

TMHGCN: 一种时序多通道超图卷积电商推荐方法

程实, 邵逸飞, 张志鑫, 顾卫江*

南通大学人工智能与计算机学院, 江苏 南通

收稿日期: 2026年3月11日; 录用日期: 2026年3月26日; 发布日期: 2026年5月29日

摘要

随着信息化时代的发展, 人们的交互强度与日俱增, 在电商推荐系统中, 传统推荐方法已经无法适应当今现实环境。人们通过处理社交关系来增强推荐质量, 大量研究表明, 社交关系的引入可以在一定程度上缓解冷启动和稀疏性问题, 但真实场景中的用户关联并非简单的“一对一”, 还存在着社区关系、共同兴趣圈等复杂社交关系, 同时用户的兴趣还可能会随着时间发生改变。超图卷积对于刻画这种“多对多”的复杂社交关系效率较高, 但如何在处理复杂关系的同时可以减小噪声影响, 同时又不忽视用户兴趣的动态变化成为了社交系统中一个值得进一步探索的方向。基于此, 本文提出了一种时序多通道超图卷积网络(TMHCN): 在技术层面, 我们通过将不同类型的关系数据划分为多个通道(比如社交、交互或二者结合等), 并在每个通道上构建专注于该类型数据的超图; 同时引入时序编码模块对用户特征进行处理, 学习用户兴趣的动态变化。通过多通道超图的信息聚合, TMHCN可以更全面、更细致地预测用户偏好, 而在Yelp、Douban等大量真实数据集上的实验结果表明, 该模型在多项指标上均取得稳步提升。

关键词

推荐系统, 社交网络, 时序处理, 超图卷积, 注意力机制

TMHGCN: A Time Series Multi-Channel Hypergraph Convolution E-Commerce Recommendation Method

Shi Cheng, Yifei Shao, Zhixin Zhang, Weijiang Gu*

School of Artificial Intelligence and Computer Science, Nantong University, Nantong Jiangsu

*通讯作者。

文章引用: 程实, 邵逸飞, 张志鑫, 顾卫江. TMHGCN: 一种时序多通道超图卷积电商推荐方法[J]. 电子商务评论, 2026, 15(5): 915-924. DOI: 10.12677/ecl.2026.155593

Abstract

With the development of information age, people's interaction intensity is increasing day by day. In the e-commerce recommendation system, the traditional recommendation method has been unable to adapt to today's realistic environment. People enhance the recommendation quality by dealing with social relationships. A large number of studies show that the introduction of social relationships can alleviate the cold start and sparseness problems to some extent, but the user association in real scenes is not simple "one-on-one", there are also complex social relationships, such as community relationships and common interest circles, and users' interests may change over time. Hypergraph Convolutional Networks have a lot of experience in depicting this "many-to-many" complex social relationship, but how to deal with the complex relationship while reducing the noise impact without ignoring the dynamic changes of users' interests has become a direction worthy of further exploration in social systems. Based on this, this paper proposes a time series multi-channel hypergraph convolution network (TMGCHN): On the technical level, we divide different types of relational data into multiple channels (such as social, interactive or a combination of the two), and build a hypergraph focusing on this type of data on each channel; at the same time, the sequential coding module is introduced to process user characteristics and learn the dynamic changes of user interests. Through the information aggregation of multi-channel hypergraph, TMGCHN can predict user preferences more comprehensively and carefully, and the experimental results on a large number of real data sets, such as Yelp and Douban, show that the model has made steady progress in many indicators.

Keywords

Recommendation System, Social Network, Time Series Processing, Hypergraph Convolution, Attention Mechanism

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

推荐系统作为智能信息处理核心技术，在电商等领域应用广泛，但其在高阶社交关系建模上面临挑战，传统图结构仅能表达一对一关系，图卷积网络也难以处理复杂多层次社交结构，如图 1 所示的超图卷积网络(HGCN) [1]因可建模多节点高阶关系成为研究热点，为推荐系统的关系建模提供了新方向。




Figure 1. Hypergraph convolution schematic diagram

图 1. 超图卷积示意图

超图卷积网络由 Feng 等人提出, 基于“节点-超边-节点”机制实现多节点特征聚合, 可有效捕捉复杂交互关系。Bai 等人在超图中引入注意力机制[2], 提升了节点关系表达的灵活性与准确性。在推荐领域, Bu 等人率先将超图引入音乐推荐[3], 构建用户-项目超图捕捉共享偏好; 成耀等人提出 HyperRec [4], 利用超图表征用户短期点击偏好并实现多维交互聚合; Ji 等人设计 DHCF 双通道超图模型[5], 分别建模社交行为与兴趣倾向以增强异构信息融合。

Liu 等人提出 DisenHGCF 模型[6], 通过社交超图融合多视角刻画用户高阶关系; Yang 等人设计 LBSN2Vec++ [7], 构建跨域超边实现社交与地理信息的联合捕捉。现有超图卷积推荐研究虽取得进展, 但在有效构建超图、处理复杂关系数据时仍受噪声干扰, 且未结合时序信息捕捉用户动态偏好, 难以适配真实推荐场景。为此, 本文提出时序多通道超图卷积推荐模型 TMHGCN, 引入多通道超图机制, 旨在捕捉用户动态偏好变化, 高效利用用户社交信息, 提升推荐性能。

2. 模型方法

2.1. 模型概述

本文提出的推荐方法基于时序多通道超图卷积网络, 通过时序建模和多类型超图卷积的融合, 缓解用户兴趣动态变化与高阶社交关系利用的挑战, 整体框架如图 2 所示。

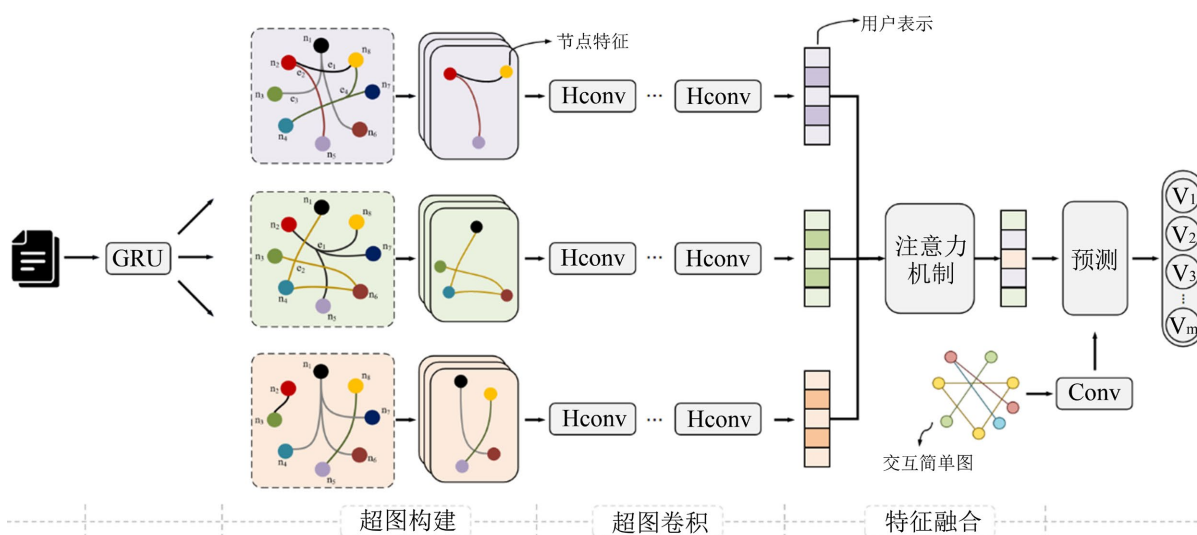


Figure 2. Overall framework diagram of the model
图 2. 模型整体框架图

模型输入用户行为与项目特征数据, 先构建特征矩阵, 经时序处理生成嵌入, 再通过超图卷积更新特征后融合预测偏好。模型含时序处理和多通道超图卷积模块, 经 GRU 捕捉动态偏好, 分析三通道卷积学习特征, 注意力融合结果并结合交互图卷积生成推荐评分。

2.2. GRU 时序处理单元

2.2.1. 建立特征矩阵

假设有 m 个用户和 n 个项目, 令 $\{U_1, U_2, U_3 \dots U_m\}$ 代表用户集合 ($|U| = m$), $I = \{I_1, I_2, I_3 \dots I_n\}$ 代表项目集合 ($|I| = n$)。需根据数据构建三个关键矩阵: 用户特征矩阵 U 、项目特征矩阵 I 和交互矩阵 R : 用户特

征矩阵 $U \in \mathbb{R}^{m \times d}$ 用于表示每个用户的静态特征以及用户的历史行为；项目特征矩阵 $I \in \mathbb{R}^{n \times d}$ 用于表示每个项目的静态特征；交互矩阵 $R \in \mathbb{R}^{m \times n}$ 记录了用户与项目之间的交互关系，其中 m 为用户数量， n 为项目数量， d 是每个用户特征的维度。

2.2.2. GRU 前向传播过程

GRU 包含三个关键组件：重置门 r_t 、更新门 z_t 和候选状态 \tilde{h}_t 。这些组件共同决定了如何从历史信息中提取当前时刻的状态表示，每个时间步的 GRU 单元将输入当前时刻的数据和上一时刻的隐藏状态。

重置门 r_t 通过决定当前输入和上一时刻隐藏状态的结合方式，控制网络如何更新当前的候选状态；更新门 z_t 控制如何将上一时刻的状态与当前时刻的候选状态融合，决定了当前时刻的输出状态将由多少比例的历史信息和候选状态构成；候选状态 \tilde{h}_t 结合上一时刻的状态和当前时刻的输入，生成当前时刻的候选状态；最终隐藏状态 h_t ：根据重置门和更新门的控制，计算当前时刻的隐藏状态。

更新门 z_t 控制了上一时刻状态 h_{t-1} 和当前时刻候选状态 \tilde{h}_t 在最终隐藏状态 h_t 中的比例，从而决定了新旧信息的融合，最终将 h_t 转换为新的用户及项目特征矩阵 U_1 和 I_1 。

2.3. 多通道超图构建

2.3.1. 超图通道的设置

电商推荐中用户偏好受三类因素影响：社交圈层的消费偏好引导、用户与项目的直接交互行为、社交与交互的共同作用。据此模型设社交、联合、交互三个超图通道，分别捕捉用户社交关系、社交关联下的用户 - 项目共现关系、无社交关联的用户 - 项目交互关系。各通道数据源与特征表征独立互补，无信息重复与数据冗余。

2.3.2. 超图的创建

首先，根据用户及项目特征矩阵 U_1 和 I_1 分别建立三个通道的超图：

在社交通道邻接矩阵 $H_s \in \mathbb{R}^{m \times m}$ (m 为用户的数量)中，若用户 u 和用户 v 存在社交关系，则 $H_s[u, v]$ 的值为 1，否则为 0；在联合通道邻接矩阵 $H_j \in \mathbb{R}^{m \times n}$ (m 为用户数量， n 为项目数量)中，若用户 u 与项目 i 有交互(例如点击、购买等)，则 $H_j[u, i]$ 为 1，否则为 0；在交互通道邻接矩阵 $H_p \in \mathbb{R}^{m \times n}$ 中，若用户 u 与项目 i 存在交互，如购买、评分等行为，则 $H_p[u, i]$ 为 1，否则为 0。

令 $G_i = (V, E)$, ($i = s, j, p$) 表示超图，其中 V 为包含了 N 个顶点的顶点集， E 是包含 M 个超边的边集，为每个超边 $e \in E$ 分配一个正向的权重 W_{ee} ，所有权重汇集生成权重矩阵 $W \in \mathbb{R}^{M \times M}$ ，在本文中， W 为唯一矩阵，统一分配为 1。然后根据邻接矩阵与权重矩阵计算出顶点与边的度矩阵 D 与 L ：

$$D_{ii} = \sum_{e=1}^M W_{ee} H_{ie}; L_{ee} = \sum_{i=1}^N H_{ie}$$

2.4. 超图卷积

因为不同通道可能会对最终的推荐性能表现出不同的重要性，为控制从基本用户嵌入 $p^{(0)}$ 到每个通道的信息流强度，我们采用了一种基于 ReLU 激活函数的门控机制，其数学表达式定义为：

$$p_c^{(0)} = f_c \left(\text{ReLU} \left(P^{(0)} W_g^c + b_g^c \right) \right)$$

其中： $c \in \{s, j, p\}$ 表示通道， $P^{(0)} \in \mathbb{R}^{N \times d}$ 为输入特征矩阵， $W_g^c \in \mathbb{R}^{d \times d}$ 和 $b_g^c \in \mathbb{R}^d$ 分别为学习得到的权重矩阵和偏置项，ReLU 函数通过抑制负值并保留正值，有效地控制信息流的传递，强化重要通道的特征，抑制不相关通道的干扰，进而生成特定于通道的用户嵌入 $p_c^{(0)}$ 。

在将用户嵌入导入超图通道之前，为确保信息流的平衡，避免节点度值过大对卷积结果产生影响，我们首先对邻接矩阵 H 进行归一化处理：

$$\hat{H} = D^{-1/2} H D^{-1/2}$$

其中， $D \in \mathbb{R}^{N \times N}$ 为度矩阵。

然后引入用户嵌入 $p_c^{(0)}$ ，利用归一化邻接矩阵 \hat{H} 和卷积权重矩阵 W_c 对用户嵌入进行加权更新，进行卷积操作：

$$p_c^{(l+1)} = \sigma(\hat{H} p_c^{(l)} W_c)$$

其中， $W_c \in \mathbb{R}^{d \times d}$ 是第 c 通道的可学习卷积权重矩阵， σ 为激活函数 Sigmoid，防止信息的线性传播。

在通过 L 层传播用户嵌入后，平均每一层获得的嵌入，以形成最终的特定于通道的用户表示：

$$P_c^* = \frac{1}{L+1} \sum_{l=0}^L P_c^{(l)}$$

为避免过度平滑问题，本文引入注意力机制对不同通道的用户嵌入信息进行选择性聚合，形成全局用户嵌入。对于每个用户 u ，定义三元组 $(\alpha_s, \alpha_j, \alpha_p)$ 来测量三个特定于通道的嵌入对最终推荐性能的不同贡献。 f_{att} 的定义为：

$$\alpha_c = f_{att}(p_c^*) = \frac{\exp(a^T \cdot W_{att} p_c^*)}{\sum_{c' \in \{s, j, p\}} \exp(a^T \cdot W_{att} p_{c'}^*)}$$

$a \in R^d$ 和 $W_{att} \in R^{d \times d}$ 都是可以训练的参数，以及全面的用户表示：

$$P^* = \sum_{c \in \{s, j, p\}} \alpha_c P_c^*$$

2.5. 兴趣概率得分计算

在计算兴趣概率之前，为提高用户与项目之间交互信息的重要性，增强其在用户和项目嵌入中的贡献，本文还对用户 - 项目交互图进行简单图卷积，对交互信息进行编码，并补充多通道超图卷积：

$$P_r^{(l+1)} = D_u^{-1} R Q^{(l)}, P_r^{(0)} = f_{gate}^r(P^{(0)}),$$

$$Q^{(l+1)} = D_i^{-1} R^T P_m^{(l)}, P_m^{(l)} = \sum_{c \in \{s, j, p\}} \alpha_c P_c^{(l)} + \frac{1}{2} P_r^{(l)}$$

其中， $P_r^{(l)}$ 是简单图卷积的门控用户嵌入， $P_m^{(l)}$ 是用户嵌入和 $P_r^{(l)}$ 的组合， $D_u \in R^{m \times m}$ 和 $D_i \in R^{n \times n}$ 分别是 R 和 R^T 的度矩阵。最后得到最终用户和项目嵌入 P 和 Q ，定义为：

$$P = P^* \frac{1}{L+1} \sum_{l=0}^L P_r^{(l)}, Q = \frac{1}{L+1} \sum_{l=0}^L Q^{(l)}$$

然后利用 sigmoid 函数计算用户 u 对物品 v 的兴趣概率：

$$y = \text{sigmoid}(PQ)$$

3. 实验与结果分析

3.1. 数据集

本文实验选取了两个公开学术数据集：Yelp 与 Douban，如表 1 所示。

1) Yelp 数据集包含用户、商家、评论等多种信息。该数据集记录了用户的基本信息、历史评分记录、

好友关系网络等,商家数据则包含类别标签、地理位置信息(纬度与经度)、评价得分等内容。用户与商家之间通过购买、评论与评分行为建立交互关系,并以 JSON 格式提供详细的时间戳与评分数值。

2) Douban 公开数据集收集自豆瓣平台,以用户对电影、图书等文化产品的评分与标签行为为核心,形成用户-物品关系网。在数据集中,用户包含基本信息,物品则提供内容类型等字段。用户对物品的交互主要通过评分与评价实现。

Table 1. Information of experimental data

表 1. 实验数据信息

数据集	用户数	项目数	边数	超边数
Yelp	13,764	7657	68,467	85,118
Douban	12,689	10,283	74,521	96,325

3.2. 实验设置及结果

1) 评价指标

为全面评估推荐模型在不同维度的性能表现,本文采用了两类指标体系。其中, Precision@10 与 Recall@10 用于衡量相关性, NDCG@10 则反映推荐结果的排名质量。

2) 参数设置

在实验中,学习率初始设定为 0.0002,批量大小初始设置为 2048,优化器采用 Adam,正则化系数为 $1e-4$,训练轮次上限为 300, NDCG@10 无提升时提前终止,数据按 8:1:1 划分为训练集、验证集与测试集。

3) 对比基线

为更好地验证 TMHGCN 模型的有效性,本文从传统推荐方法,基于内容的推荐方法,基于 CNN 等方法的推荐模型中选择以下几种具有代表性的基线模型与 TMHGCN 进行比较。

LightGCN [8]: 一种图神经网络推荐模型,去除非线性操作,仅聚合邻居信息建模高阶关系。

BPR [9]: 一种典型的基于矩阵分解的协同过滤模型,通过优化用户对物品的相对偏好排序。

GC-MC [10]: 一种基于图卷积的矩阵分解模型,通过图卷积捕捉用户和项目之间的潜在关系。

DHCN [11]: 一种双通道超图卷积模型,结合局部与全局信息捕捉复杂关系数据。

GraphRec [12]: 一种基于图的推荐模型,结合社交网络与交互数据来联合建模社交信息与偏好信息。

MAGNN: 一种异构图神经网络模型,结合元路径聚合机制,联合建模节点内容与多种元路径关系,以提升异构图中的嵌入表示学习效果。

HGNN: 一种超图神经网络模型,通过超边建模多节点高阶关系提升表示能力。

4) 实验结果

从整体表现来看, TMHGCN 在两项数据集的所有评价指标上均取得最优结果,尤其在 Douban 数据集上的提升相对更大, P@10 的提升为 1.34%, R@10 提升了 2.46%, N@10 则大幅提升了 2.85%。这种表现不仅表明 TMHGCN 在推荐准确性方面能力更强,这表明模型在处理更复杂数据集时,依然能够保持较高的性能。除此之外,可以发现 BPR 这类传统协同过滤方法表现最差,这与其忽略社交结构或许有所关联,导致在面对动态社交背景时较为乏力; DHCN 和 HGNN 等超图方法可以刻画多节点关系,效果相对优秀,但或许因其缺乏对用户时序变化的捕捉,在预测试可能会受到用户喜好变化的影响,所以效果略差于 TMHGCN。

Table 2. Results of model performance comparison
表 2. 模型性能比较结果

数据集	指标	模型							本模型	
		BPR	GC-MC	LightGCN	GraphRec	HAGNN	DHCN	HGNN	TMHGCN	提升(%)
Yelp	P@10	0.2214	0.2335	0.2510	0.2603	0.2691	0.2789	<u>0.2894</u>	0.3138	2.44
	R@10	0.0712	0.0810	0.0734	0.0808	0.0852	0.0911	<u>0.0936</u>	0.1179	2.43
	N@10	0.2376	0.2443	0.2476	0.2583	0.2629	0.2951	<u>0.2932</u>	0.3147	1.96
Douban	P@10	0.2648	0.2791	0.2986	0.3104	0.3203	<u>0.3365</u>	0.3417	0.3551	1.34
	R@10	0.0837	0.0906	0.0958	0.1014	0.1030	0.1057	<u>0.1120</u>	0.1366	2.46
	N@10	0.3011	0.3162	0.3388	0.3506	0.3567	0.3834	<u>0.3814</u>	0.4119	2.85

3.3. 消融实验

(a) V-G: 移除时序处理模块, 直接对数据进行超图卷积训练; (b) V-M: 不设置多个超图通道, 将时序处理后的数据直接进行超图卷积训练。

从图 3 的实验结果来看, 在去除任一模块都会导致模型性能下滑。其中去除时序处理模块对效果影响相对较小, 模型效果会降至表 2 中 MGNN 水平, 表明多通道超图模块对整体性能贡献度最大, 但单凭多超图通道无法超越基线模型, 对于用户喜好动态变化的捕捉也尤为关键。

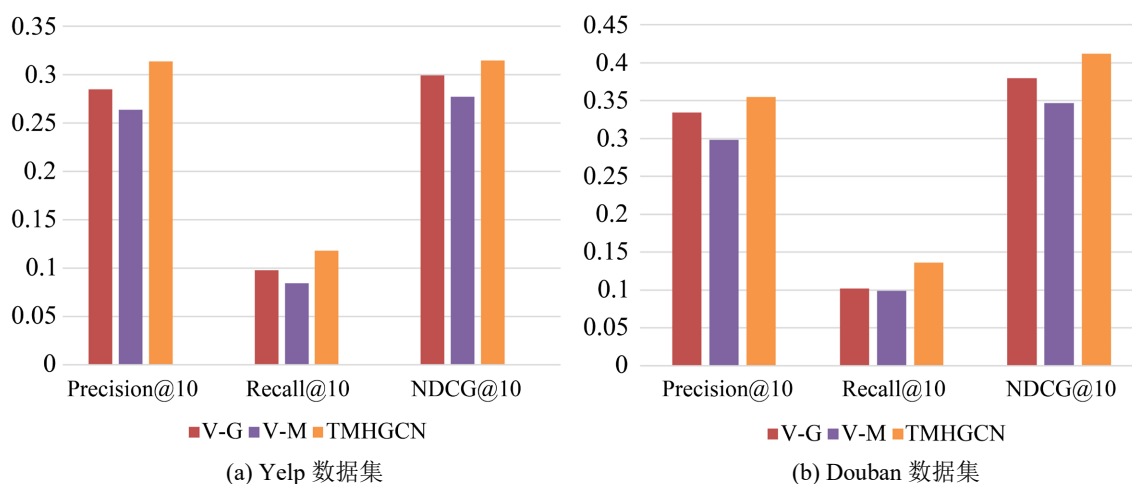


Figure 3. Ablation study results for each module
图 3. 各模块消融实验对比结果

3.4. 通道贡献程度分析

本文为深入探究各超图通道对 TMHGCN 的贡献程度, 对不同通道用户嵌入在进行选择性聚合时所计算得出的贡献度 ($\alpha_s, \alpha_j, \alpha_p$) 进行加权计算, 对得出的通道整体贡献度做可视化处理, 如图 4 所示。可以很明显地看出, 交互通道的贡献度在两个数据集上均超过 50%; 联合通道在 Douban 数据集上的贡献度明显大于 Yelp 数据集; 社交通道贡献度最小, 这与社交通道并不涉及交互信息密切相关, 但并不可忽视其贡献度, 社交关系数据的引入或许正是模型可以优于其余基线模型的关键所在。

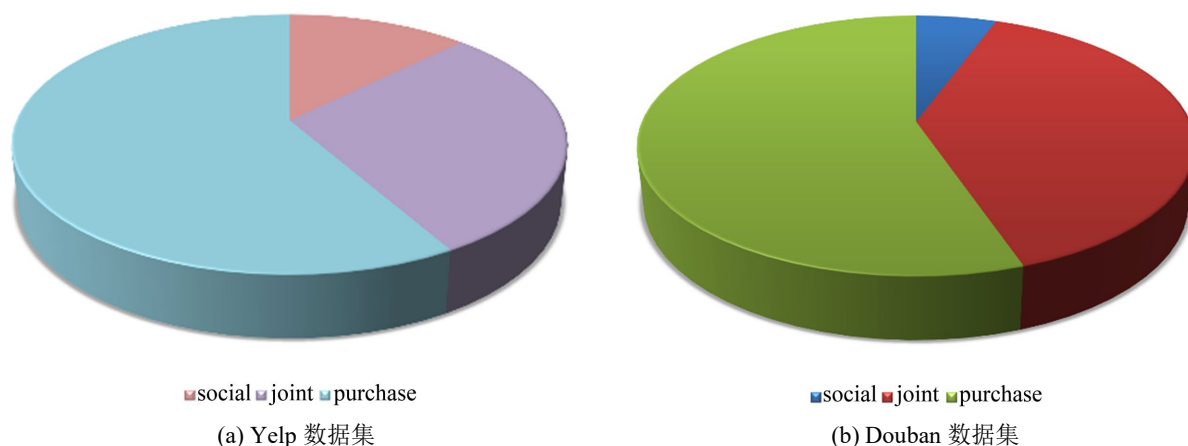


Figure 4. Channel contribution experiment results diagram
图 4. 通道贡献度实验结果图

3.5. 时序序列长度分析

在本文中对用户与项目的时序数据进行处理时，对时序序列长度也进行了深入实验，本文以用户历史行为的时间步数，即每个用户的历史交互记录数作为单位，对时间序列长度选取比较具有代表性的 5、10、20、50、100、200 进行了实验报告。由图 5 可知，当序列长度在 100 左右时模型性能最佳，当序列长度过小时，模型性能显著下降，表明序列过短时无法准确捕捉用户偏好的长期变化；当序列长度在 50 至 200 之间效果较好；而当序列过长时效果变差，这说明其不仅会加大训练难度，延长训练时间，还容易造成过拟合或信息冗余，但相比之下，序列长度过小对于推荐性能的影响更大一些，说明捕捉用户偏好的长期变化对时序处理更为重要。




Figure 5. Results of time series length experiments
图 5. 时序序列长度实验结果

3.6. 超图卷积深度分析

最后，本文研究了超图卷积层数对 TMHGCN 的影响程度。本文将超图卷积的层数从 1 增加到了 5，由图 6 可得，在两个数据集上，各指标均在卷积深度为 2 时达到最佳，随着卷积层数递增，性能均发生不同程度的下降，在 Douban 数据集上当卷积深度超过 3 时 Recall 指标就已经低于单层超图卷积，这表明浅层超图卷积更适合 TMHGCN，究其原因可能为其在浅层时可以更好聚合远距离邻居信息。

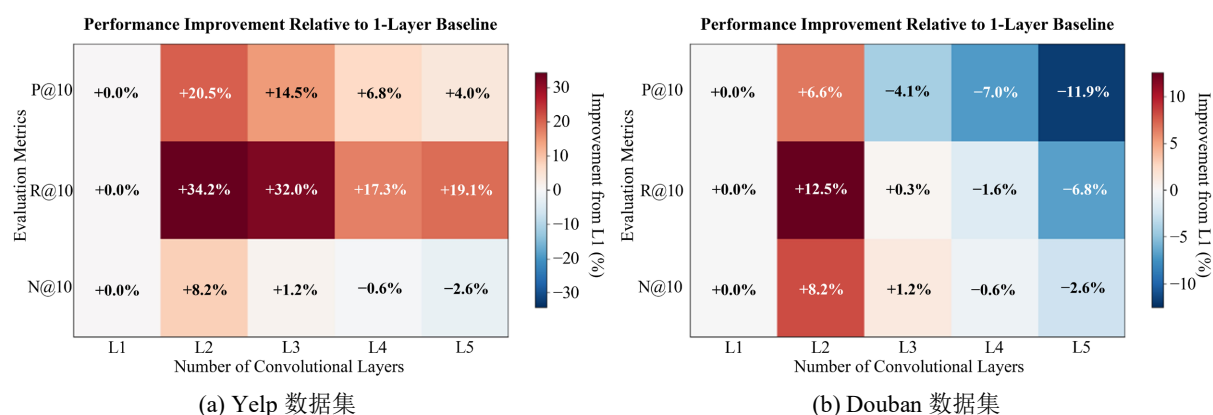


Figure 6. Experimental results of hypergraph convolution depth

图 6. 超图卷积深度实验结果

4. 总结

近年来，基于图卷积的推荐方法逐渐替代传统方法占据主流，但其只能处理一对一交互的特点使其在当今应用场景愈加多变，推荐要求愈加严苛的条件下无法满足实际需求。超图卷积的引入虽提供了处理复杂关系数据的建模方法，但其易受噪声干扰及其对算力的要求严苛使其在实际应用中效果不佳；此外，随着社交关系的复杂化，用户动态喜好问题仍无法有效缓解。本文将时序处理与超图卷积融合，再通过构建多通道超图针对性提取用户特征，提出了一种时序多通道超图卷积网络(TMHCN)。我们还分别从基线对比、时序序列长度、卷积深度等方面对模型参数进行了深层次剖析，在两个公共数据集多个指标上均验证了模型有效性，展示其卓越性能。

参考文献

- [1] Feng, Y., You, H., Zhang, Z., Ji, R. and Gao, Y. (2019) Hypergraph Neural Networks. *Proceedings of the AAAI Conference on Artificial Intelligence*, **33**, 3558-3565. <https://doi.org/10.1609/aaai.v33i01.33013558>
- [2] Bai, S., Zhang, F. and Torr, P.H.S. (2021) Hypergraph Convolution and Hypergraph Attention. *Pattern Recognition*, **110**, Article 107637. <https://doi.org/10.1016/j.patcog.2020.107637>
- [3] Bu, J., Tan, S., Chen, C., Wang, C., Wu, H., Zhang, L., et al. (2010) Music Recommendation by Unified Hypergraph: Combining Social Media Information and Music Content. *Proceedings of the 18th ACM international conference on Multimedia*, Firenze, 25-29 October, 391-400. <https://doi.org/10.1145/1873951.1874005>
- [4] 成耀, 张铎, 周宇, 何金凤, 程实. 基于模糊聚类的电商企业不平衡财务数据风险预测方法[J]. 电子商务评论, 2025, 14(1): 640-647.
- [5] Ji, S., Feng, Y., Ji, R., Zhao, X., Tang, W. and Gao, Y. (2020) Dual Channel Hypergraph Collaborative Filtering. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, Online, 6-10 July 2020, 2020-2029. <https://doi.org/10.1145/3394486.3403253>
- [6] Liu, X., Meng, S., Li, Q., Xu, X., Qi, L., Dou, W., et al. (2023) Disentangled Hypergraph Collaborative Filtering for Social Recommendation. *2023 IEEE International Conference on Web Services (ICWS)*, Chicago, 2-8 July 2023, 475-482. <https://doi.org/10.1109/icws60048.2023.00066>
- [7] Yang, D., Qu, B., Yang, J. and Cudre-Mauroux, P. (2020) LBSN2vec++: Heterogeneous Hypergraph Embedding for Location-Based Social Networks. *IEEE Transactions on Knowledge and Data Engineering*, **34**, 1843-1855. <https://doi.org/10.1109/tkde.2020.2997869>
- [8] He, X., Deng, K., Wang, X., Li, Y., et al. (2020) LightGCN: Simplifying and Powering Graph Convolution Network for Recommendation. *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*, New York, 25-30 July 2020, 639-648.
- [9] Rendle, S., Freudenthaler, C., Gantner, Z. and Schmidt-Thieme, L. (2009) BPR: Bayesian Personalized Ranking from Implicit Feedback. *Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence*, Arlington, 18-21 June 2009, 452-461.

- [10] Berg, R.V.D., Kipf, T.N. and Welling, M. (2017) Graph Convolutional Matrix Completion. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, New York, 13-17 August 2017, 1-10.
- [11] Xia, X., Yin, H., Yu, J., Wang, Q., Cui, L. and Zhang, X. (2021) Self-Supervised Hypergraph Convolutional Networks for Session-Based Recommendation. *Proceedings of the AAAI Conference on Artificial Intelligence*, **35**, 4503-4511. <https://doi.org/10.1609/aaai.v35i5.16578>
- [12] Fan, W., Ma, Y., Li, Q., He, Y., Zhao, E., Tang, J., *et al.* (2019) Graph Neural Networks for Social Recommendation. *The World Wide Web Conference*, San Francisco, 13-17 May, 417-426. <https://doi.org/10.1145/3308558.3313488>