模型		38491, 40011, 38626, 36600, 37215, 17585, 30742,
	DHCN	30850, 9592, 37403, 33927, 32570, 27100, 39892, 39954, 36693, 38938, 27561, 34974, 41599
	MSGAT	39533, 39446, 43035, 42104, 20724, 41874, 42386, 40197, 41190, 33107 , 42508, 26229, 36625, 38491, 9933, 42515, 27101, 36979, 42571, 42598
	SDMHC-GNN	29547, 33107 , 42572, 20724, 43035, 38654, 33925, 21218, 35340, 42570, 41854, 10770, 42484, 27100, 8291, 17418, 41111, 41190, 42104, 42948

4 结论与展望

为了解决传统图神经网络在会话推荐系统中对高

阶信息处理能力不足以及数据稀疏性等挑战,本文提出了一种结合动态多阶门控图神经网络和超图卷积的自监督会话推荐模型(SDMHC-GNN)。通过不同的图结构对会话序列建模,从不同的角度学习会话表示,并通过稀疏交叉注意力机制加强不同会话表示之间的潜在联系。其次,通过引入自监督学习增强会话数据来缓解会话稀疏性。同时,依靠超图卷积学习超图结构数据的强大能力以捕捉项目之间复杂的高阶转换关系。除此之外,使用动态多阶GGNN,在避免过平滑的情况下,有效地捕获了会话的高阶信息。在今后研究中,将考虑使用其他方法来更有效地捕获会话的高阶信息,另外可以把更复杂的用户上下文信息融入到SBR中,如设备信息、社交关系等,并设计一个更有效地辅助任务来缓解会话稀疏性,以提供更具个性化和更加准确的会话推荐系统。

表6 数据集Tmall中的实例分析

内容	项目编号
会 话	12056→16716→17029→21039→21040→21043→
	23033→23364→25465→25820→29889→29890→
	31626→34179→35464→37520→38542→39320
真实值	20875
模 型	26567, 34406, 30359, 26237, 21042, 35065, 21318,
	DHCN 21914, 34385, 7645, 34383, 31127, 21945, 22575,
	33213, 22694, 34386, 10358, 40764, 17873
	21042, 10708, 14436, 22607, 7756, 37596, 10743,
	MSGAT 21040, 32007, 40021, 24933, 36709, 30681, 37173,
SDMHC	17125, 2033, 10431, 30812, 28200, 22777
	20875 , 21040, 21042, 21039, 22633, 38265, 21043,
	12398, 7353, 18094, 40027, 19831, 17786, 40673,
-GNN	21563, 39279, 23032, 13344, 35020, 35006

参考文献

- 1 吴永庆, 朱月, 王钰涵. 基于注意力机制的自监督图卷积会话推荐. 计算机系统应用, 2024, 33(5): 57–66. [doi: [10.15888/j.cnki.csa.009483](https://doi.org/10.15888/j.cnki.csa.009483)]
- 2 崔少国, 独潇, 张宜浩. 基于兴趣注意力网络的会话推荐算法. 电子科技大学学报, 2024, 53(1): 67–75.
- 3 Chen WY, Cai F, Chen HH, *et al.* Joint neural collaborative filtering for recommender systems. *ACM Transactions on Information Systems (TOIS)*, 2019, 37(4): 39. [doi: [10.1145/3343117](https://doi.org/10.1145/3343117)]
- 4 Yu JL, Gao M, Li JD, *et al.* Adaptive implicit friends identification over heterogeneous network for social recommendation. *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*. Torino: ACM, 2018. 357–366. [doi: [10.1145/3269206.3271725](https://doi.org/10.1145/3269206.3271725)]
- 5 王永贵, 赵晓暄. 结合自监督学习的图神经网络会话推荐. 计算机工程与应用, 2023, 59(3): 244–252. [doi: [10.3778/j.issn.1002-8331.2204-0245](https://doi.org/10.3778/j.issn.1002-8331.2204-0245)]
- 6 Gao C, Wang X, He XN, *et al.* Graph neural networks for recommender system. *Proceedings of the 15th ACM International Conference on Web Search and Data Mining*. ACM, 2022. 1623–1625. [doi: [10.1145/3488560.3501396](https://doi.org/10.1145/3488560.3501396)]
- 7 Chen DL, Lin YK, Li W, *et al.* Measuring and relieving the over-smoothing problem for graph neural networks from the topological view. *Proceedings of the 34th AAAI Conference on Artificial Intelligence*. New York: AAAI, 2020. 3438–3445. [doi: [10.1609/aaai.v34i04.5747](https://doi.org/10.1609/aaai.v34i04.5747)]
- 8 Chen YH, Huang L, Wang CD, *et al.* Hybrid-order gated graph neural network for session-based recommendation. *IEEE Transactions on Industrial Informatics*, 2022, 18(3): 1458–1467. [doi: [10.1109/TII.2021.3091435](https://doi.org/10.1109/TII.2021.3091435)]
- 9 Shani G, Heckerman D, Brafman RI. An MDP-based recommender system. *Journal of Machine Learning Research*, 2005, 6: 1265–1295. [doi: [10.48550/arXiv.1301.0600](https://doi.org/10.48550/arXiv.1301.0600)]
- 10 Rendle S, Freudenthaler C, Schmidt-Thieme L. Factorizing personalized markov chains for next-basket recommendation. *Proceedings of the 19th International Conference on World Wide Web*. Raleigh: ACM, 2010. 811–820. [doi: [10.1145/1772690.1772773](https://doi.org/10.1145/1772690.1772773)]
- 11 Yin HZ, Cui B. *Spatio-temporal Recommendation in Social Media*. Singapore: Springer, 2016. [doi: [10.1007/978-981-10-0748-4](https://doi.org/10.1007/978-981-10-0748-4)]
- 12 Hidasi B, Karatzoglou A, Baltrunas L, *et al.* Session-based recommendations with recurrent neural networks. *arXiv:1511.06939*, 2015.
- 13 Li J, Ren PJ, Chen ZM, *et al.* Neural attentive session-based recommendation. *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*. Singapore: ACM, 2017. 1419–1428. [doi: [10.1145/3132847.3132926](https://doi.org/10.1145/3132847.3132926)]
- 14 Quadrana M, Karatzoglou A, Hidasi B, *et al.* Personalizing session-based recommendations with hierarchical recurrent neural networks. *Proceedings of the 11th ACM Conference on Recommender Systems*. Como: ACM, 2017. 130–137. [doi: [10.1145/3109859.3109896](https://doi.org/10.1145/3109859.3109896)]
- 15 朱志国, 李伟玥, 姜盼, 等. 图神经网络会话推荐系统综述. 计算机工程与应用, 2023, 59(5): 55–69.
- 16 Wu S, Tang YY, Zhu YQ, *et al.* Session-based

- recommendation with graph neural networks. Proceedings of the 33rd AAAI Conference on Artificial Intelligence. Honolulu: AAAI, 2019. 346–353. [doi: [10.1609/aaai.v33i01.3301346](https://doi.org/10.1609/aaai.v33i01.3301346)]
- 17 Wang MR, Ren PJ, Mei L, *et al.* A collaborative session-based recommendation approach with parallel memory modules. Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. Paris: ACM, 2019. 345–354. [doi: [10.1145/3331184.3331210](https://doi.org/10.1145/3331184.3331210)]
- 18 Wang ZY, Wei W, Cong G, *et al.* Global context enhanced graph neural networks for session-based recommendation. Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2020. 169–178. [doi: [10.1145/3397271.3401142](https://doi.org/10.1145/3397271.3401142)]
- 19 Xia X, Yin HZ, Yu JL, *et al.* Self-supervised hypergraph convolutional networks for session-based recommendation. Proceedings of the 35th AAAI Conference on Artificial Intelligence. AIAA, 2021. 4503–4511. [doi: [10.1609/aaai.v35i5.16578](https://doi.org/10.1609/aaai.v35i5.16578)]
- 20 Feng YF, You HX, Zhang ZZ, *et al.* Hypergraph neural networks. Proceedings of the 33rd AAAI Conference on Artificial Intelligence. Honolulu: AAAI, 2019. 3558–3565. [doi: [10.1609/aaai.v33i01.33013558](https://doi.org/10.1609/aaai.v33i01.33013558)]
- 21 Han QL, Zhang C, Chen R, *et al.* Multi-faceted global item relation learning for session-based recommendation. Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid: ACM, 2022. 1705–1715.
- 22 Li ZH, Wang XZ, Yang C, *et al.* Exploiting explicit and implicit item relationships for session-based recommendation. Proceedings of the 16th ACM International Conference on Web Search and Data Mining. Singapore: ACM, 2023. 553–561. [doi: [10.1145/3539597.3570432](https://doi.org/10.1145/3539597.3570432)]
- 23 Qiao ST, Zhou W, Wen JH, *et al.* Bi-channel multiple sparse graph attention networks for session-based recommendation. Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. Birmingham: ACM, 2023. 2075–2084. [doi: [10.1145/3583780.3614791](https://doi.org/10.1145/3583780.3614791)]
- 24 Yu JL, Yin HZ, Xia X, *et al.* Self-supervised learning for recommender systems: A survey. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(1): 335–355. [doi: [10.1109/TKDE.2023.3282907](https://doi.org/10.1109/TKDE.2023.3282907)]
- 25 Huang C, Wang X, He XN, *et al.* Self-supervised learning for recommender system. Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid: ACM, 2022. 3440–3443. [doi: [10.1145/3477495.3532684](https://doi.org/10.1145/3477495.3532684)]
- 26 Xie X, Sun F, Liu ZY, *et al.* Contrastive learning for sequential recommendation. Proceedings of the 38th IEEE International Conference on Data Engineering (ICDE). Kuala Lumpur: IEEE, 2022. 1259–1273. [doi: [10.1109/ICDE53745.2022.00099](https://doi.org/10.1109/ICDE53745.2022.00099)]
- 27 Xia X, Yin HZ, Yu JL, *et al.* Self-supervised graph cotraining for session-based recommendation. Proceedings of the 30th ACM International Conference on Information & Knowledge Management. Queensland: ACM, 2021. 2180–2190. [doi: [10.1145/3459637.3482388](https://doi.org/10.1145/3459637.3482388)]
- 28 Li YJ, Tarlow D, Brockschmidt M, *et al.* Gated graph sequence neural networks. arXiv:1511.05493, 2015.
- 29 Correia GM, Niculae V, Martins AFT. Adaptively sparse Transformers. Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Hong Kong: ACL, 2019. 2174–2184. [doi: [10.18653/v1/D19-1223](https://doi.org/10.18653/v1/D19-1223)]
- 30 Liu X, Zhang FJ, Hou ZY, *et al.* Self-supervised learning: Generative or contrastive. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(1): 857–876. [doi: [10.1109/TKDE.2021.3090866](https://doi.org/10.1109/TKDE.2021.3090866)]
- 31 van den Oord D, Li YZ, Vinyals O. Representation learning with contrastive predictive coding. arXiv:1807.03748, 2018.
- 32 Gupta P, Garg D, Malhotra P, *et al.* NISER: Normalized item and session representations to handle popularity bias. arXiv: 1909.04276, 2019.
- 33 Qiu RH, Li JJ, Huang Z, *et al.* Rethinking the item order in session-based recommendation with graph neural networks. Proceedings of the 28th ACM International Conference on Information and Knowledge Management. Beijing: ACM, 2019. 579–588. [doi: [10.1145/3357384.3358010](https://doi.org/10.1145/3357384.3358010)]

(校对责编: 张重毅)