



研究与开发

基于多通道超图卷积与跨视图对比学习的会话推荐

任宇彬, 王瑞琴, 隋欣怡, 方驰

(湖州师范学院信息工程学院, 浙江 湖州 313000)

摘要: 会话推荐通过分析匿名用户的历史交互数据来预测下一个交互项。由于用户行为数据的稀疏性, 从单个维度对会话表示进行建模可能无法全面地捕获用户的真实意图。此外, 现有的会话推荐模型主要考虑会话项的顺序信息而忽略了不同会话项之间的高阶关系。因此, 提出对比学习和多通道超图卷积 (cross-view contrastive learning and multi-channel hypergraph convolution, CLMHC) 模型, 该模型构建了超图和全局超图两个互补的视图, 通过通道混合注意力机制自适应地融合从两个超图通道中捕获的用户意图, 并对不同视图空间的用户意图进行对比学习。在3个数据集上的实验研究表明, 所提模型较现有模型在推荐准确性方面具有显著的提升, 进一步的消融实验表明两个维度的视图表示均起到了积极作用。

关键词: 会话推荐; 超图; 多通道; 注意力机制; 对比学习

中图分类号: TP393; TN99

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025233

Cross-view contrastive learning and multi-channel hypergraph convolution for session-based recommendation

REN Yubin, WANG Ruiqin, SUI Xinyi, FANG Chi

School of Information Engineering, Huzhou University, Huzhou 313000, China

Abstract: Session-based recommendation predicts the next interaction item by analyzing anonymous users' historical interaction data. Because of the sparsity of user behavior data, modeling session representations from a single perspective may fail to fully capture users' true intentions. Moreover, existing session-based recommendation models primarily focus on the sequential order of session items while overlooking the higher-order relationships between them. To address this, the cross-view contrastive learning and multi-channel hypergraph convolution (CLMHC) model that constructs two complementary views was proposed: a hypergraph and a global hypergraph. By leveraging a channel-mixing attention mechanism, the model adaptively integrated the user intentions captured from both hypergraph channels while employing contrastive learning to refine user representations across different views. Extensive experiments on three datasets demonstrate that our model significantly outperforms existing approaches in recommendation accu-

收稿日期: 2025-03-08; 修回日期: 2025-05-21

通信作者: 王瑞琴, angelwrq@163.com

基金项目: 国家自然科学基金资助项目 (No. 62277016)

Foundation Item: The National Natural Science Foundation of China (No. 62277016)

racy. The ablation studies further confirm that both views contribute positively to performance improvement.

Key words: session-based recommendation, hypergraph, multi-channel, attention mechanism, contrastive learning

0 引言

在当今信息爆炸的时代,用户通常难以从海量数据中快速筛选出有价值的信息。推荐系统的广泛应用有效地提升了个性化信息的获取效率。然而,传统推荐模型通常依赖用户的长期历史行为,导致在面对新用户或匿名用户时,缺乏足够的历史记录,推荐效果不尽如人意。为应对这一挑战,会话推荐应运而生,它通过分析匿名用户的短期行为数据预测其下一步可能交互的物品,预测并推荐用户下一步最可能交互的物品,既保护了用户隐私,也提升了推荐系统的适应性和准确性。

会话推荐的关键在于如何从有限的信息中准确地捕捉物品间的复杂转换关系。早期的方法如基于频率或马尔可夫链的模型推荐效果十分有限。随着深度学习的发展,循环神经网络(recurrent neural network, RNN)^[1]、卷积神经网络(convolutional neural network, CNN)^[2]、图神经网络(graph neural network, GNN)^[3]和注意力机制逐渐被引入推荐任务。RNN擅长建模时间序列,但难以捕获高阶关系,CNN则对数据质量依赖较大,不适应数据稀疏的实际场景。相比之下,图神经网络尤其是融合了注意力机制的GNN模型^[4-5],因擅长刻画复杂物品关系和高阶交互而逐渐成为研究热点。但传统的图结构每条边连接两个节点,通常表示一对一的关系,难以充分表达物品间的多元相关性。同时,考虑到每个会话都是由短期动态物品组成的,数据的稀疏性问题依然无法有效地处理。

为更好地建模物品间的高阶联系,近年来,研究者引入了超图结构,将每个会话建模为超边,使会话内所有物品相互连接,并通过共享物

品在不同超边间建立关联,从而补充会话间的信息并构建物品的多重关系网络。基于此,本文提出了一种基于多通道超图卷积与跨视图对比学习(cross-view contrastive learning and multi-channel hypergraph convolution, CLMHC)会话推荐模型。该模型通过构建两个独立的超图通道,从不同维度提取用户意图特征,并引入注意力机制实现多视图特征的动态融合。此外,本文设计了一种新的损失函数,以进一步提升推荐系统的预测精度。

本文具体工作如下。

(1) 提出了双视图建模框架,通过构建全局超图和局部超图两个互补的视图,再对不同视图分别进行超图卷积,全面捕获用户的兴趣偏好和行为特征。

(2) 设计了通道混合注意力机制,自适应地融合来自不同视图空间的用户意图信息,提高了用户偏好建模的精度,进一步提升了模型的表达能力。

(3) 提出了跨视图对比学习机制,通过优化两个视图中学习到的会话表示的一致性,进一步增强了模型的表征能力,同时缓解了数据稀疏问题。

1 相关工作

1.1 基于超图卷积的会话推荐

超图^[6]作为一种特殊的图,由顶点集合和超边集合构成,其核心特征在于能够同时连接任意数量的顶点,突破了传统图中边仅能连接两个顶点的限制,能够更自然地表达多元素间的群体关系。SHARE^[7]模型提出了一种超图注意力网络,通过滑动窗口将每个会话构建为一个局部超图和超边,并利用超图注意力网络聚合会话中的上



下文信息得到物品嵌入来预测用户意图。GC-HGNN^[8]模型同时考虑了物品的全局和局部上下文信息，构建了全局会话超图和局部会话图，并通过平均池化融合了两种特征，取得了显著效果。HyperS²Rec^[9]使用超图卷积网络和门控循环单元分别学习两种物品嵌入，然后将两种嵌入使用注意力机制进行结合，有效地解决了现有研究对物品间一致性和顺序依赖关系的忽视问题。C-HAN^[10]在超图注意力网络中引入了多种交互上下文，增强了模型的上下文感知能力，并通过软注意力机制集成信息，进一步提升了推荐性能。

1.2 对比学习

对比学习是一种新兴的自监督学习方法，核心在于利用正负样本对的对比关系来优化特征表示空间。该方法通过最小化正样本对距离的同时最大化负样本对差异，从而学习到判别性更强的特征表示，显著地提升了模型的特征能力。

为了一定程度上缓解会话推荐面临的数据稀疏和不同级物品之间的互信息难以捕获等问题。最近，自监督学习已应用于会话推荐系统。S²-DHCH^[11]模型开创性地将对比学习引入会话推荐领域，通过构建超图及其对应的线图，利用两者之间的自监督关系指导模型学习。A-HGNN^[12]设计了会话图和超图的双视图结构，并从两个视图监督和细化学习到的会话表示，提升了模型性能。CM-GNN^[13]模型在会话图和全局图融合的基础上，进一步引入了超图结构，并将不同视图的会话表示作为对比学习的输入，增强了模型的泛化性能。Ss-GNN^[14]通过构建会话图结构，采用图注意力网络并行学习物品级和会话级表征，并整合用户长期兴趣偏好与短期兴趣构建辅助任务，实现了自监督信号的自动化生成。ISHGL^[15]模型提出了一种创新的对比学习方法，该方法直接在意图层面构建自监督信号，避免了传统方法中复杂的数据增强和正负样本构造过程，简化了模型设计。

2 模型设计

2.1 问题表述

会话推荐旨在基于匿名用户的短期交互行为，挖掘用户偏好并预测其下一步可能交互的物品。形式上，令 $S=[s_1, s_2, \dots, s_M]$ 表示匿名会话的数据集，其中， M 为会话的数目； $V=[v_1, v_2, \dots, v_N]$ 表示所有交互物品的集合， N 为物品总数。给定一个会话序列 $s=[v_{s,1}, v_{s,2}, \dots, v_{s,n}]$ ，其中， $s \in S$ ， $v_{s,k}$ 表示用户在序列 s 中与之交互的第 k 个物品。本文采用序列拆分技术对原始数据进行了预处理，生成了一系列带有标注的训练样本序列 $([v_{s,1}], v_{s,2})$ 、 $([v_{s,1}, v_{s,2}], v_{s,3})$ 、 \dots 、 $([v_{s,1}, v_{s,2}, v_{s,3}, \dots, v_{s,m-1}], v_{s,m})$ ，对于每个会话序列 $S=[v_{s,1}, v_{s,2}, v_{s,3}, \dots, v_{s,m}]$ ，将其最后一个交互项 $v_{s,m}$ 作为标签，即模型需要预测的目标物品。

2.2 方法提出

超图作为一种特殊的图结构，可以有效地捕获物品之间的高阶关系^[14]。然而，会话推荐依赖于用户的短期交互行为，单一维度建模难以全面捕捉用户的多层次意图，加之数据稀疏性问题进一步影响了模型的泛化能力和推荐效果。近年来，对比学习作为一种自监督学习方法已被引入推荐领域来缓解数据稀疏问题，但如何选择合适的正对和负对依然是一个挑战。

综合以上几点，本文提出了一种CLMHC会话推荐模型，CLMHC模型的整体架构如图1所示。在全局超图通道模块中，将会话建模为超边，通过超图卷积捕获用户的全局偏好。在局部超图通道模块中，利用滑动窗口生成局部超图，借助超图注意力网络建模用户的局部兴趣。由于全局和局部意图均源于超图结构，二者在语义上具有相关性，因此，在对比学习模块中，引入了跨视图对比机制，作为正样本进行自监督训练，增强模型表示能力。最后，混合注意力模块融合

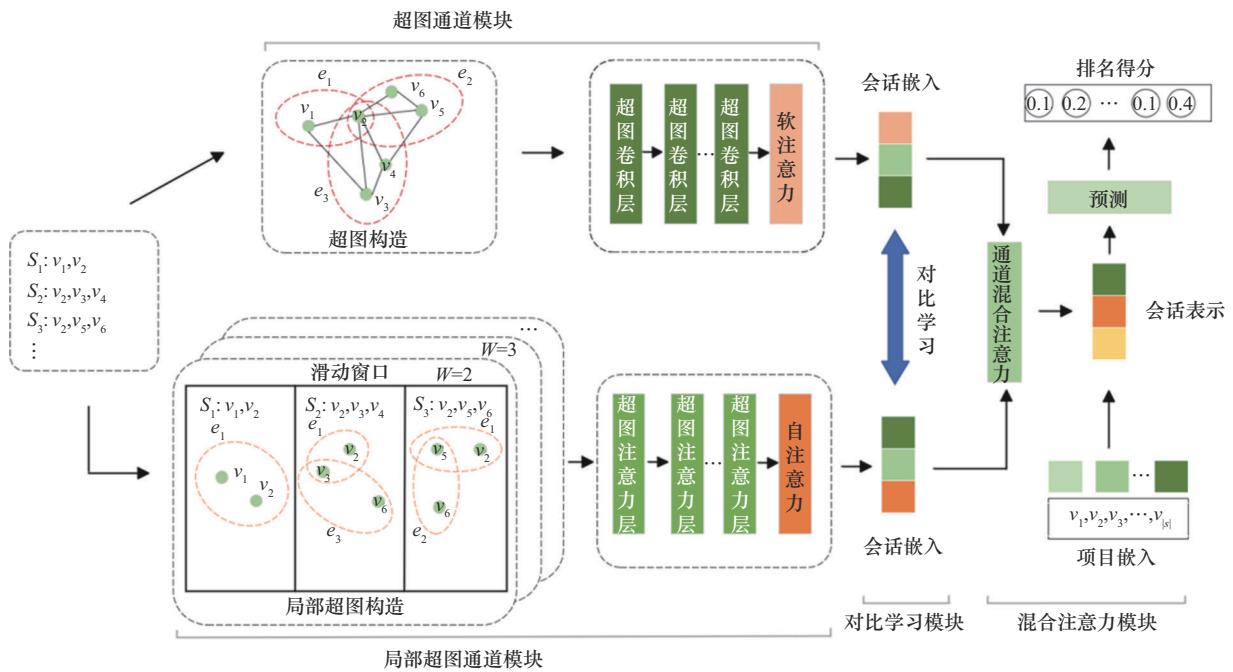


图1 CLMHC模型的整体架构

多通道特征，更全面地挖掘用户的真实意图，从而提升推荐性能。

2.3 多通道视图的构造

本文对原始会话构造了超图和局部超图两个视图来捕获会话信息，超图构造过程如图2所示。

为了捕捉所有会话中物品的高阶关系，本文将每个会话都视为一条超边，使不同的会话通过共享节点相互构成连接，而每个会话中的节点在超边中相互连接。图2中的会话 S_1 、 S_2 、 S_3 构造了超边 e_1 、 e_2 、 e_3 ，该结构建模了物品之间的复杂关系，有效地捕获了物品的全局特征。




图2 超图构造过程

除了超图，本文还构造了一个局部超图，局部超图的构造如图3所示。对于每个会话，考虑会话中每个物品可以为该物品提供的上下文信息，图3通过设置不同大小的滑动窗口来构建局部超图的超边，每个窗口覆盖的物品均作为该超边连接的节点。通过整合多个尺寸的滑动窗口，生成了与当前会话对应的局部超图。这种结构能




图3 局部超图的构造



够有效地捕获物品的局部特征，从而更全面地反映会话中的上下文信息。

2.4 超图卷积网络

超图可以形式化表示为 $G_g=(V,E)$ ，其中， V 表示所有会话中物品的节点集合， E 表示所有超边的集合。每条边包含两个或更多节点，边总数为 M 。每条边对应一个会话数据，不同的超边通过会话中的共享节点建立连接关系。本文使用超图卷积方法（hypergraph convolutional network, HGCN）来学习会话在超图中的物品嵌入，矩阵表示形式如下：

$$\mathbf{X}_h^{(l+l)} = \mathbf{D}^{-1} \mathbf{H} \mathbf{B}^{-1} \mathbf{H}^T \mathbf{X}_h^{(l)} \quad (1)$$

其中， $\mathbf{X}_h^{(l)}$ 和 $\mathbf{X}_h^{(l+1)}$ 分别表示所有物品节点在第 l 层和第 $l+1$ 层的嵌入表示， \mathbf{D} 和 \mathbf{B} 分别表示节点和超边的度矩阵， \mathbf{H} 表示节点-超边关联矩阵。这是一个两阶段的图卷积过程，执行“节点→超边→节点”两层特征转换， $\mathbf{H}^T \mathbf{X}_h^{(l)}$ 定义了从节点到超边的信息聚合，再经过 \mathbf{H} 表示从超边到节点的信息聚合， \mathbf{D}^{-1} 和 \mathbf{B}^{-1} 作为信息聚合过程中的归一化因子。

在经过 L 层超图卷积之后，为了充分融合不同层次的特征信息，本文对每一层的物品嵌入表示进行平均池化处理，从而得到全局超图的物品嵌入表示为：

$$\mathbf{X}_h = \frac{1}{L+1} \sum_{l=0}^L \mathbf{X}_h^{(l)} \quad (2)$$

该池化操作通过对各层嵌入的加权平均，不仅保留了低层卷积捕获的局部结构信息，还整合了高层卷积提取的全局语义特征，从而生成更具

表达力的物品表示。

两阶段超图卷积具体过程如图4所示。

为了捕获会话中的时序依赖关系，引入了一个可学习的位置编码矩阵 $\mathbf{P}=[\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_N]$ ，用于将反向位置嵌入与学习的物品表示相结合，表示如下：

$$\mathbf{x}_i^* = \tanh(\mathbf{W}_2[\mathbf{x}_i \parallel \mathbf{p}_{N-i+1}] + \mathbf{b}_2) \quad (3)$$

其中， \parallel 表示向量连接操作， \mathbf{W}_2 和 \mathbf{b}_2 分别表示可学习的权重矩阵和偏置向量。

接下来，对会话表示进行建模，以捕获用户的动态偏好。用户的动态偏好可以分为长期偏好和短期偏好。其中，长期偏好通过计算当前会话中所有物品嵌入的平均池化得到，表示为：

$$\bar{\mathbf{s}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i^* \quad (4)$$

短期偏好需要考虑不同会话物品的访问时间，越近访问的物品对用户的短期偏好影响越大，这里采用自注意力网络计算每个会话项的权重系数。

$$\beta_i = \mathbf{q}_2^T \sigma(\mathbf{W}_3 \bar{\mathbf{s}} + \mathbf{W}_4 \mathbf{x}_i^* + \mathbf{b}_3) \quad (5)$$

其中，得到的 β_i 值越大，代表第 i 个物品在会话建模中的重要性越大。

最终超图的会话表示向量 θ_s 的计算式为：

$$\theta_s = \sum_{i=1}^N \beta_i \mathbf{x}_i^* \quad (6)$$

2.5 超图注意力网络

局部超图可以形式化表示为 $G_l=(V_l, E_l)$ ， V_l 是当前会话中所有物品的集合， E_l 是通过不同尺寸滑动窗口构建的超边集合。虽然上述的全局超图结构已被简化以提高模型的计算效率，但局部超图




图4 两阶段超图卷积具体过程

中同一超边中的一些节点仍然能够为该超边提供一些信息，并对节点产生不同的影响。参考SHARE^[7]，本文采用超图注意力网络方法（hypergraph attention network, HGAT）来学习会话在局部超图中的物品嵌入表示。

与全局超图类似，局部超图的信息也是先从节点传递到超边，本文采用注意力机制来进行信息的传递，计算式为：

$$\mathbf{e}_j^{(l)} = \sum_{t \in N_j} \mathbf{h}_{t-j}^{(l)} \quad (7)$$

$$\mathbf{h}_{t-j}^{(l)} = \alpha_{jt} \mathbf{W}_1^{(l)} \mathbf{x}_t^{(l-1)} \quad (8)$$

其中， N_j 表示边 j 连接的所有项的集合， $\mathbf{e}_j^{(l)}$ 表示第 l 层边 j 的特征向量， $\mathbf{x}_t^{(l-1)}$ 表示第 $l-1$ 层物品 t 的输入表示， $\mathbf{h}_{t-j}^{(l)}$ 表示为在第 l 层超图注意力网络中，从节点 t 通过超边 j 传播的信息， $\mathbf{W}_1^{(l)} \in \mathbf{R}^{d \times d}$ 是可训练的参数矩阵。 α_{jt} 是超边 j 和物品 t 之间的注意力系数，计算式为：

$$\alpha_{jt} = \frac{S(\hat{\mathbf{W}}_1^{(l)} \mathbf{x}_t^{(l-1)}, \mathbf{u}^{(l)})}{\sum_{f \in N_j} S(\hat{\mathbf{W}}_1^{(l)} \mathbf{x}_f^{(l-1)}, \mathbf{u}^{(l)})} \quad (9)$$

其中， $\hat{\mathbf{W}}_1^{(l)} \in \mathbf{R}^{d \times d}$ ， $\mathbf{u}^{(l)} \in \mathbf{R}^d$ 分别是可训练参数矩阵和注意力参数。本文使用函数 $S(\cdot, \cdot)$ 来计算节点嵌入和上下文向量之间的相似性，具体是通过缩点积注意力来计算，如式（10）所示：

$$S(\mathbf{a}, \mathbf{b}) = \frac{\mathbf{a}^T \mathbf{b}}{\sqrt{D}} \quad (10)$$

在完成节点到超边传播的第一步后，为了更新节点的嵌入，要聚合来自其所有连接的超边的内容。类似的，从超边到节点的传播计算式为：

$$\mathbf{x}_t^{(l)} = \sum_{j \in Y_t} \mathbf{h}_{j-t}^{(l)} \quad (11)$$

$$\mathbf{h}_{j-t}^{(l)} = \beta_{jt} \mathbf{W}_2^{(l)} \mathbf{e}_j^{(l)} \quad (12)$$

其中， Y_t 表示连接到物品 t 的所有边， $\mathbf{h}_{j-t}^{(l)}$ 表示从边 j 到物品 t 传递的信息， $\mathbf{W}_2^{(l)} \in \mathbf{R}^{d \times d}$ 是可训练的参数矩阵。 β_{jt} 表示物品 t 和超边 j 之间的注意力系数，计算式为：

$$\beta_{jt} = \frac{S(\hat{\mathbf{W}}_2^{(l)} \mathbf{e}_j^{(l)}, \mathbf{W}_3^{(l)} \mathbf{x}_t^{(l-1)})}{\sum_{f \in Y_t} S(\hat{\mathbf{W}}_2^{(l)} \mathbf{e}_f^{(l)}, \mathbf{W}_3^{(l)} \mathbf{x}_t^{(l-1)})} \quad (13)$$

其中， $\hat{\mathbf{W}}_2^{(l)}$ ， $\hat{\mathbf{W}}_3^{(l)} \in \mathbf{R}^{d \times d}$ 是可训练的参数矩阵。

两阶段超图注意力网络执行过程如图5所示。

给定一个按顺序交互的会话 $[i_{s,1}, i_{s,2}, \dots, i_{s,t}]$ ，从上述的超图注意力网络的输出中查找相应的节点嵌入以获得物品嵌入集合 $[\mathbf{x}_{s,1}^{(L)}, \mathbf{x}_{s,2}^{(L)}, \dots, \mathbf{x}_{s,t}^{(L)}]$ 。为了生成局部超图的会话表示来编码会话的一般兴趣和当前需求，本文采用自注意力来进行会话建模，如下：

$$\mathbf{h}_s = \sum_{i \leq t} \sigma_{ti} \mathbf{W}_V \mathbf{x}_{s,i}^{(L)} \quad (14)$$

$$\sigma_{ti} = \frac{S(\mathbf{W}_Q \mathbf{x}_{s,t}^{(L)}, \mathbf{W}_K \mathbf{x}_{s,i}^{(L)})}{\sum_{j \leq t} S(\mathbf{W}_Q \mathbf{x}_{s,t}^{(L)}, \mathbf{W}_K \mathbf{x}_{s,j}^{(L)})} \quad (15)$$

其中， \mathbf{W}_Q 、 \mathbf{W}_K 和 \mathbf{W}_V 为可训练的向量， \mathbf{h}_s 为最终的局部超图会话表示向量。

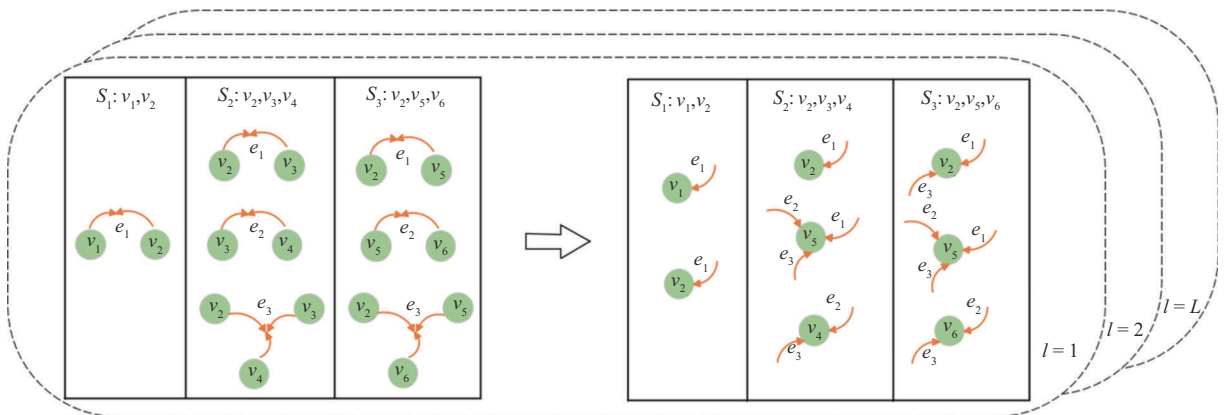


图5 两阶段超图注意力网络执行过程



2.6 通道混合注意力

本文分别从超图和局部超图通道中得到各自的会话表示 θ_s 和 h_s ，并设计了一个通道混合注意力模块自适应地学习两种嵌入的相对重要性。

$$\mathbf{u}_\theta = \mathbf{q}_1^T \tanh(\mathbf{W}_1 \theta_s + \mathbf{b}_1) \quad (16)$$

$$\mathbf{u}_h = \mathbf{q}_1^T \tanh(\mathbf{W}_1 h_s + \mathbf{b}_1) \quad (17)$$

其中， \mathbf{q}_1 、 \mathbf{W}_1 和 \mathbf{b}_1 分别表示可学习的注意力向量、权重矩阵和偏置向量。

接下来将不同嵌入向量的相对重要性转化为权重系数。

$$a_\theta = \frac{\exp(\mathbf{u}_\theta)}{\exp(\mathbf{u}_\theta) + \exp(\mathbf{u}_h)} \quad (18)$$

$$a_h = 1 - a_\theta \quad (19)$$

最后的会话物品嵌入为两个通道得到的物品嵌入的融合。

$$\mathbf{f}_s = a_\theta \theta_s + a_h h_s \quad (20)$$

2.7 对比学习的应用

为了缓解数据稀疏性问题，本文采用对比学习方法对会话表示生成过程进行监督，旨在最大化两个视图中会话表示之间的互信息。对比学习的关键在于正负样本对的构建，由于本文构造的两个视图中的会话表示 θ_s 和 h_s 均基于超图生成，因此可以将它们视为正样本对。基于此，设计了一个标准的二元交叉熵损失函数：

$$\mathcal{L}_s = -\log \sigma(\text{sim}(\theta_i^s, h_i^s)) - \log \sigma(1 - \text{sim}(\tilde{\theta}_i^s, \tilde{h}_i^s)) \quad (21)$$

其中， $\tilde{\theta}_i^s$ 、 \tilde{h}_i^s 是通过行列变换破坏 θ_i^s 、 h_i^s 获得的负样本。 $\text{sim}(\cdot, \cdot)$ 表示相似性度量函数来衡量每个表示之间的相似性，本文用点积作为 $\text{sim}(\cdot, \cdot)$ 来简化计算。

2.8 预测层

对于一个给定的候选物品 v_j ，该物品在会话 s 中的预测评分值用会话表示与物品表示的相似性计算得到：

$$\hat{z}_j = \mathbf{f}_s^T \mathbf{x}_j \quad (22)$$

其中， \mathbf{x}_j 表示物品 v_j 通过超图通道的物品嵌入表示。

接下来利用 softmax 函数得到每个候选物品

的下一跳访问概率。

$$\hat{y}_j = \text{softmax}(\hat{z}_j) \quad (23)$$

为了优化模型，使用交叉熵函数作为损失函数，定义为：

$$\mathcal{L}_r = -\sum_{i=1}^n (y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) \quad (24)$$

其中， y_i 表示测试集中真正的下一跳会话物品。

最后，采用多任务学习方法将推荐任务和自对比学习任务进行集成，实现联合优化。

$$\mathcal{L} = \mathcal{L}_r + \beta \mathcal{L}_s \quad (25)$$

其中， β 为控制自我监督任务的大小。

3 实验结果与分析

3.1 数据集

本文在 3 个公开的真实场景数据集上对所提模型进行了评估，包括 Diginetica、Tmall 和 RetailRocket 数据集。Diginetica 数据集来源于 CIKM Cup 2016，主要包含用户的交易记录。Tmall 数据集提取自 IJCAI-15，记录了 Tmall 平台上匿名用户的购物行为日志。RetailRocket 数据集则由一家电子商务公司发布在 Kaggle 上，涵盖了用户在 4 个半月内的浏览行为数据。为了确保数据质量，对这 3 个数据集进行了预处理，剔除了仅包含单个物品的会话以及出现频率低于 5 次的稀疏物品，从而有效地降低了噪声对模型性能的影响，数据集统计见表 1。

表 1 数据集统计

数据集	Tmall	RetailRocket	Diginetica
训练集会话数	321,268	433,648	719,470
测试集会话数	25,898	15,132	60,858
项目数	40,728	36,968	43,097
平均长度	6.69	5.43	5.12

3.2 评价指标

本次实验采用 HR@K 和 MRR@K 两个基于排名的指标来评估推荐结果。HR@K 用来衡量推荐的准确性，表示生成的 K 个推荐结果中正确物品

的比例，定义为

$$HR@K = \frac{Hit_n}{N} \quad (26)$$

其中， Hit_n 表示在生成的 K 个排序列表中正确物品的数量， N 是测试集的总数量。 $HR@K$ 的值越大，推荐结果越准确。

$MRR@K$ 强调正确物品的排名，用于衡量推荐排名的顺序，定义为

$$MRR@K = \frac{1}{N} \sum_{i=0}^N \frac{1}{rank(i)} \quad (27)$$

其中， N 是测试集的总数量， $rank(i)$ 表示在第 i 个测试样本中生成的列表中正确物品的排名，如果正确物品不在生成的列表中，则 $1/rank(i)$ 被设置为 0。 $MRR@K$ 的值越大，表示正确物品的排名越高。

3.3 基准模型

通过与以下 7 个模型的结果比较，证明了 CLMHC 模型在提高推荐性能方面的能力。

Item-KNN^[16]：通过计算物品之间的余弦相似度来推荐相似产品。

GRU4Rec^[1]：将用户的当前会话视为序列，通过门控循环网络计算会话特征表示。

STAMP^[17]：用多个注意力机制替代循环神经网络，并捕获会话最后一个节点上的短期偏好。

SR-GNN^[18]：通过将多个会话建模为有向图，在图神经网络中学习特征表示，并通过注意

力机制融合会话中多个物品的特征表示。

SHARE^[7]：在单个会话序列上设置上下文窗口，以捕获会话内物品之间的复杂交互。

DHCN^[11]：分别构建超图和线图，通过超图神经网络计算物品和会话的特征表示，并通过比较学习方法学习它们之间的互信息。

HyperS²Rec^[9]：使用超图卷积网络和门控循环单元分别学习两种物品嵌入，然后将两种嵌入使用注意力机制进行结合。

3.4 对比实验

不同模型的推荐性能比较见表 2，其中，展示了不同模型在 3 个数据集上的性能表现。为了方便比较，表中使用粗体标注了性能最优的模型，次优模型以下划线标识。从实验结果可以看出，本文所提的 CLMHC 模型在 3 个常用数据集上效果都有明显的提升。说明融合超图模块、局部超图模块和对比学习模块的协同作用显著地提升了模型的整体性能。

3.5 消融实验

本文所提的模型由多个关键组件构成。为了验证各组件对模型性能的贡献，设计了 4 个变体来进行消融实验。消融实验结果如图 6 所示。其中，CLMHC-HG 表示模型未引入超图通道模块，仅依赖局部超图通道对用户兴趣进行建模；

表 2 不同模型的推荐性能比较

方法	Tmall				RetailRocket				Diginetica			
	H@10	M@10	H@20	M@20	H@10	M@10	H@20	M@20	H@10	M@10	H@20	M@20
Item-KNN	6.65	3.11	9.15	3.31	22.48	10.43	28.97	10.98	25.07	10.77	35.75	11.57
GRU4Rec	9.47	5.78	10.93	5.89	38.35	23.27	44.01	23.67	17.93	7.33	29.45	8.33
STAMP	22.63	13.12	26.47	13.36	42.95	24.61	50.96	25.17	33.98	14.26	45.64	14.32
SR-GNN	23.41	13.45	27.57	13.72	43.21	26.07	50.32	26.57	36.86	15.52	50.73	17.59
SHARE	25.04	13.98	29.69	14.24	46.47	26.59	54.16	27.11	39.52	17.12	52.73	18.05
DHCN	<u>29.25</u>	<u>16.33</u>	<u>35.15</u>	<u>16.75</u>	48.06	28.41	55.83	28.95	39.66	17.40	53.11	18.31
HyperS ² Rec	27.26	14.98	32.91	15.39	<u>49.11</u>	<u>29.44</u>	<u>56.71</u>	<u>29.95</u>	<u>40.23</u>	<u>17.50</u>	<u>53.58</u>	<u>18.47</u>
CLMHC	30.65	17.06	36.72	17.48	50.27	29.73	57.99	30.46	41.51	18.21	55.07	19.19
提升百分比	4.7%	5.7%	4.5%	4.4%	2.4%	1.0%	2.3%	1.7%	3.2%	2.3%	2.8%	3.9%

注：H@K 即 HR@K，M@K 即 MRR@K。



CLMHC-LHG 表示模型未引入局部超图通道模块，仅通过超图通道对用户兴趣进行建模；CLMHC-F 表示模型未使用通道混合注意力机制模块，而是采用简单的相加法对不同用户兴趣进行融合；CLMHC-CL 表示模型未引入对比学习模块，没有对从两个通道学习到的用户兴趣向量进行对比优化；CLMHC 代表本文所提模型。

在捕获不同会话之间的相关性方面更具优势。此外，通过比较 CLMHC-F 与 CLMHC-HG 和 CLMHC-LHG 的性能，得知融合不同维度的用户兴趣相较于对单一维度用户兴趣建模能取得更好的效果。同时，CLMHC-F 和 CLMHC-CL 的对比验证了本文所提的混合通道注意力机制模块和对比学习模块的有效性。CLMHC 在 3 个数据集上的出色表现，充分证明了本文所提模型具有优异的性能。

3.6 参数敏感性实验

在实验设置中，将嵌入维度设置为 100，批量大小设置为 100，初始化所有可训练参数为均值为 0、标准差为 0.1 的高斯分布。优化器采用 Adam，初始学习率为 0.001。训练 epoch 统一设置为 30。为分析不同模型性能对不同因素的敏感性，参考 HyperS²Rec^[9] 的研究，将层数分别设置为 1 至 5，进行对比实验。局部滑动窗口尺寸设置为 1 至 5。此外，对比学习系数参照 S²-DHCN^[11] 设置为 0.001、0.010、0.020、0.030、0.040 以分析其对模型性能的影响。HGAT 层数对 CLMHC 模型性能的影响、HGAT 层数对 CLMHC 模型性能的影响、滑动窗口大小对 CLMHC 模型性能的影响、对比学习系数对 CLMHC 模型性能的影响分别如图 7、图 8、图 9、图 10 所示。




图6 消融实验结果

对图 6 进行分析，发现 CLMHC 的性能表现最优异。在对比中，观察到 CLMHC-HG 相较于 CLMHC-LHG 性能下降更显著，这表明全局超图

通过对图 7 进行分析，观察到在 Tmall 数据集上，当 HGAT 层数设为 1 时模型性能最优，随着层数增加，性能出现明显下降；而在 Diginetica 与 RetailRocket 数据集上，3 层结构带来最佳表现。本文认为这种差异可能源于数据集间会话长度的不同。Tmall 数据集中较长的会话序列使单层超图卷积足以捕捉会话内部的一致性信息，而 Diginetica 与 RetailRocket 数据集的短会话则须更深的结构以增强节点间的关联建模。对图 8 结果分析得知，当 HGAT 的层数分别设置为 3 (Tmall)、2 (Diginetica) 和 4 (RetailRocket) 时性能最优。因此推测，适中的注意力层数有助于




图7 HGCN层数对CLMHC模型性能的影响




图8 HGAT层数对CLMHC模型性能的影响




图9 滑动窗口大小对CLMHC模型性能的影响




图10 对比学习系数对CLMHC模型性能的影响

平衡信息表达能力与节点信息的渐进式融合，避免因网络层数过深造成表征能力下降。在图9中，相较于 Diginetica 数据集，Tmall 与 RetailRocket 数据集在较大滑动窗口设置下性能更佳。可能是

后者会话长度较长，较大的滑动窗口能生成更多超边，从而可以更全面地建模会话结构。最后，对图10分析可知，较小的对比学习损失系数有利于性能提升，而增大该系数会造成明显的性能下



降。这可能是由于对比损失权重过高时，主任务与辅助任务间的梯度干扰加剧，从而影响模型训练的稳定性和效果。

4 结束语

本文提出了一种新型会话推荐模型 CLMHC，相较于传统的 GNN 方法，该模型引入了超图结构以更好地捕获会话间的高阶关联信息。具体而言，本文设计了超图通道和局部超图通道：前者用于建模不同会话之间的全局依赖关系，后者专注于捕获会话内部的上下文信息，并通过实验验证了通道混合注意力机制在多维信息融合方面的有效性。此外，模型还引入了对比学习模块，通过将两个超图通道得到的会话项嵌入作为正样本进行自监督训练，解决了对比学习中正负样本选择的难题。这种方法不仅有效地缓解了会话推荐中的数据稀疏问题，还显著地提升了模型的性能。

参考文献：

- [1] HIDASIB, KARATZOGLOUA, BALTRUNAS L, et al. Session-based recommendations with recurrent neural networks[EB]. arXiv preprint, 2015, arXiv: 1511.06939
- [2] YUAN F J, ALEXANDROS K, IOANNIS A, et al. A simple convolutional generative network for next item recommendation[C]//Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining (WSDM). New York: ACM Press, 2019: 582-590.
- [3] SCARSELLI F, GORI M, TSOI A H, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2009, 20(1): 61-80.
- [4] YUAN J H, SONG Z H, SUN M Y, et al. Dual sparse attention network for session-based recommendation[C]//Proceedings of the Thirtyfifth AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2021, 35(5): 4635-4643.
- [5] 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 (WSDM). New York: ACM Press, 2023: 168-176.
- [6] FENG Y F, YOU H X, ZHANG Z Z, et al. Hypergraph neural networks[C]//Proceedings of the Thirtythird AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2019: 3558-3565.
- [7] WANG J L, DING K Z, ZHU Z W, et al. Session-based recommendation with hypergraph attention networks[C]//Proceedings of the 2021 SIAM International Conference on Data Mining (SDM). Piscataway: IEEE Press, 2021: 82-90.
- [8] PENG D L, ZHANG S. GC-HGNN: a global-context supported hypergraph neural network for enhancing session-based recommendation[J]. Electronic Commerce Research and Applications, 2022, 52(C): 101129.
- [9] DING C X, ZHONG Z Y, LI C, et al. Session-based recommendation with hypergraph convolutional networks and sequential information embeddings[J]. Expert Systems with Applications, 2023, 223: 119875-119875.
- [10] ZHANG Z G, ZHANG H M, ZHANG Z F, et al. Context-embedded hypergraph attention network and self-attention for session recommendation[J]. Scientific Reports, 2024, 14(1): 19413.
- [11] XIA X, YIN H Z, YU J L, et al. Self-supervised hypergraph convolutional networks for session-based recommendation[C]//Proceedings of the Thirtyfifth AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2021, 35(5): 4503-4511.
- [12] LI X B, TANG Y, GUO C J, et al. Attribute-enhanced hypergraph neural networks for session-based recommendation[C]//Proceedings of the Thirtyfourth International Joint Conference on Neural Networks (IJCNN). Piscataway: IEEE Press, 2024: 1-7.
- [13] WANG F Y, GAO X Y, CHEN Z Y, et al. Contrastive multi-level graph neural networks for session-based recommendation[J]. IEEE Transactions on Multimedia, 2023, 25: 9278-9289.
- [14] ZHAO Q B, ZHOU X M, ZHANG X Z, et al. Unified Empirical Evaluation and Comparison of Session-based Recommendation Algorithms[J]. ACM Computing Surveys, 2025, 57(10): 1-39.
- [15] FANG X S, WU Y G, LU J H, et al. Intent enhanced self-supervised hypergraph learning for session-based recommendation[C]//Proceedings of the 2024 European Conference on Machine Learning and Knowledge Discovery in Databases. Vilnius, Lithuania: ECML PKDD Press, 2024: 83-99.
- [16] SARWAR B, KARYPIS G, KONSTAN J, et al. Item-based col-

laborative filtering recommendation algorithms[C]//Proceedings of the Tenth International World Wide Web Conference. New York: ACM Press, 2001: 285-295.

[17] LIU Q, ZENG Y F, MOKHOSI R, et al. Stamp: short-term attention memory priority model for session-based recommendation[C]//Proceedings of the Twentyfourth ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2018, 1831-1839.

[18] WU S, TANG Y Y, ZHU Y Q, et al. Session-based recommendation with graph neural networks[C]//Proceedings of the Thirtythird International Joint Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2019, 33(1): 346-353.

[作者简介]



任宇彬 (2000-), 男, 湖州师范学院信息工程学院硕士生, 主要研究方向为个性化推荐、数据挖掘。



王瑞琴 (1979-), 女, 博士, 湖州师范学院信息工程学院教授, 主要研究方向为自然语言处理、社交网络分析、个性化推荐。



隋欣怡 (2000-), 女, 湖州师范学院信息工程学院硕士生, 主要研究方向为深度学习、自然语言处理、个性化推荐。



方驰 (2000-), 男, 湖州师范学院信息工程学院硕士生, 主要研究方向为序列推荐、多模态推荐。