

基于邻域与超图协作的会话推荐

陈荣元^{1,2}, 文杰彬^{1,2}, 黄少年³, 何晔宇^{1,2*}

(1. 湖南工商大学前沿交叉学院, 湖南长沙 410205; 2. 湖南工商大学统计学习与智能计算湖南省重点实验室, 湖南长沙 410205;
3. 湖南工商大学计算机学院, 湖南长沙 410205)

摘要: 现有会话推荐模型长于提取用户当前偏好, 但不善于捕捉用户兴趣随时间和情境的动态演变, 难以从短时交互序列数据中提取项目之间的隐性关系. 本文提出了一种基于邻域与超图协作学习会话推荐模型 (Neighborhood and Hypergraph Collaboration for session-based Recommendation model, NHG-Rec), 首先综合利用自适应多跳超图卷积和邻域卷积, 以同时捕捉项目间的显性和隐性关系; 然后利用基于上下文感知的位置动态注意力机制, 来挖掘会话内各项目的重要程度, 从而捕捉用户实时兴趣; 再采用多视图会话嵌入, 通过局部-全局对比学习策略, 以期捕捉项目间的多维特征、辨别语义差异. 实验结果表明: 对于 Tmall、Diginetica、Nowplaying 这 3 个基准数据集, 相比 SR-GNN、GCE-GNN、DHCN 等主流基准模型, 该模型的 P@10、P@20、MRR@10、MRR@20 性能指标分别平均提升了 12.38%、5.47%、6.53%、6.39%. NHG-Rec 模型能够捕捉用户兴趣的动态变化和项目间的多维关系.

关键词: 会话推荐; 超图学习; 邻域卷积; 对比学习; 注意力机制

基金项目: 国家自然科学基金 (No.41101425); 长沙市自然科学基金 (No.kq2402096, No.kq2208056)

中图分类号: TP391.3

文献标识码: A

文章编号: 0372-2112(2025)08-2805-13

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250144

Neighborhood and Hypergraph Collaboration for Session-Based Recommendation

CHEN Rong-yuan^{1,2}, WEN Jie-bin^{1,2}, HUANG Shao-nian³, HE Ye-yu^{1,2*}

(1. College of Frontier Intersection, Hunan University of Technology and Business, Changsha, Hunan 410205, China;

2. Key Laboratory of Hunan Province for Statistical Learning and Intelligent Computation, Hunan University of Technology and Business, Changsha, Hunan 410205, China;

3. School of Computer Science, Hunan University of Technology and Business, Changsha, Hunan 410205, China)

Abstract: Current session recommendation models excel at extracting users' immediate preferences but struggle to capture the dynamic evolution of user interests over time and context, making it challenging to extract latent relationships between items from short-term interaction sequences. This paper proposes a neighborhood and hypergraph collaboration for session-based recommendation model (NHG-Rec), which first comprehensively utilizes adaptive multi-hop hypergraph convolution and neighborhood convolution to simultaneously capture explicit and implicit relationships between items; then employs a context-aware dynamic positional attention mechanism to explore the importance of items within a session, thereby capturing users' real-time interests; further adopts multi-view session embeddings through a local-global contrastive learning strategy to capture multi-dimensional item features and distinguish semantic differences. Experimental results demonstrate that for Tmall, Diginetica, and Nowplaying benchmark datasets, compared to mainstream baseline models such as SR-GNN, GCE-GNN, and DHCN, this model improves P@10, P@20, MRR@10, and MRR@20 performance metrics by an average of 12.38%, 5.47%, 6.53%, and 6.39%, respectively. The NHG-Rec model effectively captures the dynamic changes of user interests and multi-dimensional relationships between items.

Key words: session-based recommendation; hypergraph learning; domain convolution; contrastive learning; attention mechanism

Foundation Item(s): National Natural Science Foundation of China (No.41101425); Changsha Natural Science Foundation (No.kq2402096, No.kq2208056)

1 引言

会话通常指用户在单一购物事件中的一系列行为。如图1所示,用户在购买笔记本电脑的同时,还点击并浏览了键盘、鼠标等相关商品。会话推荐(Session-Based Recommendation, SBR)更多依赖用户短期点击记录,其核心是依据当前会话中的实时行为来预测用户可能感兴趣的下一个商品^[1]。会话推荐可以分为3种,最早的是基于马尔可夫链的传统推荐方法。2005年,Shani等人^[2]采用马尔可夫链来模拟会话中的用户行为转移,以此捕捉时间序列的动态特性。2016年,Hidasi等人^[3]构建了基于循环神经网络(Recurrent Neural Networks, RNNs)的会话推荐模型,通过学习用户行为序列中的内在依赖性,以期有效地预测用户下一步行动。2019年,Wu等人^[4]构建了基于图神经网络(Graph Neural Networks, GNNs)的会话推荐模型,通过将用户的行为序列转化为图结构,有效地揭示了项目间的复杂交互关系。会话中的用户行为在短时间内连续发生,通常这些行为序列之间存在时间上的依赖,因此RNNs通常将其视为单向链。但用户行为序列不具备语言序列的严格时序性。如图1所示,用户可以用两种不同的顺序点击物品:先点击电脑再点击鼠标,先点击鼠标再点击电脑。这两种不同的点击顺序都是对同一组物品的序列化,即背后蕴含着用户相同的偏好。因此,过分强调物品的相对顺序而忽视它们之间的关联性,可能会误判用户偏好。

与基于RNNs的方法相比,GNNs将用户行为序列建模为有向图^[5],放宽了对连续项目间时间依赖性的限制,从而克服了RNNs的单向序列限制^[6]。然而,这类方法不易提取项目间的内在联系和用户实时意图,难以处理多样性和非线性的用户行为^[7]。当两个物品间没有直接联系时,GNNs类模型往往难以提取隐性关系(如啤酒与纸尿裤典例)。其次,在实际应用中,用户对商品的选择往往受之前累积行为的影响,商品间存在复杂的多对多和高阶双向关系。如图1中用户点击了笔记本电脑,后续可以产生两种不同的序列:(笔记本电脑,鼠标,⋯,有线耳机)与(笔记本电脑,键盘,⋯,无线耳机)。虽然鼠标与键盘分别属于不同的会话,但两个会话中均含有同一件物品:笔记本电脑,两者之间可能存在某种高阶关系。有线耳机与无线耳机之间也存在类似的关系。因此,模型应当提取这些物品之间的关系,并将上述物品看作一个新的序列(笔记本电脑,键盘,鼠标,耳机)。然而,传统的图卷积难以提取这种集合性质的关联;如果通过增加节点来提高图结构的描述能力,则会增加模型的计算量。此外,由于会话推荐所依据的短时交互序列蕴含的信息本身非常有限,容易受到数据稀疏性的制约。

超图可以通过超边连接任意数量的节点,因此能够对高阶关系进行建模。然而,超图在SBR的潜力尚未得到充分开发。一方面,高阶关系建模复杂。超图允许通过超边连接任意数量的节点,以建模高阶关系。这种结构在进行节点特征更新时,超边之间的信息流动可能受到限制,这使得连接节点之间的复杂关系难以被充分捕捉。另一方面,多源信息不易聚合。因超边能够连接多个节点,节点间的信息传播会削弱节点与邻居节点的关系。当信息通过超边传播时,节点的信息更新可能受到多个连接节点的影响,这种多源信息的聚合可能导致节点特征的模糊化,进而影响模型对用户行为的准确捕捉。这种现象在处理短时交互序列时尤为明显。因为用户的意图往往依赖于与特定邻居节点的直接交互,而超边的引入可能使得这种直接关系被稀释,从而影响推荐的准确性和个性化程度。

综上所述,目前会话推荐面临以下挑战:(1)模型对用户行为理解的局限性。现有基于RNN和GNN的模型在理解用户行为序列的内在关联和高阶隐性关系方面存在不足。RNNs过度强调时序性,而GNNs难以提取项目间的隐性关联,使得模型难以准确捕捉用户意图。(2)数据稀疏性与信息传递。会话推荐所依赖的短时交互序列信息有限,引发数据稀疏性问题,而超图结构设计不合理,容易放大数据稀疏性问题,进一步加剧了模型理解用户意图的难度,并且超图内部之间的信息传递不合理。



图1 高阶特征与隐式之间关系的示例

为了解决上述挑战,本文提出了一种基于邻域与超图协作学习的会话推荐模型(Neighborhood and Hypergraph Collaboration for session-based Recommendation model, NHG-Rec)。该模型整合了超图卷积与邻域图卷积,旨在深入挖掘会话中物品之间复杂的高阶关系和

用户行为模式. 首先,在构建超图邻接矩阵时,摒弃了传统基于会话归一化的共现图构建方法,改用 PageRank 算法,使得所构建的超图结构更加关注重要节点之间的连接. 其次,使用 K -hop 算法作为邻域图卷积组件,以提取邻近商品间的复杂交互关系和隐性特征. 邻域图卷积通过建模用户行为序列中的显性关系,增强了节点与其邻居之间的信息传递能力,弥补了超图卷积节点信息传递方面的不足,从而更全面地捕捉用户的短期兴趣变化. 接着,结合上下文信息的位置感知动态注意力机制,根据节点信息及序列位置信息动态调整权重,以准确描述用户行为序列之间的相关性,从而提升模型对用户兴趣的刻画精度. 最后,通过局部-全局对比学习策略,捕捉项目间的多维特征并辨别语义差异,以增强特征的有效性,减轻了因数据稀疏性带来的影响. 综上所述,本文主要贡献如下.

(1) 采用了基于 PageRank 算法的超图卷积结合邻域卷积网络. 创新地采用 PageRank 算法构建超图,并首次结合多跳图卷积网络,即超图卷积和集成邻域卷积,挖掘用户与物品、物品与物品的多层次的隐性交互关系,提升了模型捕捉高阶和隐性关系的能力.

(2) 采用了结合上下文信息的位置感知动态注意力机制. 通过结合位置和上下文信息,提升了识别会话内项目重要程度的能力,提高了判断用户偏好的精度,更加准确地捕捉用户兴趣的动态变化.

(3) 进行了集实验验证. 在多个公开数据集上, NHG-Rec 在推荐精度和鲁棒性方面表现出色,显著优于现有先进方法,展示了其在实际场景中的有效性和适应性.

2 相关工作

2.1 基于会话的推荐

会话推荐致力于利用用户点击产生的交互信息和上下文来提高推荐质量. 传统推荐方法通常依赖于用户的历史行为数据,如购买记录和评分. 然而,在动态的会话场景中,用户瞬时意图往往与短期内的行为序列更加相关. 为此,研究者们引入循环神经网络和长短时记忆网络(Long Short Term Memory, LSTM)等序列建模技术,以捕获会话中的序列信息. Hidasi 等人^[8]提出了基于用户会话行为序列模型,该模型将用户会话视为序列数据,通过学习项目间的时间依赖性,使得模型能够感知交互对象之间的时间间隔与用户意图之间的关系,从而准确地刻画用户兴趣. Tan 等人^[9]提出了 HRNN 模型,通过层次化的循环神经网络编码用户行为序列,从而识别用户瞬时兴趣. 此外, Li 等人^[10]提出基于混合编码器的 NARM 模型,利用注意力机制和 GRU (Gated Recurrent Unit) 估算用户近期操作的行为重要

性,识别当前场景下用户的主要意图,进一步改进推荐的即时反应能力. Li 等人^[11]提出动态路由机制,通过动态分配权重自动捕捉用户多个兴趣维度,从而提高推荐的准确性. Sun 等人^[12]提出 SASRec 模型,基于多层自注意力机制来建模用户行为序列,能够灵活地捕获动态兴趣. 尽管这些模型在各自场景中获得了比较好的效果,但还存在如下不足:在处理长序列时,RNN 和 LSTM 常受到梯度消失或爆炸的影响,难以捕捉长期依赖关系;过于关注兴趣偏好和项目顺序转换,难以刻画物品间的内部关系和全局转换,且计算效率不高.

一些学者利用图神经网络整合用户、商品和上下文信息,构建出了更善于表达用户-商品复杂关系的模型. Xu 等人^[13]提出 GC-SAN 模型,利用自注意力网络动态构造会话图,以捕捉更丰富的上下文信息. 随后,出现了多种变体模型. Qiu 等人^[14]提出了 FGNN 模型,运用多头注意力机制聚合邻近节点嵌入,提升了对项目特征表示能力. Zhang 等人^[15]利用动态图神经网络,实时更新用户兴趣表示以反映会话中的动态变化,从而更准确地捕捉用户短期偏好. 为挖掘项目间的高阶关系, Xia 等人^[16]提出了 DHCN 模型,通过综合超图和线性图来捕获项目的高阶特征. 范伟等人^[17]提出 DB-DCAC 模型,该模型利用双通道分别建模全局和局部关系,并结合自适应对比学习优化异构关系表示,能够有效捕捉节点之间的关系. 尽管这些模型在利用图结构信息方面取得了显著进展,但普遍仅用简单图结构描述会话,忽略了邻居节点间的隐性特征,未能充分捕捉会话中的复杂高阶多元和隐性关系.

2.2 注意力机制

2014 年, Bahdanau 等人^[18]首次将注意力机制引入神经网络机器翻译模型中,旨在解决传统编码器-解码器结构对长序列信息捕捉能力不足的问题. 在会话推荐中,注意力机制通常被用来为用户会话中的每个项目分配权重,捕捉用户在会话中的即时兴趣. 注意力机制的引入提高了模型捕捉用户会话序列特征的能力. 例如, Xiao 等人^[19]提出 JLS-Rec 模型,其通过堆叠多种自注意力机制来学习用户近期行为序列的特征转换,从而产生用户当前阶段短期利益的动态表示,能够比较精准地提取用户的即时兴趣. 曾碧卿等人^[20]提出 CEMA 模型,该模型通过多级注意力机制分别在物品级和会话级这两个粒度上学习物品特征和用户偏好,以增强模型的个性化推荐能力. 钱忠胜等人^[21]提出 SAMBGCL 模型,通过融合自注意力机制和多行为图对比学习,有效缓解了目标行为稀疏性问题,并显著提升了推荐性能. 这些模型均巧妙地融入了注意力机制,以提升模型对用户意图的理解与刻画. 虽然这类模型在捕捉用户兴趣方面展现出了显著优势,然而,它们仍然存

在一些局限性:首先,这些模型大多依赖于单一视图的用户行为建模,未能充分整合全局和局部信息,难以全面刻画用户的兴趣偏好.并且该类注意力机制在处理短时交互序列时,可能会因缺乏足够的上下文信息而导致权重分配不够准确,从而影响推荐效果.此外,这些模型在捕捉用户兴趣的动态演变时,往往忽略了跨会话的长期兴趣关联,无法有效建模用户在不同情境下的行为模式.

2.3 多跳超图学习

超图学习是图神经网络的一个扩展方法,它能够更自然地表示多元组关系,允许一条超边连接多个节点,从而可以更灵活地对复杂关系进行建模.近几年,得益于超图在复杂关系建模方面的卓越表现,研究者们纷纷将超图理论应用于会话推荐系统,并取得了一系列令人瞩目的成果. Ding 等人^[22]提出 HyperS²Rec 模型,该模型分别使用超图卷积网络和门控循环单元学习两种项目嵌入,利用注意力机制灵活地组合上述两种嵌入,以解释一致性感知和顺序依赖感知. Khan 等人^[23]提出 HHGSA 模型,该模型利用超图对用户的 5 个维度进行建模,并利用 attentive vertex 和 attentive hyper-edge 两个聚合模块,捕获用户和项目的注意力. Chen 等人^[24]提出 MoHyNet 模型,该模型基于超图卷积建模用户之间的高阶关系,并利用超图主题描述用户的行为模式,从而增强了会话间的信息挖掘.然而,尽管这些研究在利用超图结构方面取得了进展,但它们普遍存在一个局限:未能充分考虑超边之间的传递效应以及节点在超图中的重要性差异.在构建超图邻接矩阵时,现有方法大多采用基于会话归一化的共现图构建策略,其核心思想是通过归一化会话长度来平衡来自不同节点的贡献,使得信息聚合过程更加公平合理.然而,这种方法过于追求公平性,忽略了不同物品在会话场景下的重要性差异.它仅仅基于物品的共现关系来构建图结构,而忽略了会话的上下文信息,这使得模型无法捕捉到物品之间更为复杂和微妙的关系.为了克服上述局限,本文提出一种新颖的超图构建方法.该方法通过融入 PageRank 算法,既可以解决节点在超图中的重要性评估问题,又能有效利用会话上下文信息,从而更准确地捕捉物品之间的复杂关系,提升会话推荐的性能.同时,通过后继的 K -hop 算法能够捕捉超图中远距离节点间的潜在关系,挖掘多跳路径中的交互信息,这有利于细粒度建模远端关系. K -hop 算法还可以缓解多跳信息引起的过平滑问题,保持节点的独特性和多样性.目前,将 K -hop 算法和 PageRank 算法融入超图用于会话推荐的研究尚属空白.

3 NHG-Rec 模型

本节首先介绍本文模型 NHG-Rec 的整体框架,如图 2 所示,主要包含以下几个模块.

(1) 基于多跳机制的图卷积网络模块. 该模块通过超图卷积和集成邻域卷积,挖掘用户与物品、物品与物品的多层次的隐性交互关系,提升模型捕捉高阶和隐性关系的能力,实现对节点特征的深层次挖掘和关系建模.

(2) 基于上下文位置感知的动态注意力模块. 该模块旨在利用用户会话中的具体上下文信息和项目在会话中的位置关系,为每个项目分配权重,从而动态捕捉用户兴趣和行为的特征变化. 该模块通过结合位置编码与上下文特征,使模型能够更细粒度地捕捉会话内项目的重要性,并刻画用户的短期动态兴趣.

(3) 多视图全局-局部对比学习模块. 该模块通过建模全局视图和局部视图之间的特征关系,优化模型对多维特征的表达能. 该模块旨在学习会话内部(局部视图)以及跨会话(全局视图)的项目关系特征,并利用对比学习策略对齐不同层级特征,从而捕捉用户的短期意图与长期兴趣,同时提升模型区分语义差异的能力.

3.1 超问题定义与符号说明

设 $U = \{u_1, u_2, u_3, \dots, u_N\}$ 表示物品集合,其中 N 为物品个数. 每个会话表示为一个集合 $v = \{u_{1,v}, u_{2,v}, u_{3,v}, \dots, u_{k,v}, \dots, u_{l,v}\}$, 其中 $u_{k,v} \in U (1 \leq k \leq l)$ 表示匿名用户在会话 v 中交互过的物品. 为了学习物品和会话的向量表示,将每个物品 $u \in U$ 嵌入到同一空间中,并令 $x_u^{(l)} \in \mathbb{R}^{d^{(l)}}$ 表示第 l 层网络中物品 u 的向量表示. 整个物品集合的表示记为 $X^{(l)} \in \mathbb{R}^{N \times d^{(l)}}$. 会话推荐的目的是预测给定会话中用户点击的下一项物品 $u_{v,l+1}$.

3.2 多视图建模

针对现有模型不善于提取邻近节点之间的复杂关系,本文引入超图视图,并设计邻居图视图,以期全面捕捉项目间的复杂高阶和隐性关系. 超图视图描述物品间的高阶关系,邻居图视图描述项目间的隐性关系. 同时引入 K -hop 算法来提取邻居节点间的关系. 记超图为 $G_h = (V, E)$, 其中 V 代表节点集; E 为超边集,每条边连接两个以上的物品,边上权重表示物品之间的关联强度. 该视图表示为一个关联矩阵 $H \in \mathbb{R}^{N \times M}$, M 表示超边数,每个顶点和每条边的度矩阵分别表示为对角矩阵 $D_u \in \mathbb{R}^{N \times N}$ 和 $D_e \in \mathbb{R}^{M \times M}$. 记邻居间视图为 $G_n = (V_{nei}, E_{nei})$, 其中 V_{nei} 为所有邻居节点的集合, E_{nei} 为边的集合. 当两个项目之间存在边时,则意味着这两个项目

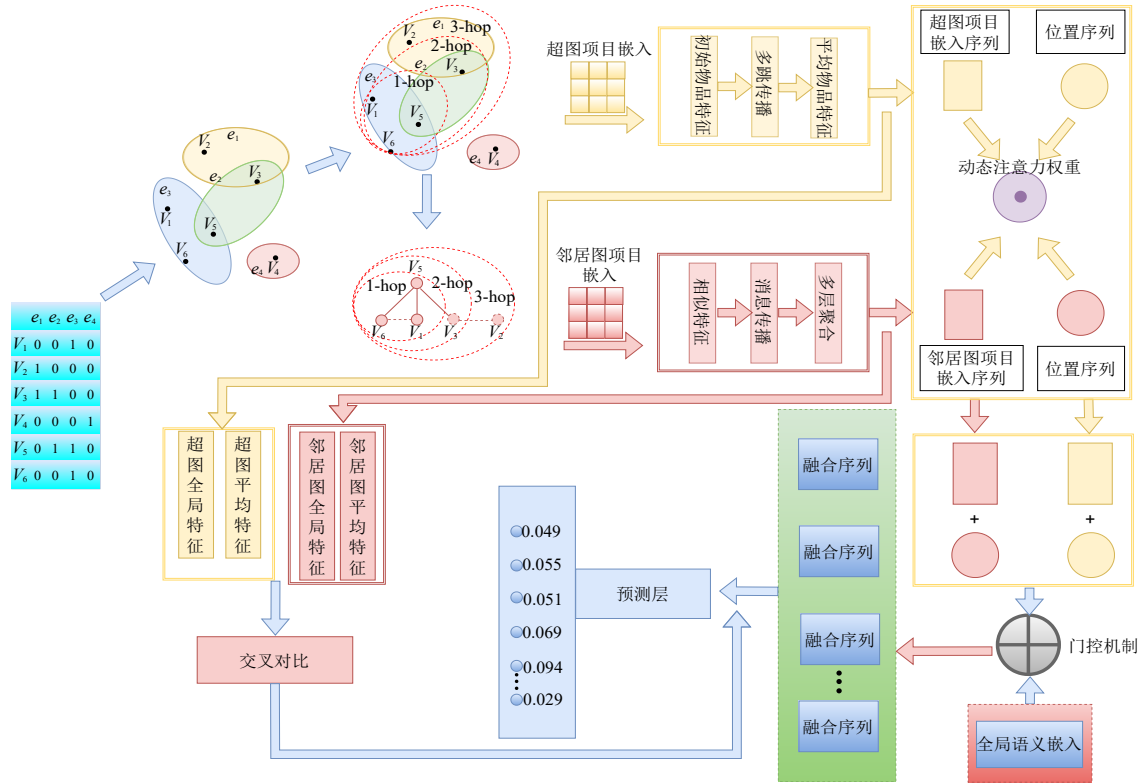


图2 NGH-Rec模型的整体框架图

在某一会话中紧密相连. 每条边均带有权重系数, 权重可根据两个项目共同出现的频率计算.

3.3 基于多跳机制的超图卷积

本文综合利用超图结构和 K -hop 算法来提取项目间的高阶信息, 以全面捕捉项目间的复杂高阶关系和隐性特征. K -hop 算法中的卷积可以提取节点多跳范围内的邻居信息, 在超图结构上进行“节点-超边-节点”的邻居节点间的两阶段信息挖掘, 以捕获更深层次的节点间关系和全局结构信息, 不同于传统超图卷积中对节点和超边进行对称归一化的方法, 本文在构建超图邻接矩阵时引入了基于 PageRank 的节点重要性加权策略, 以增强重要节点对特征传播的主导作用, 从而提高模型对高阶信息的建模能力. 超图的邻接矩阵计算公式为

$$A = P \cdot H \cdot D_e^{-1} \cdot H^T \quad (1)$$

其中, $P \in \mathbb{R}^{N \times N}$ 是通过 PageRank 算法得出的对角矩阵, 其对角线元素是节点的 PageRank 值, 用于表示节点重要性. 通过 $(H \cdot D_e^{-1}) \cdot H^T$ 实现了“节点-超边-节点”的信息聚合. 融入 K 跳算法的模型定义为

$$X_{hg}^{(l+1)} = W_l^{(l)} \cdot A^k \cdot X_{hg}^{(l)} \quad (2)$$

其中, $X_{hg}^{(l)}$ 为第 l 层的物品嵌入, $W_l^{(l)}$ 为第 l 层的参数矩

阵, $k \in [1, K]$ 为跳数, 表示在每一层中应用单步超图卷积 k 次, 捕捉 k 跳范围内的关系.

值得注意的是, 尽管本文移除了显式的非线性激活函数, 但模型仍然能够学习复杂的非线性关系. 这是因为多跳传播过程本身就包含了非线性变换, 每一跳都可以看作是对前一跳结果的非线性变换, 经过多次迭代后, 模型就能拟合高度复杂的函数关系. 为了进一步增强模型的表达能力, 在多跳卷积的基础上引入了多尺度融合. 多尺度融合连接允许梯度直接流向较浅的层, 缓解了深层网络中的梯度消失问题, 并且可以保留原始输入的信息. 修改后的更新规则为

$$X_{hg_final} = \frac{1}{L+1} \left(X_{hg}^{(0)} + \sum_{l=1}^L X_{hg}^{(l)} \right) \quad (3)$$

其中, X_{hg_final} 为最终的卷积结果, $X_{hg}^{(0)}$ 为原始的输入信息, L 表示卷积层总层数.

3.4 基于多跳机制的邻域图卷积

以往模型更多依赖显性关系 (如直接的项目点击序列), 而忽略了项目之间隐性关系的深层次特征. 为了更好地提取邻近节点间的这种关系, 本文设计了邻居图卷积, 以全面捕捉邻近节点间的隐性关系. 这里借用了上文中超图的关联矩阵计算邻域图的邻接矩阵,

当两个项目在会话中多次共现,则用一条边将它们关联起来,并用权重系数表示它们共同出现的频率,且引入阈值机制来权衡重要连接信息和计算量.当某条边上的权重系数小于预设阈值,则将其视为无用信息舍弃.在此基础上,应用K-hop算法来捕捉更远距离的节点间潜在关系.邻域图卷积的核心操作可以表示为

$$\mathbf{A}_{\text{nei}} = \mathbf{H} \cdot \mathbf{H}^T \quad (4)$$

$$X_{\text{nei}}^{(l+1)} = \mathbf{A}_{\text{filtered}}^k \cdot X_{\text{nei}}^{(l)} \quad (5)$$

其中, \mathbf{A}_{nei} 为邻域图的邻接矩阵, \mathbf{H}^T 表示 \mathbf{H} 的转置矩阵, $X_{\text{nei}}^{(l)}$ 和 $X_{\text{nei}}^{(l+1)}$ 分别为邻域图卷积第 l 层和第 $l+1$ 层的嵌入, $\mathbf{A}_{\text{filtered}}^k$ 是经过 k 跳算法和过滤处理后的邻接矩阵.同样,为了融合多尺度特征,缓解梯度消失,采用多层卷积的均值表示项目间的关系:

$$X_{\text{nei}_{\text{final}}} = \frac{1}{L+1} \left(X_{\text{nei}}^{(0)} + \sum_{l=1}^L X_{\text{nei}}^{(l)} \right) \quad (6)$$

其中, $X_{\text{nei}_{\text{final}}}$ 为邻域图卷积最终的结果.

3.5 基于上下文信息的位置感知动态注意力机制

为了更精确地捕捉用户在会话中的动态兴趣变化,本文在生成会话嵌入时,引入了融合上下文信息的位置感知动态注意力机制.为了平衡模型对会话中最后一项物品的权重,引入了超参数权重 λ .如图3所示,模型融合了位置感知动态注意力和上下文感知自适应注意力两种生成会话嵌入方法,利用注意力机制来融合不同位置的项目信息.模型中的双通道都含有此模块,这里以超图通道为例.结合位置编码和项目表示的隐藏层状态 n_h ,定义如下:

$$n_h = \mathbf{W}_2 \left(\left[p_{\text{emb}}; X_{\text{hg}_{\text{final}}} \right] \right) \quad (7)$$

其中, $;$ 表示拼接操作, p_{emb} 是位置编码序列, $X_{\text{hg}_{\text{final}}}$ 是超图卷积得到的项目序列, \mathbf{W}_2 是可学习的权重矩阵.通过门控线性单元融合注意力权重和项目序列信息,更新隐藏层状态:

$$g_1 = \mathbf{W}_{g1} \cdot n_h + b_{g1} \quad (8)$$

$$g_2 = \mathbf{W}_{g2} \cdot X_{\text{hg}_{\text{final}}} + b_{g2} \quad (9)$$

$$n_h' = \sigma(g_1 + g_2) \quad (10)$$

其中, \mathbf{W}_{g1} 和 \mathbf{W}_{g2} 是门控线性单元的权重矩阵. b_{g1} , b_{g2} 为门控单位的偏置项, σ 为 sigmoid 激活函数.最后,计算注意力分数并应用于序列:

$$\lambda = n_h' \cdot \mathbf{W}_3 \quad (11)$$

$$\text{mask}_{\text{combined}} = \text{mask}_{\text{valid}} + \text{mask}_{\text{last}} \quad (12)$$

$$h_{\text{hg}} = \sum_{i=0}^{l-1} \lambda[i] \cdot X_{\text{hg}_{\text{final}}}[i] \cdot \text{mask}_{\text{combined}}[i] \quad (13)$$

其中, λ 为最终注意力权重, \mathbf{W}_3 是可学习的权重向量,用于计算注意力权重的参数, $\text{mask}_{\text{valid}}$ 为有效位置的掩码, $\text{mask}_{\text{last}}$ 为最后一项物品的权重掩码,仅在最后一个

位置为有效权重,其余位置均为0, $\text{mask}_{\text{combined}}$ 为合并掩码,有效掩码与最后一项权重掩码之和, h_{hg} 是超图通道最终的会话嵌入, $i \in [0, l-1]$ 表示序列中第 $i+1$ 个物品的位置索引, l 为最大序列长度.

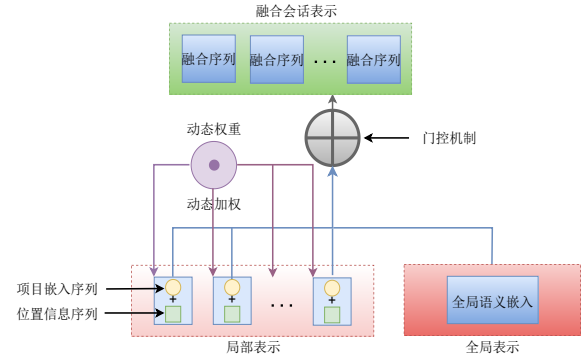


图3 基于上下文信息的位置感知动态注意力框架图

3.6 全局-局部对比学习建模

稀疏性的数据限制了模型的泛化能力与节点表现效果,而全局-局部对比学习通过融合局部特征与全局语义信息,结合多视图嵌入的对比机制来实现用户行为建模,能够更加精准地提取项目之间和用户行为之间的特征关系,从而有效提升模型的表现.受对比学习在简单图上成功实践的启发,本文将全局-局部多视图对比学习整合到网络中以增强多视图建模效果,设计了全局-局部多视图对比学习模型.通过两个通道学习4组特定的会话嵌入以创建多视角特征的对齐与互补,显式建模用户行为在局部细节与全局上下文中的一致性,从而增强推荐模型对复杂行为、隐性关联和多层次兴趣的捕捉能力.局部视图代表用户在某一具体会话中局部点击序列或商品邻域间的直接信息,侧重于用户短期行为特征,而全局视图则基于用户的整体行为模式,通过超图、长期交互场景建模商品之间的全局语义,代表用户长期兴趣偏好的整体嵌入.对于训练中每个 mini-batch,会话嵌入组之间存在对应关系.这些嵌入能够作为自监督学习过程中相互参照,实现自我监督.具体而言,对于超图通道的会话嵌入 $h_{\text{hg}} = \{x_{\text{hg},1}, x_{\text{hg},2}, \dots, x_{\text{hg},B}\}$ (其中 B 为批处理大小) 和邻域图通道的会话嵌入 $h_{\text{nei}} = \{x_{\text{nei},1}, x_{\text{nei},2}, \dots, x_{\text{nei},B}\}$,其全局表示分别计算为

$$\text{Global}_{\text{hg}} = \frac{1}{B} \sum_{i=1}^B x_{\text{hg},i} \quad (14)$$

$$\text{Global}_{\text{nei}} = \frac{1}{B} \sum_{i=1}^B x_{\text{nei},i} \quad (15)$$

其中, $\text{Global}_{\text{hg}}$ 和 $\text{Global}_{\text{nei}}$ 分别为超图视图和邻域图视图的全局表示.对于每个视图,首先对局部嵌入和全局

表示进行 L_2 归一化:

$$\hat{x}_{hg,i} = \frac{x_{hg,i}}{\|x_{hg,i}\|_2} \quad (16)$$

$$\widehat{\text{Global}}_{hg,i} = \frac{\text{Global}'_{hg,i}}{\|\text{Global}'_{hg,i}\|_2} \quad (17)$$

$$\hat{x}_{nei,i} = \frac{x_{nei,i}}{\|x_{nei,i}\|_2} \quad (18)$$

$$\widehat{\text{Global}}_{nei,i} = \frac{\text{Global}'_{nei,i}}{\|\text{Global}'_{nei,i}\|_2} \quad (19)$$

对于超图视图,正样本为 $(\hat{x}_{hg,i}, \widehat{\text{Global}}_{hg,i})$,负样本为 $(\hat{x}_{hg,j}, \widehat{\text{Global}}_{hg,j})$ (其中 $j \neq i$). 通过交叉熵损失计算:

$$\text{Loss}_{hg} = -\frac{1}{B} \sum_{i=1}^B \log \left(\frac{\exp\left(\frac{1}{\tau} \langle \hat{x}_{hg,i}, \widehat{\text{Global}}_{hg,i} \rangle\right)}{\sum_{i=1}^B \exp\left(\frac{1}{\tau} \langle \hat{x}_{hg,j}, \widehat{\text{Global}}_{hg,j} \rangle\right)} \right) \quad (20)$$

其中, τ 为温度参数,控制相似度分布的陡峭程度, \langle, \rangle 表示内积运算. 同理,邻域图视图的局部-全局损失为

$$\text{Loss}_{nei} = -\frac{1}{B} \sum_{i=1}^B \log \left(\frac{\exp\left(\frac{1}{\tau} \langle \hat{x}_{nei,i}, \widehat{\text{Global}}_{nei,i} \rangle\right)}{\sum_{i=1}^B \exp\left(\frac{1}{\tau} \langle \hat{x}_{nei,j}, \widehat{\text{Global}}_{nei,j} \rangle\right)} \right) \quad (21)$$

为增强超图视图与邻域图视图的一致性,引入交叉视图对比,即计算超图局部嵌入与邻域图全局表示的损失,以及邻域图局部与超图全局表示的损失:

$$L_{\text{cross1}} = -\frac{1}{B} \sum_{i=1}^B \log \left(\frac{\exp\left(\frac{1}{\tau} \langle \hat{x}_{hg,i}, \widehat{\text{Global}}_{nei,i} \rangle\right)}{\sum_{i=1}^B \exp\left(\frac{1}{\tau} \langle \hat{x}_{hg,j}, \widehat{\text{Global}}_{nei,j} \rangle\right)} \right) \quad (22)$$

$$L_{\text{cross2}} = -\frac{1}{B} \sum_{i=1}^B \log \left(\frac{\exp\left(\frac{1}{\tau} \langle \hat{x}_{nei,i}, \widehat{\text{Global}}_{hg,i} \rangle\right)}{\sum_{i=1}^B \exp\left(\frac{1}{\tau} \langle \hat{x}_{nei,j}, \widehat{\text{Global}}_{hg,j} \rangle\right)} \right) \quad (23)$$

全局-局部对比学习的总损失为内视图损失与跨视图损失的加权和:

$$L_{\text{ssl}} = \text{Loss}_{hg} + \text{Loss}_{nei} + L_{\text{cross1}} + L_{\text{cross2}} \quad (24)$$

3.7 模型预测与推荐算法

3.7.1 模型预测层

本文的推荐目标是预测给定会话中用户点击的下一项物品 $u_{v,m+1}$,模型的预测分数表示模型对每个候选物品的置信度,本文通过在超图通道学习到的会话嵌入 h_{hg} 和项目嵌入 X_{hg} 内积得到分数,应用 softmax 函数计算每个项目成为会话下一个项目的概率

$$\text{Score} = \text{softmax}(h_{hg} \cdot X_{hg}^T) \quad (25)$$

其中, X_{hg}^T 表示 X_{hg} 的转置,训练过程中使用交叉熵损失函数作为训练任务损失

$$L_{\text{rec}} = -\sum_{i=1}^N \left[y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \right] \quad (26)$$

其中, y_i 是真实标签的独热编码向量, \hat{y}_i 是模型预测值.

最后,将推荐任务和自监督任务统一到联合学习框架中,总的损失函数为

$$L_{\text{total}} = L_{\text{rec}} + \beta L_{\text{ssl}} \quad (27)$$

其中, β 是控制对比学习任务强度的超参数.

3.7.2 推荐算法

NHG-Rec 是一种面向会话推荐任务的图神经网络模型,通过结合全局高阶信息和局部邻域信息,全面建模项目间的复杂关系. 模型利用位置嵌入和注意力机制,生成用户会话的动态表征,同时引入对比学习模块,通过局部-全局及多视图对比,提升会话嵌入的鲁棒性. 基于预测分数矩阵,模型能够通过交叉熵损失和对比损失的联合优化,高效捕捉用户行为模式,具体过程见算法 1.

算法 1 NHG-Rec 模型训练流程

输入: 用户和商品的历史交互记录 $v = \{u_{1,v}, u_{2,v}, u_{3,v}, \dots, u_{k,v}, \dots, u_{l,v}\}$

输出: 模型结果评价指标

BEGIN

1. 构建视图: 构建超图 $G_h = (V, E)$, 其中 V 为节点集, E 为超边集, 邻域图 $G_n = (V_{nei}, E_{nei})$, 其中 V_{nei} 为节点集, E_{nei} 为边集, 边权重表示共现频率.

2. 初始化变换层参数 $P \in \mathbb{R}^{d \times d}$ 和 $Q \in \mathbb{R}^{d \times d}$ 为超图卷积和邻域图卷积的相关参数.

3. WHILE 模型未收敛 DO:

4. 从 H 中采样一批交互记录 H^B

5. 超图卷积模块: 在 G_h 中为 H^B 的每个用户交互采样 K -hop 邻居. 通过“节点-超边-节点”的两阶段信息挖掘,生成初始表征.

6. 邻域图卷积模块: 在 G_n 中为 H^B 的每个用户采用 K -hop 邻居, 并应用阈值机制过滤低权重边,捕捉隐性关系.

7. 动态注意力模块: 结合位置编码和上下文特征,生成会话内项目的重要性权重.

8. 多视图对比学习模块: 建模全局视图和局部视图的特征关系. 通过对比学习对齐全局和局部特征,捕捉语义差异.

9. 计算损失: 联合优化交叉熵损失和对比损失,更新各个指标

10. END WHILE

11. 输出最终评价指标

12. END

NHG-Rec 模型主要通过超图和邻域图的协同优化实现会话推荐,输入为用户和商品的历史交互记录 v ,输出为用户的 Top- k 推荐列表,用于生成个性化推荐结果. 首先分别构建超图 G_h 和邻域图 G_n ,用于捕捉用户

与商品间的高阶关系和共现频率关系,并初始化变换层参数和相关卷积参数.在模型训练循环中,从交互记录中随机采样小批次数据 B ,依次通过超图卷积模块生成初始表征,通过邻域图卷积模块进一步过滤低权重边以捕捉隐性关系,接着使用动态注意力模块结合位置编码和上下文生成会话内项目的重要性权重,并通过多视图对比学习模块对齐全局和局部视图特征,提升语义一致性.最后,计算交叉熵损失和对比损失,优化模型参数并生成最终的推荐评价指标.

3.7.3 时间复杂度分析

NHG-Rec 的总体运行时间可以分为“图卷积-建模”“会话表征”与“打分-预测”3个阶段.首先,双分支图卷积阶段会在 L 个传播层内对每条边进行 K 次稀疏矩阵-向量乘积,两条分支并行执行一次即可完成一次前向传播.因此,该阶段的时间开销等价于 $2 \times L \times K \times M \times d$,可写作 $O(LKMd)$,其中 M 为邻接矩阵的非零元素数, d 为嵌入维度.其次,会话表征阶段会把 B 条会话的 I 个点击依次映射成向量并计算门控注意力,再额外构造 $B \times B$ 的相似度矩阵做对比学习,综合起来的代价近似为 $O(BId) + O(B^2d)$.最后的打分-预测阶段,将每个会话向量同 N 个候选物品嵌入做一次全量矩阵乘,再在每行结果里取前 k 个最高分,这一过程的复杂度是 $O(BNd)$,而维护 k 位小顶堆只带来 $O(BM \log k)$ 的附加量级,因 $\log k$ 与 d 同阶可并入前者.将三段开销相加可得到 NHG-Rec 的总体时间复杂度 $O(LKMd + Bid + B^2d + BNd)$.

4 实验设计与分析

为测试所提模型 NHG-Rec 的性能,在3个公开数据集上进行了系统性的实验,并对实验结果进行了详细分析.实验不仅评估了 NHG-Rec 的整体效果,还与现有的主流会话推荐模型进行了详细对比,验证了模型的优势和稳健性.此外,还通过消融实验对 NHG-Rec 的各个核心组件进行了逐项剖析,探讨了每个模块对模型性能的具体贡献,旨在揭示其关键作用和机制.本实验是在 Linux 操作系统下,处理器为 Intel(R) Xeon(R) CPU E5-2620 v4 @ 2.10GHz,运行内存为 94 GB,显卡型号为 NVIDIA GeForce RTX2080Ti,显存为 11019MiB,实验中使用的是 Python 3.10 编程语言,深度学习计算框架为 Pytorch 1.11.0+cuda11.5 版本.

4.1 数据集及预处理

本文的数据集为 Tmall、Diginetica、Nowplaying. Tmall 来自 IJCAI-15 竞赛,包含天猫平台购物日志, Diginetica 来自 CIKM Cup 2016, Nowplaying 描述了用户音乐收听行为.数据预处理包括删除单物品会话和低频物品(出现次数 <5).采用时间戳法对数据集进行划分,以

最新数据向前推一周为界,之前为训练集,之后为测试集,并从训练集随机抽取 10% 作为验证集.最后对数据集进行扩充和标记,即将一个会话 $v = \{u_{1,v}, u_{2,v}, \dots, u_{L,v}\}$ 拆分为 $([u_{1,v}], u_{2,v}), \dots, ([u_{v,1}, u_{2,v}, \dots, u_{L-1,v}], u_{L,v})$,其中每个会话序列的标签均为该会话的最后一项物品.3个数据集的统计信息如表1所示.

表1 数据统计表

数据集	训练集	测试集	物品	平均长度
Tmall	351 268	25 898	40 728	6.69
Diginetica	719 470	60 858	43 097	5.12
Nowplaying	825 304	89 824	60 417	7.42

4.2 基线模型

根据会话推荐系统领域从传统方法到深度学习方法演变过程,本文共选用了1个传统方法、2个基于 RNN、5个基于 GNN、3个基于超图建模,共11个基线模型与 NHG-Rec 作比较.

(1)FPMC^[25]:基于一阶马尔可夫链模型,该模型结合了会话序列中的顺序关系和用户偏好.

(2)NARM^[9]:基于 GRU 并融合注意力机制的模型,该模型捕获用户在会话中的动态兴趣变化,实现顺序与兴趣的有效建模.

(3)STAMP^[26]:基于短期注意力机制的模型,该模型从长会话中提取用户的真实兴趣,关注用户近期的行为特征.

(4)SR-GNN^[4]:基于图结构会话推荐模型,该模型应用门控图神经网络学习嵌入表示,以增强对会话关系的捕获能力.

(5)FGNN^[13]:基于门控图神经网络分类模型,该模型将下一个物品推荐作为一个图分类问题.

(6)GCE-GNN^[27]:结合图注意机制的模型,该模型将会话构建为局部图和全局图,加入反向位置信息,结合图注意力网络学习物品嵌入.

(7)DHCC^[15]:基于双通道卷积模型,该模型通过双通道学习物品转换关系,引入自监督学习作为辅助任务.

(8)Disen-GNN^[28]:基于独立因素表示物品模型,该模型利用独立因素表示每个物品.从因子级别学习物品嵌入.

(9)Att-Mixer^[29]:基于多层次注意力混合网络模型,利用概念视图和实例视图实现对项目转换的多层次推理.

(10)HyperS²Rec^[21]:基于超图卷积网络和门控循环单元模型,通过学习物品的一致性感知和序列依赖感知嵌入,并设计注意力机制组合以上两种嵌入.

(11)RHC-CRR^[30]:基于面向重复性构建超图和面

向共现性重构排名的推荐模型,通过构建重复项目超边、重构位置信息排名以注入会话间协同信息.

4.3 评估指标

使用 $P@K$ (precision) 和 $MRR@K$ (Mean Reciprocal Rank) 来评估模型的预测结果. $P@K$ 代表目标商品在召回列表中的比例. $MRR@K$ 代表目标商品在召回列表中的位置,越靠前分值越高.

$$P@K = \frac{n_{hit}}{N} \quad (28)$$

$$MRR@K = \frac{1}{N} \sum_{i=1}^N \frac{1}{rank_i} \quad (29)$$

其中, n_{hit} 表示目标商品在 Top- k 列表中的数量, $rank_i$ 表示目标商品 i 在 Top- k 列表中的位置.

4.4 参数设置

本文设置嵌入维度和批次数量经过多次实验得出最佳维度和批次都为 150. 其余模型超参数均采用网格搜索策略寻找最佳参数,其中,正则化系数 ($L2$) 的搜索范围为 $\{1 \times 10^{-4}, 1 \times 10^{-5}, 1 \times 10^{-6}\}$, 模型学习率 (lr) 的搜索范围为 $\{0.1, 0.01, 0.001, 0.0001\}$, 网络层数 (layer) 的搜索范围为 $\{1, 2, 3\}$, 最后一个物品的超参数权重 (ls) 的搜索范围为 $\{0.3, 0.4, 0.5, 0.6\}$, 温度参数 (τ)、权重系数 (β) 通过大量实验和模型调试,最后确定的网格搜索范围为 $\{0.1, 0.2, 0.3, 0.4, 0.5\}$. 对模型其他参数初始化使用一个平均值为 0、标准差为 0.1 的高斯分布. 基线模型则采用每个模型的最佳表现参数.

4.5 实验结果与分析

实验结果如表 2 所示,其中粗体为本文的结果,下划线显示基线模型最优结果. 从表 2 可看出:循环神经网络模型 (如 NARM、STAMP) 在会话推荐任务中表现出色,明显优于传统模型不考虑顺序依赖性的方法 (如 FPMC). 这说明物品在序列中的顺序对推荐效果有着较为重要的影响,需要重点关注,同时还需考虑用户意图的动态变化. NARM 和 STAMP 采用循环单元编码用户行为结合注意力机制,能够比较精准地捕获用户兴趣,获得了比较好的推荐性能. 这表明为会话中不同项目赋予相应的权重,相比传统模型更能准确捕捉用户意图,从而提高推荐效果. 基于图神经网络的模型 (如 SR-GNN、FGNN、GCE-GNN、DHCN、Disen-GNN 等模型) 的推荐效果,相比传统模型和 RNN 模型普遍效果更好. SR-GNN 和 FGNN 将每个会话建模为子图,应用门控图神经网络学习嵌入表示,效果普遍得到提高,证实了图建模比序列建模更善于表示物品间的复杂关系. GCE-GNN 和 Disen-GNN 进一步丰富了图建模,探索了当前会话之外的物品转换关系,提升了对物品间复杂关系的提取能力. 这表明物品在全局层面的转换信息对推荐也有帮助. DHCN、RHC-CRR、HyperS²Rec 利用双视图、超图对用户-物品之间的关系进行建模,有效提取了二者之间的高阶和低阶关系,进一步提升效果. 这表明通过不同的视图建模也能提升推荐效果.

表 2 基线模型在 3 个数据集上的性能

单位: %

模型	Tmall				Nowplaying				Diginetica			
	P@10	MRR@10	P@20	MRR@20	P@10	MRR@10	P@20	MRR@20	P@10	MRR@10	P@20	MRR@20
FPMC (2010)	13.10	7.12	16.06	7.32	5.28	2.68	7.36	2.82	15.42	6.20	22.14	6.66
NARM (2017)	19.17	10.42	23.30	10.70	13.60	6.62	18.59	6.93	35.44	15.13	48.32	16.00
STAMP (2018)	22.63	13.12	26.47	13.36	13.22	6.57	17.66	6.88	33.98	14.26	46.62	15.13
SR-GNN (2019)	23.41	13.45	28.04	13.60	14.17	7.15	19.38	7.78	36.86	15.52	52.49	18.39
FGNN (2019)	20.67	10.07	25.24	10.39	13.89	6.80	18.78	7.15	37.72	15.95	50.58	16.84
GCE-GNN (2020)	28.01	15.08	33.42	15.42	<u>15.67</u>	8.03	22.37	8.06	38.09	16.45	54.06	19.04
DHCN (2021)	26.22	14.60	31.42	15.05	15.35	7.85	<u>23.08</u>	8.18	38.01	16.03	53.66	18.51
Disen-GNN(2023)	26.58	14.82	31.56	15.31	15.09	8.06	22.47	8.22	38.13	16.39	53.49	18.99
Att-Mixer(2023)	<u>28.04</u>	<u>15.93</u>	33.36	<u>16.30</u>	15.62	<u>8.47</u>	22.62	<u>8.67</u>	40.44	17.62	53.93	18.55
HyperS ² Rec(2023)	27.26	14.98	32.91	15.39	15.53	8.12	22.54	8.51	<u>40.52</u>	<u>18.52</u>	<u>55.39</u>	<u>19.43</u>
RHC-CRR(2024)	27.50	15.24	<u>35.09</u>	15.89	15.58	8.08	22.67	8.43	39.68	18.04	54.65	19.16
NHG-Rec	31.89	18.36	37.86	18.92	18.16	8.61	24.76	8.84	43.57	19.02	56.07	19.65
Gain	13.73	15.25	7.89	16.07	15.89	1.65	7.28	1.96	7.53	2.70	1.23	1.13

本文提出的 NHG-Rec 模型在会话推荐任务中展现了更优的性能,充分验证了其设计的有效性. 通过不同的视图建模, NHG-Rec 不仅能够有效提取会话序列中

的低阶直接关系信息,还深入挖掘了复杂高阶的全局物品转换信息. 结合低阶和高阶信息的建模方式,显著增强了物品间复杂关系的表达能力,更精准地捕获用

户行为和兴趣偏好. 具体而言, NHG-Rec 通过构建高效且全面的图结构, 充分利用物品的多层次交互关系, 与传统的序列性建模方法相比, 显著提升了对物品序列顺序依赖性的捕获能力, 同时改进了全局物品关系的建模效果. 实验结果表明, 在多个数据集上, NHG-Rec 的评价指标均超越了其他基线模型, 特别在 Tmall 数据集上提升明显, 因为其在真实电商环境下收集的, 较另外两个数据集拥有较高的一致性. 在该数据集的 $P@20$ 和 $MRR@20$ 指标上分别取得了 37.86% 和 18.92% 的结果, 相较于传统模型 FPMC 在 $P@20$ 指标上提升了 135.74%, 相较于 RNN 类模型 NARM 也提高了 62.49%, 说明该模型能够更好地捕捉物品间的依赖关系和用户行为序列特性. 在基于超图类模型中, 效果也一样得到提升, 说明 NHG-Rec 也能更好地提取用户-物品之间的复杂关系. 在复杂度较高的 Nowplaying 数据集上, NHG-Rec 依托高阶全局物品关系建模和会话外信息的引入, $P@10$ 和 $MRR@20$ 分别达到了 18.16% 和 8.61%, 明显优于循环神经网络模型 (如 NARM 和 STAMP) 及图模型 (如 GCE-GNN 和 DHCN). 在 Diginetica 数据集中, NHG-Rec 的 $P@20$ 和 $MRR@20$ 进一步取得了 56.07% 和 19.65% 的最高分, 相较于基线最优模型 HyperS²Rec 分别提升了 1.23% 和 1.13%, 充分证明了其建模物品复杂关系和捕获用户动态意图的能力. 此外, NHG-Rec 通过动态调整全局-局部对比学习信号优化了推荐性能, 弥补了传统方法对序列信息建模的不足, 在无需额外数据的情况下有效提升了推荐效果且计算开销不大. 综上所述, NHG-Rec 能够精准建模物品的顺序依赖性和上下文全局信息, 同时对用户的动态偏好变化更加敏感, 其全面整合低阶路径依赖和高阶全局转换信息的能力, 使其对复杂数据展现了强大的适应性和鲁棒性. NHG-Rec 的显著优势验证了其设计的合理性和可行性.

4.6 消融实验

为了验证 NHG-Rec 模型各组成部分的有效性, 本文进行了一系列消融实验. 本文分别移除了邻域图卷积 (NHG-Rec-N)、全局-局部对比学习 (NHG-Rec-GL)、多跳算法 (NHG-Rec-K) 和位置感知动态注意力机制 (NHG-Rec-P) 这 4 个关键组件, 并在 Tmall、Nowplaying 和 Diginetica 这 3 个数据集上进行了验证, 实验结果如图 4 所示. 完整的 NHG-Rec 模型在所有数据集和评估指标上都取得了最佳性能, 这有力地证实了 NHG-Rec 的各个组件的综合效果.

具体来看, 如表 3 所示, 在 Tmall 数据集上, 完整的 NHG-Rec 模型在 $P@20$ 和 $MRR@20$ 上分别达到了 37.86% 和 18.36%, 相比移除邻域图卷积的 NHG-Rec-N 版本 ($P@20$ 为 36.31%, $MRR@20$ 为 17.01%) 有显著提

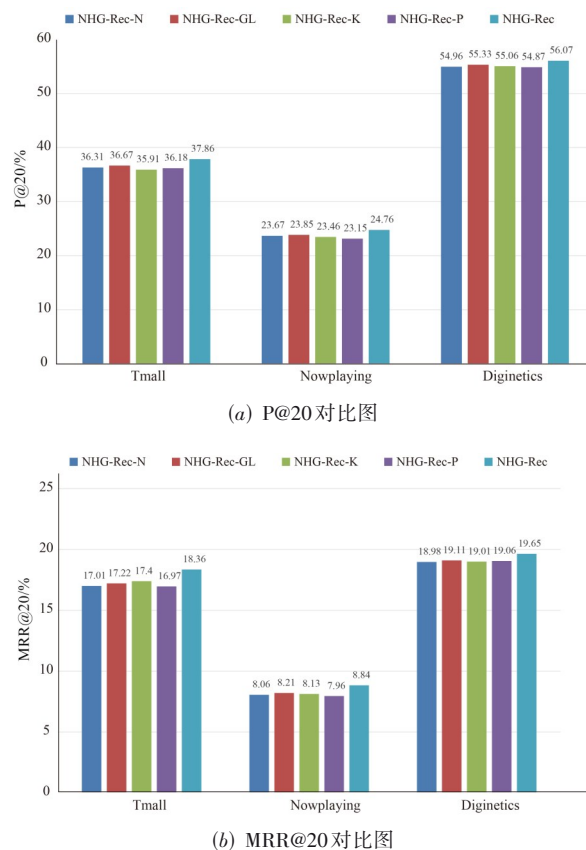


图 4 NHG-Rec 组件在数据集上的表现

升, 这表明邻域图卷积在捕捉项目间局部关系方面发挥了重要作用. 全局-局部对比学习的重要性在 Nowplaying 数据集上体现得尤为明显, 其中完整模型的 $P@20$ 和 $MRR@20$ 分别为 24.76% 和 8.84%, 而 NHG-Rec-GL 的相应指标为 23.85% 和 8.21%, 说明对比学习策略显著增强了模型的表示学习能力. 在 Diginetica 数据集上, 完整模型的 $P@20$ 达到 56.07%, $MRR@20$ 达到 19.65%, 相比各种简化版本都有不同程度的提升. 特别是与 NHG-Rec-N ($P@20$ 为 54.96%, $MRR@20$ 为 18.98%) 和 NHG-Rec-P ($P@20$ 为 54.87%, $MRR@20$ 为 19.06%) 相比, 性能提升更为显著, 这表明邻域图卷积和位置感知机制在该数据集上的重要性. 通过对比不同变体的性能可以发现, 移除多跳算法 (NHG-Rec-K) 对模型性能的影响在不同数据集上表现不一: 在 Tmall 数据集上, NHG-Rec-K 的 $P@20$ 为 35.91%, $MRR@20$ 为 17.40%, 相比完整模型有明显下降; 而在 Nowplaying 数据集上, 其性能降幅相对较小 ($P@20$ 从 24.76% 降至 23.46%). 位置感知动态注意力机制的作用也得到了验证, 虽然其影响相对其他组件较小, 但在 Tmall 数据集上的实验结果 (NHG-Rec-P 的 $P@20$ 为 36.18%, $MRR@20$ 为 16.97%) 显示其对序列建模仍具有重要作用. 消融实验的结果不仅验证了 NHG-Rec 模型中每个组件的必要性

和有效性,还揭示了它们之间的协同作用.其中,邻域图卷积和全局-局部对比学习被证明是对模型性能提升贡献最大的两个组件,而多跳算法和位置感知机制则在不同场景下展现出其独特的价值.这些结果充分说明了NHG-Rec各组件设计的合理性,以及它们在提升推荐性能方面的重要作用.


表3 消融实验结果对比 单位:%

模型	Tmall		Nowplaying		Diginetica	
	P@20	MRR@20	P@20	MRR@20	P@20	MRR@20
NHG-Rec-N	36.31	17.01	23.67	8.06	54.96	18.98
NHG-Rec-GL	36.67	17.22	23.85	8.21	55.33	19.11
NHG-Rec-K	35.91	17.4	23.46	8.13	55.06	19.01
NHG-Rec-P	36.18	16.97	23.15	7.96	54.87	19.06
NHG-Rec	37.86	18.92	24.76	8.84	56.07	19.65

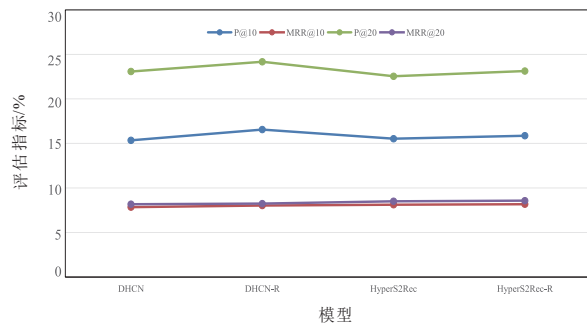
4.7 融合PageRank算法的超图构建对推荐性能的影响

为了研究传统的基于会话归一化的共现图构建方法与融合PageRank算法构建超图对推荐性能的影响,本文选取两个主要依赖于超图建模的模型,使用控制变量法,将构建超图邻接矩阵的方法设为单一变量,其他组件和参数都保持统一进行验证.其中,DHCN和HyperS²Rec为原模型,DHCN-R和HyperS²Rec-R为融合PageRank算法构建的超图模型.为了保证实验的公正性和偶然性,本文选取了2个数据集去探究超图构建方法对推荐性能的影响.通过分析不同的超图邻接矩阵的构建方法对P@10、P@20和MRR@10、MRR@20指标的影响,如图5所示,可以发现本文提出的方法显性提升了推荐模型的性能.具体而言,对超图结构依赖性较大的DHCN模型,其因会话嵌入和物品嵌入皆依赖于超图,所以提升更为明显,而HyperS²Rec由于融入门控循环单位作为学习项目嵌入,削弱了对超图的依赖,所以提升相比于DHCN较小,但其效果较于原模型得到了提升,同样验证了本文方法的有效性.对于不同的数据集,提升的表现也不同.对于Tmall数据集,提升的幅度较大,原因在于基于会话归一化的共现图构建方法更侧重于会话内部物品的局部共现关系,其权重计算高度依赖单一会话内的交互频率,容易忽略跨会话的全局关联与物品的整体重要性.而Tmall数据集作为大型电商平台数据,具有显著的特性差异.PageRank算法通过迭代计算物品在全局超图中的重要性权重,能够有效整合跨会话的关联信息——Tmall数据集中频繁出现在相似会话中的物品,PageRank会赋予其更高的全局权重,强化其与关联物品的连接强度.相比之下,另一数据集Nowplaying为音乐收听数据,会话中的音乐更趋于随机,且错杂交互的数据居多,会话关联较弱,

此时会话归一化的共现图已能较好地捕捉核心关联,PageRank算法带来的全局补充作用相对有限,因此提升幅度不及Tmall数据集.这一现象进一步验证了本文提出的融合PageRank的超图构建方法在复杂、大规模交互数据中的优势,其对全局与局部关联的协同建模能力具有更强的场景适应性.



(a) Tmall数据集



(b) Nowplaying数据集

图5 不同超图构建方法的表现

5 结论

本文提出的多重异构图卷积网络模型(NHG-Rec),通过多视图建模、K-hop多跳算法、位置感知的动态注意力机制和多图全局-局部对比学习策略,有效解决了现有会话推荐模型过分强调物品相对顺序、忽视复杂关联性和高阶转换关系,以及处理稀疏短时交互序列困难的问题.通过融入PageRank算法有效解决了现有超图结构忽略节点相对重要性的问题.实验结果表明,NHG-Rec在多个关键指标上优于基线模型,特别是在真实电商环境中表现突出,证实了其在捕捉复杂高阶关系和处理稀疏数据方面的优越性.未来研究方向可探索将动态图学习技术整合到NHG-Rec中,以更好地捕捉用户兴趣的实时变化并研究如何将NHG-Rec扩展到跨域推荐场景,利用不同邻域的信息提升推荐性能.

参考文献

- [1] NINICHUK M, NAMIOT D. Survey on methods for building session-based recommender systems[J]. *International Journal of Open Information Technologies*, 2023, 11(5): 22-32.
- [2] SHANI G, HECKERMAN D, BRAFMAN R I. An MDP-based recommender system[J]. *Journal of Machine Learning Research*, 2005, 6(9): 1265-1295.
- [3] HIDASI B, KARATZOGLOU A, BALTRUNAS L, et al. Session-based recommendations with recurrent neural networks[EB/OL]. (2016-03-29)[2024-12-26]. <https://arXiv.org/abs/1511.06939>.
- [4] WU S, TANG Y Y, ZHU Y Q, et al. Session-based recommendation with graph neural networks[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, 33(1): 346-353.
- [5] 杨长春, 张毅, 刘昊, 等. 基于全局增强图神经网络的会话推荐方法[J]. *计算机工程与设计*, 2024, 45(10): 3089-3095.
- YANG C C, ZHANG Y, LIU H, et al. Session recommendation based on global enhanced graph neural network[J]. *Computer Engineering and Design*, 2024, 45(10): 3089-3095. (in Chinese)
- [6] 周俊, 胡斌斌, 张志强, 等. MoGE: 基于图上下文增强的多任务推荐算法[J]. *电子学报*, 2023, 51(11): 3377-3387.
- ZHOU J, HU B B, ZHANG Z Q, et al. MoGE: Graph context enhanced multi-task recommendation method[J]. *Acta Electronica Sinica*, 2023, 51(11): 3377-3387. (in Chinese)
- [7] 郑文静. 基于图神经网络的协同会话推荐算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2023.
- ZHENG W J. Research on Graph Neural Network for Collaborative Session-Based Recommendation Algorithm[D]. Harbin: Harbin Institute of Technology, 2023. (in Chinese)
- [8] HIDASI B, KARATZOGLOU A. Recurrent neural networks with top-k gains for session-based recommendations[C]//*Proceedings of the 27th ACM International Conference on Information and Knowledge Management*. New York: ACM, 2018: 843-852.
- [9] TAN Y K, XU X X, LIU Y. Improved recurrent neural networks for session-based recommendations[C]//*Proceedings of the 1st Workshop on Deep Learning for Recommender Systems*. New York: ACM, 2016: 17-22.
- [10] LI J, REN P J, CHEN Z M, et al. Neural attentive session-based recommendation[C]//*Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*. New York: ACM, 2017: 1419-1428.
- [11] LI C, LIU Z, WU M, et al. Multi-interest networks with dynamic routing for sequential recommendation[C]//*Proceedings of the 13th ACM Conference on Recommender Systems*. New York: ACM, 2019: 358-366.
- [12] SUN F, LIU J, WU J, et al. BERT4Rec: Sequential recommendation with bidirectional encoder representations from transformer[C]//*Proceedings of the 28th ACM International Conference on Information and Knowledge Management*. New York: ACM, 2019: 1441-1450.
- [13] XU C F, ZHAO P P, LIU Y C, et al. Graph contextualized self-attention network for session-based recommendation[C]//*Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence (IJCAI-19)*. California: AAAI, 2019, 19(2019): 3940-3946.
- [14] QIU R H, LI J J, HUANG Z, et al. Rethinking the item order in session-based recommendation with graph neural networks[C]//*Proceedings of the 28th ACM International Conference on Information and Knowledge Management*. New York: ACM, 2019: 579-588.
- [15] ZHANG M Q, WU S, YU X L, et al. Dynamic graph neural networks for sequential recommendation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(5): 4741-4753.
- [16] XIA X, YIN H Z, YU J L, et al. Self-supervised hypergraph convolutional networks for session-based recommendation[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(5): 4503-4511.
- [17] 范伟, 周魏, 文俊浩. 基于异构图的双通道交叉自适应对比学习推荐[J]. *电子学报*, 2023, 51(7): 1929-1938.
- FAN W, ZHOU W, WEN J H. Recommendation based on graph heterogeneous using dual channel cross-adaptive contrast learning[J]. *Acta Electronica Sinica*, 2023, 51(7): 1929-1938. (in Chinese)
- [18] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[EB/OL]. (2016-05-19)[2024-12-26]. <https://arXiv.org/abs/1409.0473>.
- [19] XIAO Y P, ZHAO W J, HUANG Y Y, et al. A joint learning recommendation model for E-commerce platforms integrating long-term and short-term interests[J]. *IEEE Transactions on Services Computing*, 2024, 17(4): 1326-1339.
- [20] 曾碧卿, 池俊龙, 陈嘉涛, 等. 基于上下文增强的多级注意力会话推荐模型[J]. *中国科学: 信息科学*, 2024, 54(9): 2116-2135.
- ZENG B Q, CHI J L, CHEN J T, et al. Context enhanced multi-level attention model for session-based recommendation[J]. *Scientia Sinica (Informationis)*, 2024, 54(9) :

2116-2135. (in Chinese)

- [21] 钱忠胜, 黄恒, 万子珑. 融合自注意力机制的多行为图对比学习推荐方法[J]. 电子学报, 2024, 52(11): 3684-3698.
QIAN Z S, HUANG H, WAN Z L. The multi-behavior graph contrastive learning recommendation method with self-attention mechanism[J]. Acta Electronica Sinica, 2024, 52(11): 3684-3698. (in Chinese)
- [22] DING C X, ZHAO Z Y, LI C, et al. Session-based recommendation with hypergraph convolutional networks and sequential information embeddings[J]. Expert Systems with Applications, 2023, 223: 119875.
- [23] KHAN B, WU J, YANG J, et al. Heterogeneous hypergraph neural network for social recommendation using attention network[J]. ACM Transactions on Recommender Systems, 2025, 3(3): 1-22.
- [24] CHEN T X, YANG L, WANG Z D, et al. Enhancing session-based recommendation with hypergraph motifs and contrastive learning[C]//ICASSP 2025-2025 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE, 2025: 1-5.
- [25] 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. New York: ACM, 2010: 811-820.
- [26] LIU Q, ZENG Y F, 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. New York: ACM, 2018: 1831-1839.

- [27] WANG Z Y, WEI W, CONG G, et al. Global context enhanced graph neural networks for session-based recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020: 169-178.
- [28] LI A S, CHENG Z Y, LIU F, et al. Disentangled graph neural networks for session-based recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(8): 7870-7882.
- [29] ZHANG P Y, GUO J Y, LI C Z, et al. Efficiently leveraging multi-level user intent for session-based recommendation via atten-mixer network[C]//Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining. New York: ACM, 2023: 168-176.
- [30] 温彦, 孙会政, 卞玮, 等. 一种基于面向重复性构建超图和面向共现性重构排名的会话推荐方法[J]. 数据分析与知识发现, 2025, 9(6): 136-148.
WEN Y, SUN H Z, BIAN W, et al. Enhancing session-based recommendations via repetition-aware hypergraph construction and co-occurrence ranking optimization[J]. Data Analysis and Knowledge Discovery, 2025, 9(6): 136-148. (in Chinese)

作者简介




陈荣元 男, 1976年6月出生于江苏省泰州市. 现为湖南工商大学教授、硕士生导师. 主要研究方向为数据挖掘、推荐系统.
E-mail: chenrongyuan@126.com



文杰彬 男, 2001年9月出生于湖南省株洲市. 现为湖南工商大学前沿交叉学院硕士研究生. 主要研究方向为推荐系统、人工智能.
E-mail: 16670835201@163.com



黄少年 女, 1977年6月出生于湖南省常德市. 现为湖南工商大学副教授、硕士生导师. 主要研究方向为数据挖掘、图像处理.
E-mail: snhuang@hutb.deu.cn



何晔宇 女, 1994年11月出生于湖南省湘潭市. 现为湖南工商大学讲师. 主要研究方向为深度学习、信息处理.
E-mail: heyeyu@hutb.edu.cn