

# 基于重复感知与频率增强的动态图推荐研究

吴国栋, 黄雯婧, 鲍宪立, 李景霞, 谢东辰

(安徽农业大学信息与人工智能学院, 安徽合肥 230036)

**摘要:** 针对现有图神经网络推荐研究较少考虑历史交互重复行为模式及其时间维度上的频率特性, 难以捕获节点交互随时间演变的“偏移”问题, 融合重复感知邻居采样与频率域分析, 设计了一种基于重复感知与频率增强的动态图推荐模型 (Repetition and Frequency-enhance Dynamic Graph Recommendation, ReFDGRec). ReFDGRec 引入一种重复感知邻居采样策略, 不仅考虑单个节点的即时邻域, 还能深入挖掘已发生过交互的节点对信息, 以更精确地识别并挖掘用户与物品之间的高频交互模式, 捕捉用户行为的动态演变, 从而为模型提供更丰富的输入特征. 同时, 结合连续小波变换 (Continuous Wavelet Transform, CWT) 具有的多分辨率分析特征, 可以在不同时间尺度上处理用户行为的非平稳性和动态变化, 有效捕捉用户行为中的周期性趋势和突发性偏好. 通过 CWT 将用户行为时间序列转换为频率域, 以此捕获长周期趋势和短期波动, 有效缓解了现有方法在处理用户行为非平稳性时的不足, 提升了模型在处理用户突发性偏好和动态兴趣转移时的性能, 以提供更精确的个性化推荐. 为全面评估模型性能, 分别在 Wikipedia、UCI、MOOC 和 MovieLens 四个公开数据集上进行了系统实验, 涵盖了直推式预测与归纳式预测两种动态图推荐场景, 并采用随机、历史及归纳三类负采样策略以确保评估严谨性与公平性. 实验结果表明: 在平均精度指标上, ReFDGRec 相比 DySAT、TGAT、TGN、GraphMixer 及 RepeatMixer 等主流基线模型均取得显著的性能提升, 实现了平均 2.3%~6.9% 的性能增益; 消融实验验证了节点交互频率编码方法与连续小波变换增强模块在提升模型性能中的关键作用; 时频分析方法对比结果显示, 连续小波变换在处理非平稳行为序列方面明显优于离散傅里叶变换与短时傅里叶变换. 本文通过理论引导的重复感知机制与信号处理驱动的频域增强技术, 为动态图推荐系统研究提供了一种能够有效捕获兴趣演化与行为偏移的解决方案, 具有一定的理论创新与实践价值.

**关键词:** 动态图; 推荐; 重复感知; 小波变换; 频率增强

**基金项目:** 国家自然科学基金 (No.32371993); 安徽省高校自然科学研究重点项目 (No.2024AH050443); 安徽省自然科学基金 (No.2108085MF209); 安徽省科技重大专项 (No.202103b06020013)

**中图分类号:** TP399 **文献标识码:** A **文章编号:** 0372-2112(2025)12-4429-15

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

**DOI:** 10.12263/DZXB.20250654

## Research on Dynamic Graph Recommendation Based on Repeat-Aware and Frequency Enhancement

WU Guo-dong, HUANG Wen-jing, BAO Xian-li, LI Jing-xia, XIE Dong-chen

(School of Information and Artificial Intelligence, Anhui Agricultural University, Hefei, Anhui 230036, China)

**Abstract:** Current graph neural network-based recommendation studies rarely consider the repetitive behavior patterns of historical interactions and their frequency characteristics in the temporal dimension, making it difficult to capture the “shift” in node interactions over time. To address this, we propose a repetition and frequency-enhanced dynamic graph recommendation model (ReFDGRec) that integrates repetition-aware neighbor sampling with frequency domain analysis. ReFDGRec introduces a repetition-aware neighbor sampling strategy that not only considers the immediate neighborhood of individual nodes but also deeply explores node pairs with prior interactions, leveraging relevant historical information to enhance the understanding of node relationships. This approach enables more precise identification and extraction of high-frequency interaction patterns between users and items, capturing the dynamic evolution of user behavior and providing richer input features for the model. Additionally, considering the multi-resolution analysis capabilities of continuous wavelet transform (CWT), ReFDGRec effectively handles the non-stationarity and dynamic changes in user behavior across different

time scales, capturing periodic trends and abrupt preference shifts. By CWT transforming user behavior time series into the frequency domain, it simultaneously captures long-term trends and short-term fluctuations, effectively addressing the limitations of existing methods in handling non-stationary user behavior. This enhances the model's performance in managing abrupt user preferences and dynamic interest shifts, delivering more accurate personalized recommendation services. To comprehensively evaluate the performance of the proposed model, systematic experiments are conducted on four public datasets, namely Wikipedia, UCI, MOOC, and MovieLens, covering both transductive and inductive dynamic recommendation scenarios. In addition, three negative sampling strategies, including random, historical, and inductive sampling, are employed to ensure the rigor and fairness of the evaluation. Experimental results demonstrate that ReFDGRec consistently outperforms state-of-the-art baseline models such as DySAT, TGAT, TGN, GraphMixer, and RepeatMixer in terms of average precision metrics, achieving an average performance improvement of 2.3%~6.9%. Ablation studies further confirm the critical contributions of the node interaction frequency encoding scheme and the CWT-based enhancement module to the overall performance gains. Moreover, comparative analyses of time-frequency modeling methods indicate that the continuous wavelet transform is markedly more effective than the discrete Fourier transform and the short-time Fourier transform in modeling non-stationary behavioral sequences. By leveraging a theoretically guided repetition-aware mechanism and signal processing-driven frequency-domain enhancement techniques, this work provides a solution for dynamic graph recommendation that effectively captures interest evolution and behavioral drift, and has certain theoretical innovation and practical value.

**Key words:** dynamic graph; recommendation; repeat-aware; wavelet transform; frequency-enhanced

**Foundation Item(s):** National Natural Science Foundation of China (No.32371993); Key Project of Natural Science Research in Universities of Anhui Province (No.2024AH050443); Natural Science Foundation of Anhui Province (No.2108085MF209); Major Science and Technology Project of Anhui Province (No.202103b06020013)

## 1 引言

随着互联网数据的爆炸式增长,信息过载问题日益严重,如何帮助用户迅速找到感兴趣的内容,成为一个有待解决的挑战.推荐系统通过分析用户的历史行为、兴趣偏好及其他关联数据,提供个性化的商品、服务或内容推荐,从而更好提升用户体验<sup>[1]</sup>.然而,随着用户需求日趋复杂化和多样化,传统推荐方法在处理动态用户行为信息和大规模数据时表现出明显不足,难以捕捉用户兴趣的时序性变化和长期演化规律.面对用户兴趣的频繁变化和实时更新的需求,动态图神经网络推荐研究受到广泛关注<sup>[2]</sup>.现有静态图推荐方法在面对动态系统时表现不佳,特别是在捕捉交互的重复性和用户偏好随时间变化特征方面<sup>[3]</sup>,难以捕捉到节点交互模式随时间演变的“偏移”现象<sup>[4]</sup>.同时,静态图推荐中常用的图神经网络邻域聚合机制,会显著放大用户隐式行为中的噪声,导致用户与物品的向量表示偏离真实偏好<sup>[5]</sup>.动态图推荐通过将时间维度融入网络建模,能够更好地捕捉用户兴趣的动态演变,进而提供更为精准的个性化推荐<sup>[6]</sup>.图1体现了不同季节用户兴趣变化导致的兴趣偏移现象.图1中的 $t_a$ 和 $t_b$ 阶段,模型主要关注夏季活动(如游泳)和夏季服装(如短袖),从而学习到这些夏季特有的行为模式.然而,当季节转变为冬季( $t_c$ )时,用户行为发生了变化,用户兴趣转向冬季活动(如滑雪)和冬季服装(如外套),但模型由于之前在夏季学到的模式,错误地向用户推荐冰激凌.由此可以看出,用户行为具有非平稳性,即用户的

交互模式不会长期保持固定,其统计特征往往会随时间变化.如何在复杂的交互中有效建模用户行为的动态性,实现对非平稳兴趣的预测尤为重要.现有研究在处理用户与物品重复交互时,通常仅依赖简单邻居采样方法,缺乏对重复交互行为模式的捕获,难以准确反映用户的长期偏好.此外,在用户行为的动态性处理方面,现有研究较少考虑对用户潜在的行为周期性和突发性变化的频率域分析,模型不能较好反映用户兴趣动态变化,即面对用户兴趣的非平稳性时表现出预测不稳定和精度下降的问题.




图1 不同季节用户兴趣变化导致的偏移现象

为应对上述挑战,本文设计了一种基于重复感知与频率增强的动态图推荐模型(Repetition and Frequency-enhance Dynamic Graph Recommendation, ReFDGRec).

本文的研究内容及创新点主要体现在:

(1)针对现有图神经网络推荐研究对用户重复行为模式捕获不足问题,设计了一种面向不同推荐场景

的重复感知邻居采样策略,旨在更精确地识别并挖掘用户与物品之间的高频交互.这一策略通过分析用户历史交互记录,特别是交互中的重复行为特征,以提升模型对用户行为随时间演变的理解能力,尤其面向复杂的动态网络环境,能够更好地捕捉用户行为变化,从而提升个性化推荐效果.

(2)为更好地处理用户行为的非平稳性和时间动态性,ReFDGRec模型中引入连续小波变换(Continuous Wavelet Transform, CWT)技术.借助CWT的时频分析能力,模型能够有效捕捉用户行为中的周期性与突发性变化.通过将用户行为的时间序列转换为频率域,从时间与频率双重视角,同时捕捉长周期趋势和短期行为波动,提升模型应对动态兴趣迁移和突发偏好的能力.

## 2 相关工作

### 2.1 动态图推荐

现有图神经网络(Graph Neural Network, GNN)推荐研究主要基于静态图,而用户兴趣往往具有动态性<sup>[7]</sup>.例如,在序列推荐或基于会话的推荐中,自然地以动态的方式去收集用户行为数据<sup>[8,9]</sup>,对动态用户偏好的建模是这些推荐场景的关键挑战之一.根据不同的时间粒度,动态图可以分为离散时间动态图(Discrete-Time Dynamic Graph, DTDG)和连续时间动态图(Continuous Time Dynamic Graph, CTDG)<sup>[10]</sup>.

对于DTDGs中推荐,DySAT<sup>[11]</sup>通过沿着邻域结构和时间动力学两个维度的联合注意力机制来计算动态节点的表示.针对动态图网络中节点的动态加入和退出问题,EvolocGCN<sup>[12]</sup>使用RNN(Recurrent Neural Network)<sup>[13]</sup>演化GCN的参数,而无需依赖于节点嵌入.DyRep<sup>[14]</sup>利用深度时间过程模型将图上结构和时间信息编码成低维表示.DRL-SRe<sup>[15]</sup>通过构建时间切片的用户-项目交互图,并利用时间切片图神经网络来学习用户和项目动态表示.WinGNN<sup>[16]</sup>利用滑动窗口上的随机梯度聚合思想来模拟没有时间编码器的时间模式.SFDyG<sup>[17]</sup>通过融合多时序快照构建统一时间图,结合霍克斯过程驱动的图神经网络实现高效动态图建模.然而,如何确定DTDGs的最佳时间粒度仍然是一个有待解决的问题.在CTDGs领域中,为增强细粒度时间信息的整合,TGAT<sup>[18]</sup>在GAT上引用时间编码技术,从谐波分析中的Bochner定理引入一个复杂的时间编码模块.TGN<sup>[19]</sup>提出一个更通用框架,可以合并节点的时间特征.另外TGN还采用一种存储模块,用于存储用户-物品交互的历史信息,以此预测未来的交互.JODIE<sup>[20]</sup>通过在耦合RNN框架内引入线性嵌入投影器来解决已过时嵌入的挑战.TGSRec<sup>[21]</sup>引入时态协作

Transformer<sup>[22]</sup>,以显式地模拟交互的时态效应.DGSR<sup>[23]</sup>通过设计动态图推荐网络来显示编码不同用户序列之间的动态协同信号.DGEL<sup>[24]</sup>基于实时更新学习方法来捕捉用户和物品的动态演变,从而提升动态环境下的推荐质量.DyGFormer<sup>[25]</sup>采用邻居共现的编码方案,将每个源/目的节点的序列拆分为多个时间序列块,然后将它们输送到Transformer模型获取节点的表示.GraphMixer<sup>[26]</sup>采用简单MLP<sup>[27]</sup>架构,使用固定时间编码函数,结合邻居均值池化的节点编码获取节点特征.SR-GNN<sup>[28]</sup>提出一种基于交互序列商品相关性建模的图卷积会话推荐方法,通过构建用户与商品间的交互图,利用图卷积网络捕捉商品之间的高阶相关性.DCE<sup>[29]</sup>通过深度学习模型捕捉社交图像中的复杂特征和用户偏好,以实现更精准的图像推荐,该方法在处理多模态数据(如图像和文本)方面表现出色.CT-Walks<sup>[30]</sup>提出社区感知时序游走框架,通过无参数游走采样机制整合社区结构,结合社区标签匿名化与神经微分方程连续动态建模,精准捕捉社区内外动态交互.RepeatMixer<sup>[31]</sup>通过repeat-aware邻居采样策略和时间感知聚合机制,在动态图学习中取得了一定效果,但其主要面向同构图链路预测和节点分类任务.在推荐场景中,不仅存在同构图交互,还存在大量、复杂的异构图交互.异构图中用户和物品间的交互,涉及不同类型节点和边,难以直接运用RepeatMixer进行推荐.本文的ReFDGRec模型,提出一种面向不同推荐场景的用户和物品交互重复感知采样策略,以更精准地捕捉动态图中不同节点间关联.此外,ReFDGRec还采用CWT捕捉用户行为的周期与突发偏好.

### 2.2 连续小波变换

连续小波变换可以将时间域的采样信号转换到频率域<sup>[32]</sup>,能同时揭示信号的时域和频域特征,且具有良好的时频局部化特性,是一种强大的时频分析技术,特别适合于分析非平稳信号.推荐系统中,采用CWT能够帮助模型有效捕获用户行为中的周期性模式和动态变化.如通过将用户的时间序列行为映射到频率域,CWT能够识别出用户行为中的高频与低频模式,这对捕捉短期的突发性偏好和长期的周期性偏好尤为重要.传统的时间域分析中,捕捉这些行为特征往往需要复杂的建模和大量的时间维度信息.而CWT能够通过在不同时间尺度上分析信号,提供细粒度的时频信息,帮助模型精准识别用户行为的各类模式.相比传统的傅里叶变换,CWT能够在同时维持时间和频率信息的情况下对信号进行分析,这意味着它不仅可以发现行为中的周期性特征,还可以识别用户行为随时间变化的模式.尤其是在捕捉用户行为的突发性变化时,CWT的这一特性可以帮助模型识别到行为变化的关键时刻,并迅速调

整推荐结果,以提供更符合用户当前需求的内容。

### 3 ReFDGRec 模型

基于重复感知与频率增强的动态图推荐模型 ReFDGRec,主要由三部分组成。(1)动态图构建.通过用户与物品的历史交互数据构建连续时间动态图(CTDG),动态地捕捉交互关系的演变。(2)重复感知邻居节点采样策略.引入一阶和高阶重复感知采样机制,用于捕捉用户与物品之间的重复交互行为模式.通过该策略,不仅能够从当前交互行为中提取即时信息,还能够深入挖掘历史交互中的行为模式,以增强对用户行为偏好的理解。(3)频率增强的动态图推荐网络.该

模块由编码层、频率感知增强层、推荐和优化三个核心部分组成.编码层利用RNN编码器捕获用户/物品与其邻居之间的长期时间依赖关系,并采用余弦时间编码函数对时间间隔信息进行编码.频率感知增强层引入CWT和频率增强的多层感知机混合层(MLP-Mixer),自适应地增强用户和物品交互的频率成分,帮助模型捕捉交互行为中的周期性特征和频率变化.推荐和优化是在给定用户和物品的交互数据和时间戳的情况下,模型将输出排序列表,通过结合一阶和高阶邻居的嵌入表示生成更准确的推荐结果,并基于优化策略对模型进行进一步提升.ReFDGRec模型结构如图2所示。

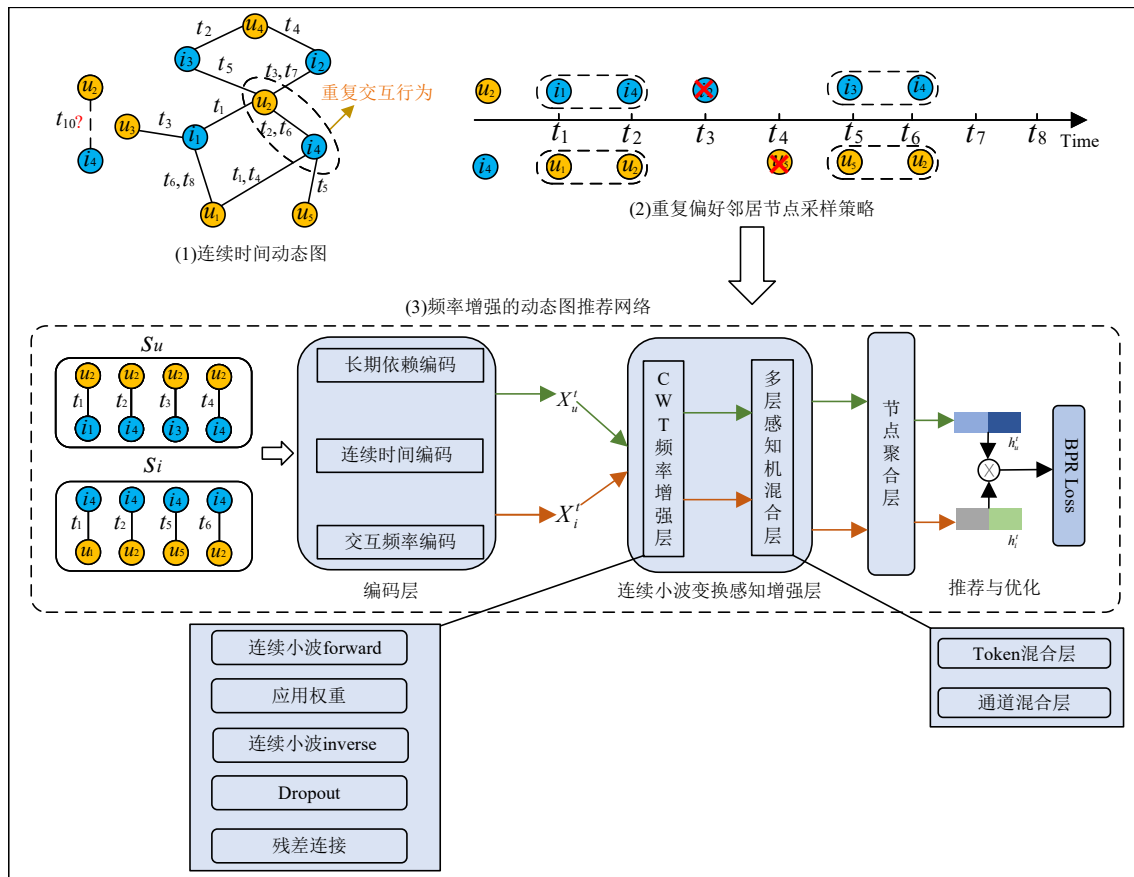


图2 ReFDGRec模型

#### 3.1 动态图推荐任务定义

在动态图推荐任务中,一个连续时间二部图可以表示为用户物品对之间的时间交互序列  $G = \{(u_0, i_0, t_0), (u_1, i_1, t_1), \dots, (u_n, i_n, t_n)\}$ , 其中  $t_i$  表示时间戳,时间戳按顺序排列为  $(0 \leq t_0 \leq t_1 \leq \dots \leq t_n)$ ,  $u_k \in U, i_k \in I$  表示第  $k$  次交互在时间戳  $t_k$  上的ID,其中  $U$  和  $I$  是所有用户和物品的完整集合.每个用户  $u \in U$  关联有用户特征  $x_u \in \mathbf{R}^{d_u}$ , 每个物品  $i \in I$  关联有物品特征  $x_i \in \mathbf{R}^{d_i}$ , 每次交互  $(u, i, t)$  具有边特征  $e_{u,i}^t \in \mathbf{R}^{d_e}$ , 其中  $d_u$  是用户的维度,  $d_e$

是边特征的维度.用户与物品之间的交互可以通过  $y_{u,i}^t$  来表示,其中当用户  $u$  在时间  $t$  与物品  $i$  有交互时,  $y_{u,i}^t = 1$ ; 否则为0.最终,通过预测  $y_{u,i}^t$  的值为每个用户在特定的时间点选择并推荐前  $k$  个物品,从而为每个用户提供个性化推荐集。

#### 3.2 动态图构建

首先,从用户历史行为交互中提取相关信息,构建连续时间动态图(CTDG).这些行为可以表示为用户  $u_j$  的时间顺序列表:  $\tau_{u_j} = \{(i_1, t_1), (i_2, t_2), \dots, (i_p, t_p), (i_q, t_q)\}$ .

在  $\tau_u$  中, 每当用户  $u_j$  在时间  $t_m$  与物品  $i_p$  发生交互时, 就会在图中形成一条边  $(u_j, i_p, t_m) \in E$ , 其中  $E$  表示图中边的集合. 边的特征  $x_{j,p}(t_m) \in \mathbf{R}^d$  包含当前交互的详细信息, 这些信息由数据集来决定. 对于用户特征或物品特征, 如果某些用户或物品没有对应的特征信息, 可以使用 one-hot 编码来表示它们的类别信息. 在 CTDG 中, 同一用户可以在多个时间戳与同一物品发生多次交互, 这也意味着动态图中的交互密集程度要高于静态图.

### 3.3 重复感知邻居节点采样

邻居选择策略在不同的场景下有着不同的意义. 如在社区检测任务中, 往往需要更广泛地采样邻居节点信息, 以充分捕捉整个社区结构信息和关联性; 在节点分类任务中, 则更强调对局部结构的关注, 邻居采样通常会聚焦于节点附近的局部连接, 以提高分类准确性. 现有的图推荐方法在进行邻居节点采样时, 往往专注于仅仅从节点本身采样邻居, 忽略了交互节点之间的重要性, 难以关联用户与其他物品间潜在联系, 这些联系可能会通过重复交互模式显现出来. 用户的重复行为能够反映用户其稳定的兴趣特征, 而现有推荐方法往往忽略了这一重要信息. 例如, 经常一起被购买的商品可能具有内在的关联性, 传统的方法未能充分利用这种关联性来丰富推荐的性能. 此外, 用户的兴趣和偏好是随着时间变化的, 考虑重复交互的时间模式, 这对于理解用户动态变化的兴趣是至关重要的. 本文提出的“重复感知邻居采样”策略旨在捕捉用户与物品之间的重复交互行为模式. 这种重复交互行为反映了用户对某些物品或类别的稳定兴趣特征, 如用户在促销时间多次购买相同类别的商品 (如电子产品或书籍). 通过一阶和高阶重复感知邻居采样机制, 分析用户与物品的历史交互信息, 特别是重复交互行为信息, 能够更全面地理解用户的行为模式. 一阶采样着重于用户与物品间的直接交互, 可以准确反映用户的即时偏好; 高阶采样通过多跳邻居引入间接联系, 可以有效缓解交互稀疏性. 在该策略中如果仅单独依赖一阶采样会忽视潜在的协同关系, 有效信息获取不足; 如果仅依赖高阶采样, 推荐结果可能偏离用户的主要兴趣, 影响模型准确性. 例如, 用户  $u$  频繁购买牛奶 A, 一阶采样直接捕获其即时偏好, 强化推荐 A; 高阶采样则通过全局消费图谱发现, 与 A 形成强重复关联的是咖啡 B (即复购 A 的用户常复购 B). 两者结合, 使模型在响应用户显式偏好的同时, 也能主动发掘其潜在的需求, 实现个体兴趣与群体模式的协同互补. 因此, 融合一阶采样和高阶采样策略, 既考虑了目标节点的即时邻域, 同时还可以深入挖掘节点间的历史交互模式, 使模型能够在多样性与准确性之间取得平衡, 从而提升推荐系统的性能.

#### 3.3.1 一阶重复感知的邻居采样

对于给定用户  $u$  和物品  $i$  在时间戳  $t$  发生交互  $(u, i, t)$ , 首先定义用户  $u$  的重复感知邻居为用户历史交互的物品. 然后, 使用切片滑动窗口策略, 选取在重复感知节点出现之前与  $u$  交互的最近  $K$  个邻居作为用户  $u$  的邻居序列, 定义用户  $u$  在时间  $t$  与物品  $i$  交互的一阶邻居序列为  $N_u^{i,t} = \left[ a(u, a, t_a) \in G \wedge (u, i, t_\beta) \in G \wedge t_\beta \leq t \wedge 0 < P_{i,t_\beta}^u - P_{a,t_a}^u < K \right]$ , 其中  $P_{i,t_\beta}^u$  和  $P_{a,t_a}^u$  分别表示为物品  $i$  和物品  $a$  在  $u$  的历史交互中出现的位置,  $K$  表示滑动窗口大小, 这个序列表示在时间  $t$  之前, 用户  $u$  与物品  $i$  交互时的最近  $K$  个邻居节点及其交互时间. 同用户  $u$  类似, 对于物品  $i$ , 可以将它的重复感知邻居视为过去交互过的用户, 并获取物品  $i$  的邻居序列作为  $N_i^{u,t}$ . 然而, 在实际推荐场景中, 可能存在用户-物品交互的历史数据部分缺失, 这种情况下, 则获取它们最近的邻居来形成邻居序列. 如缺失用户  $u$  与物品  $v$  的交互的历史数据, 则无法直接从历史数据中获取关于物品  $v$  的邻居信息. 此时, 为捕捉用户  $u$  可能的兴趣偏好, 可将用户  $u$  最近发生过的同类型交互行为对应的其他物品, 或与物品  $v$  具有相似属性特征的物品作为物品  $v$  的潜在邻居.

#### 3.3.2 高阶重复感知的邻居采样

在进行高阶邻居采样时, 同样考虑用户物品交互的时空模式和重复行为. 首先, 获取用户  $u$  和物品  $i$  的在时间  $t$  的第  $s-1$  阶邻居序列, 分别记为  $N_{u,s-1}^{i,t}$  和  $N_{i,s-1}^{u,t}$ . 对于用户  $u$ , 定义  $s$  阶重复感知物品为其在第  $s-1$  阶交互过的物品. 因此, 对于  $m \in N_{u,s-1}^{i,t}$ , 查找历史交互记录中的重复感知物品, 并选择在重复感知物品出现之前的最近  $K$  个物品作为  $s$  阶邻居子序列. 接下来, 将用户  $u$  和  $s-1$  阶邻居的所有子序列合并为  $u$  的  $s$  阶邻居序列, 并引入关系类型约束集合  $R_s$ , 可表示为  $N_{u,s}^{i,t} = \left[ c(m, r, c, t_r) \in G \wedge r \in R_s \wedge (m, r, d, t_\theta) \in G \wedge d \in N_{i,s-1}^{u,t} \wedge m \in N_{u,s-1}^{i,t} \wedge t_\theta \leq t \wedge 0 < P_{d,t_\theta}^m - P_{c,t_r}^m < K \right]$ , 其中  $P_{d,t_\theta}^m$  和  $P_{c,t_r}^m$  分别表示物品  $d$  和  $c$  在  $m$  的历史序列中出现的位置,  $r$  表示关系类型,  $K$  表示滑动窗口大小, 生成物品  $i$  的  $s$  阶邻居序列的采样过程与用户  $u$  的类似, 即将  $N_{i,s-1}^{u,t}$  中的物品节点作为其  $s$  阶的重复感知节点, 从而得到  $N_{i,s}^{u,t}$ .

在同构图中, 所有节点和边的类型相同. 此时, 重复感知邻居采样策略可以直接应用于用户和物品节点, 通过分析用户与物品之间的历史交互记录, 捕捉重复交互行为模式. 此时将  $R_s$  设置为包含图中这唯一的边类型, 此时该策略等价于同构图中的邻居采样, 能够有效挖掘用户与物品之间的高频交互模式, 提升推荐系统的性能. 而在异构图中, 节点和边的类型多样, 例如用户、物品、类别等, 不同的交互边可能具有购买、浏览等不同的语义. 通过结合这些语义信息, 分析用户与

不同类型的物品之间的重复交互模式,可以进一步丰富推荐系统的输入特征,更全面地理解用户的兴趣特征.为适应异构图的复杂性,重复感知邻居采样策略需要考虑不同类型的节点和边.此时在 $R_s$ 内设置不同的关系类型,在不同类型的边之间进行多跳扩展,以更好地捕捉异构图环境中的复杂兴趣关联.

因此,重复感知邻居采样策略不仅能够适应同构图中的简单场景,还能有效处理异构图中复杂的多类型节点和边的交互关系,从而在更广泛的推荐场景中提供更精确的个性化推荐服务.

### 3.4 频率增强的动态图推荐网络

主要从一阶和高阶邻居序列中生成用户物品交互 $e=(u, i, t)$ 的时间表示,具体而言,首先利用重复感知邻居采样策略采样节点 $u$ 和 $i$ 的一阶和高阶邻居序列.如果一个节点的历史邻居少于 $L$ 个,则用零向量来填充.随后,通过编码层对长短期依赖、连续时间和交互频率进行编码,对时间间隔信息和交互频率进行建模,以丰富序列的时间和频率信息表达.其次,模型引入了CWT来进行频域分析.通过CWT处理后的嵌入,模型能够增强用户与物品交互的频率成分,特别是在不同时间尺度上识别出用户行为中的周期性和变化趋势.此过程中,MLP-Mixer进一步处理嵌入特征,帮助捕捉用户行为中的高频与低频模式,提升对用户动态偏好变化的敏感性.最后,将来自所有邻居的信息聚合起来,形成统一的一阶和高阶嵌入,用于后续的推荐优化.

#### 3.4.1 编码层

(1)用户/物品长期依赖编码.首先,利用3.3节所提到的重复感知节点采样方法,采用滑动窗口策略来选取用户/物品的最近邻居序列,直到出现重复感知到的邻居为止.接下来,使用RNN编码器来捕获序列中的长期依赖关系.具体来说,对于用户 $u$ 和物品 $i$ ,提取其历史邻居序列 $S_u^i$ (\*可以是 $u$ 或者 $i$ ),然后利用重复感知节点采样策略选取最近的邻居序列,并将其划分为多个块,每个块包含一定数量的邻居.然后对每个块进行编码,并将其输入到RNN编码器中,以捕获用户/物品与其邻居之间的长时间依赖关系,最后得到用户 $u$ 和物品 $i$ 的长期依赖编码 $X_{uL}^i$ 和 $X_{iL}^i$ ,其中 $X_{uL}^i$ 和 $X_{iL}^i$ 的嵌入维度是 $d_L$ .

(2)连续时间编码.为编码时间间隔信息,采用时间编码来捕获用户/物品交互的时间信息.具体而言,本文采用的余弦时间编码函数将时间间隔 $\Delta t'=t-t_n$ 映射到一个连续向量中,其中 $t_n$ 是用户和物品发生交互的时间戳,通过对时间间隔信息进行建模,可以更好地学习节点的演变过程.时间编码函数见式(1):

$$X_{*T}^i = \sqrt{\frac{1}{d_T}} \left[ \cos(w_1 \Delta t'), \cos(w_2 \Delta t'), \dots, \cos(w_{d_T} \Delta t') \right] \quad (1)$$

其中,\*可以是 $u$ 或 $i$ , $w = \{\alpha^{-(i-1)\beta}\}_{i=1}^{d_T}$ 被用来编码时间戳,其中 $\alpha$ 和 $\beta$ 是超参数, $X_{*T}^i$ 的维度是 $d_T$ ,采用余弦函数可以将这些值投影到 $[-1, +1]$ 区间内.这里使用的是相对时间戳而不是绝对时间戳来进行编码.简而言之,如果采样交互的时间戳是 $t_0$ ,并且预测未来是否交互的特定时间戳是 $t$ ,采用余弦函数可以有效地进行相对时间编码,这种技术使得模型易于优化,并能促进性能改进.

(3)用户物品交互频率编码.节点交互频率编码是一种新颖的方法,它不仅考虑节点间的直接交互,还通过计算节点间“共同邻居”出现频率和节点对的交互频率,揭示更深层次的关联.这里的“共同邻居”可以视为用户或物品相关的其他实体,如用户的朋友、物品的类别等.例如,如果你正在研究社交媒体平台上的推荐,用户可能有朋友列表,而物品可能是帖子或文章.在这种情况下,用户和物品之间的共同邻居可以被视为他们共同关注的主题或标签.如果是在购物网站上,用户和物品的共同邻居可以是用户购买过的其他商品或查看过的商品类别.例如,用户A购买了商品B和C,同时商品B和C都属于类别D,那么类别D就可以看作是用户A和商品B、C的共同邻居.这种方法在推荐系统中尤为重要,因为它可以帮助模型理解用户与物品之间的潜在联系,特别是在用户兴趣随时间发生变化的情况下.具体而言,对于给定的用户 $u$ 和物品 $i$ 的交互序列 $S_u^i$ 和 $S_i^i$ ,分别计算它们各自邻居的出现频率以及它们之间的交互频率,这有助于识别哪些物品经常与特定用户一起购买或浏览,从而推断出用户的潜在兴趣.节点对之间的相互作用采用频率进行专门编码,并得到了 $u$ 和 $i$ 的节点相互作用频率特征,用 $X_{*F}^i$ 表示,其中\*表示 $u$ 或 $i$ .例如,假设用户 $u$ 和物品 $v$ 的历史交互邻居分别为 $\{b, v, c, c, v, c\}$ 和 $\{b, u, c, b, u, b\}$ ,则节点 $b$ 和 $c$ 在 $u$ 的历史交互中出现的次数分别为1和3,在 $v$ 的历史交互中出现的次数分别为3和1,而节点对 $(u, v)$ 的交互次数为2.为捕捉用户和物品在不同时间尺度上的交互频率,分别构建用户 $u$ 和物品 $i$ 的节点交互频率特征向量见式(2)、式(3):

$$F_u^i = \left[ [1, 3], [2, 2], [3, 1], [3, 1], [2, 2], [3, 1] \right]^T \quad (2)$$

$$F_i^i = \left[ [1, 3], [2, 2], [3, 1], [1, 3], [2, 2], [1, 3] \right]^T \quad (3)$$

这些特征向量用于捕捉用户和物品在不同时间尺度上的交互频率信息,从而丰富节点的表示.用户物品的交互频率特征可以提供关于用户行为模式的重要信息,例如用户在特定时间段内与某类物品的交互频率可能反映了其当前的兴趣偏好.通过将交互频率信息编码到模型中,可以增强模型对用户行为动态变化的

理解能力. 接下来, 利用两层感知器和 ReLU (Rectified Linear Unit) 激活函数对节点交互频率特征进行编码, 计算公式见式(4):

$$X_{*,F}^l = f(F_*^l[:, 0]) + f(F_*^l[:, 1]) \in \mathbf{R}^{K \times d_F} \quad (4)$$

其中, \* 可以是  $u$  或  $i$ .  $f(\cdot)$  代表具有 ReLU 激活的两层感知器, 其输入和输出维度分别为 1 和  $d_F$ .

最后, 将所有上述编码连接在一起形成一个可训练的维度为  $d$  的嵌入向量, 其中权重矩阵为  $\mathbf{W}_* \in \mathbf{R}^{d_* \times d}$  和偏置项  $b_* \in \mathbf{R}^d$ , 最终分别得到  $X_{u,*}^l \in \mathbf{R}^{l_u \times d}$  和  $X_{i,*}^l \in \mathbf{R}^{l_i \times d}$ . 这里的 \* 可以是  $L$ 、 $T$  或  $F$ . 然后, 将节点的编码相加得到  $X_u^l = X_{u,L}^l + X_{u,T}^l + X_{u,F}^l \in \mathbf{R}^{K \times d}$  和  $X_i^l = X_{i,L}^l + X_{i,T}^l + X_{i,F}^l \in \mathbf{R}^{K \times d}$ .

### 3.4.2 连续小波变换感知增强层

用户行为具有非平稳性和动态变化的特性, 传统的方法难以同时捕捉用户行为中的长周期趋势和短期波动. CWT 是一种强大的时频分析工具, 能够将时间域的采样信号转换到频率域, 特别适合分析非平稳信号. 通过 CWT 处理后的嵌入, 模型能够增强用户与物品交互的频率成分, 特别是在不同时间尺度上识别出用户行为中的周期性和变化趋势. 为更有效地识别用户行为中的周期性模式和突发性变化, 引入 CWT 来进行频域分析. 为保证 CWT 的有效性, 本文采用 PyWavelets 库提供的 Morlet 小波基函数, 并以线性分布的整数序列  $S = \{s \in \mathbb{Z} | 1 \leq s \leq L_{\max}\}$  设置尺度集合, 其中  $\mathbb{Z}$  为整数集合,  $L_{\max}$  为输入序列的最大长度, 以覆盖完整频域. 针对不规则时间戳对齐问题, 模型以交互强度为信号值进行线性插值, 将不规则时间戳映射到固定长度的均匀时间网格, 时间网格的采样间隔根据历史交互时间跨度归一化到  $[0, 1]$  区间. 由于 CWT 在本研究中主要用于增强与重复交互行为模式相关的频率成分 (如周期性趋势或突发偏好), 而不是无损重建, 因此逆变换并非完全可逆; 其梯度稳定性通过在系数域优化可学习权重, 并结合残差连接和 Dropout 机制共同保障. 在上述设置的基础上, 利用编码层提取用户  $u$  和物品  $i$  的历史交互嵌入序列. 由于每个交互嵌入都是严格按照时间交互顺序进行排列的, 将其视为离散的时间序列数据. 这样可以利用连续小波变换将时间序列数据分解成它们的组成频率, 有效捕获节点在不同频率下的交互模式. 为此, 引入了连续小波变换增强的 MLP-Mixer, 它包含两个子层: CWT 频率增强层和多层感知机混合层.

(1) CWT 频率增强层. 给定第  $l$  层的输入  $X_*^l$  (\* 可以是  $u$  或  $i$ ), 为简便起见,  $X_*^l$  代表  $X_*^{l,t}$ . 第一层的输入是  $X_*^l$ , 为更好识别历史交互序列数据中的重要频率, 采用 CWT 将时间序列数据转换到频域. 首先, 对每个序列  $X_*^l$  执行一维 CWT 变换, 将其转换到频域. CWT 变换的输出是一个系数矩阵, 该矩阵在每个尺度和位移上量

化了信号的能量或重要性, 计算公式见式(5):

$$\mathbf{X}_{*,\text{cwt}}^l = C(X_*^l) \quad (5)$$

其中,  $C$  表示 CWT 变换.  $\mathbf{X}_{*,\text{cwt}}^l$  表示  $X_*^l$  的 CWT 系数矩阵. 然后, 通过乘以一个可学习的系数矩阵  $\mathbf{W} \in \mathbf{R}^{(K/2+1) \times d}$  以自适应增强 CWT 系数矩阵中的频率成分, 见式(6):

$$\bar{\mathbf{X}}_{*,\text{cwt}}^l = \mathbf{W} \cdot \mathbf{X}_{*,\text{cwt}}^l \quad (6)$$

其中, “ $\cdot$ ” 表示元素级乘法,  $\bar{\mathbf{X}}_{*,\text{cwt}}^l$  表示增强后的 CWT 系数矩阵. 最后, 将增强后的 CWT 系数矩阵转换回时域, 见式(7):

$$\bar{\mathbf{X}}_*^l = C^{-1}(\bar{\mathbf{X}}_{*,\text{cwt}}^l) \quad (7)$$

其中,  $C^{-1}$  表示逆 CWT 变换, 其将 CWT 系数矩阵转换为实数张量. 接下来, 使用残差连接和 dropout 层, 见式(8):

$$X_*^l = X_*^l + \text{Dropout}(\bar{\mathbf{X}}_*^l) \quad (8)$$

(2) 多层感知机混合层 (MLP-Mixer). 采用多层感知机混合层进一步捕捉数据的非线性特性. 本层主要包含两种类型的层, 本质为两步前馈神经网络 (Feed-Forward Network, FFN) 的交替执行: token 混合多层感知机层和通道混合多层感知机层, 见式(9)、式(10):

$$X_{*,\text{token}}^l = X_*^l + \mathbf{W}_{\text{token}}^{(2)} \text{ReLU}(\mathbf{W}_{\text{token}}^{(1)} \text{LN}(X_*^l)) \quad (9)$$

$$X_{*,\text{channel}}^l = X_{*,\text{token}}^l + \text{ReLU}(\text{LN}(X_{*,\text{token}}^l) \mathbf{W}_{\text{channel}}^{(1)}) \mathbf{W}_{\text{channel}}^{(2)} \quad (10)$$

其中, ReLU 是一个非线性激活函数,  $\mathbf{W}_{\text{token}}^* \in \mathbf{R}^{d \times d}$  和  $\mathbf{W}_{\text{channel}}^* \in \mathbf{R}^{d \times d}$  是可训练的参数, 在 token 混合和通道混合多层感知机层中分别使用, “\*” 可以是  $u$  或  $i$ . 相同的通道混合多层感知机层 (token 混合多层感知机层) 应用于输入的每一行 (列). LN 表示 Layer Normalization, 用于对输入进行归一化处理, 以提高模型的稳定性和收敛速度. 最后, 采用加权聚合方程对时间戳  $t$  时用户  $u$  和物品  $i$  的时间感知 (分别用  $h_u^t \in \mathbf{R}^d$  和  $h_i^t \in \mathbf{R}^d$  表示) 做聚合, 计算见式(11):

$$h_*^t = \left( \left( \mathbf{W}^{\text{agg}} \cdot X_{*,\text{channel}}^l \right)^T \cdot X_{*,\text{channel}}^l \right)^T \quad (11)$$

其中,  $\mathbf{W}^{\text{agg}} \in \mathbf{R}^{1 \times K}$  是一个可训练的向量, 设计用于自适应学习各种交互的重要性, “\*” 可以是  $u$  或  $i$ .

### 3.4.3 推荐和优化

对于每一个交互元组  $(u_j, i_p, t_m)$ , 可以计算亲和力分数, 见式(12):

$$y_{j,p}(t_m) = \text{FFN}(h_{u_j}^t || h_{i_p}^t) \quad (12)$$

其中, FFN 表示前馈神经网络, 用于对用户和物品的嵌入进行非线性变化, 从而生成亲和力分数.  $y_{j,p}(t_m)$  表示用户  $u_j$  和物品  $i_p$  在时间  $t_m$  上的亲和力分数, 这里  $h_{u_j}^t$  和

$h_p^{t_m}$  分别表示用户和物品的时间感知. 这些亲和力分数用于为每个用户生成物品排名列表, 亲和力分数越高、物品排名越靠前的物品会被优先推荐给用户.

采用 BPR 损失函数来学习模型的参数, 该损失函数广泛应用于推荐系统领域, 它假设正样本交互的亲和力分数应该比负样本交互更高. 损失函数定义见式(13):

$$\text{Loss} = \sum_{(u_j, i_p, i_p', t_m) \in \Omega} -\ln \sigma(y_{j,p}(t_m) - y_{j,p'}(t_m)) \quad (13)$$

其中,  $\Omega = \{(u_j, i_p, i_p', t_m) | (u_j, i_p, t_m) \in E, (u_j, i_p', t_m) \notin E\}$  表示成对的训练数据;  $\sigma(\cdot)$  是 sigmoid 激活函数. 重复感知与频率增强的动态图推荐算法伪代码如算法 1 所示.

### 3.4.4 复杂度分析

为全面评估所提出方法的效率, 实验对 ReFDGRec 模型的主要模块进行时间复杂度和空间复杂度分析. 复杂度分析见表 1. 通过上述复杂度分析, 可以看出 ReFDGRec 模型在处理大规模数据时的效率. 尽管某些模块(如 CWT)可能具有较高的时间复杂度, 但它们在捕捉用户行为的动态变化方面具有重要作用. 此外, 通过合理选择参数(如邻居节点数量  $K$  和嵌入维度  $d$ ), 可以有效平衡模型的性能和效率.

## 4 实验

### 4.1 实验设置

#### 4.1.1 数据集

为验证 ReFDGRec 模型的有效性, 本文对四个公开数据集进行实验. Wikipedia: 跟踪用户在维基百科页面上编辑的数据集, 表示为一个用户与维基百科页面之间的交互(编辑)的二分交互图. UCI: 包含加州大学欧文分校学生间的一个类似 Facebook、未归属的在线通信网络数据集. MOOC: 一个在线资源二分互动网络, 其

### 算法 1 基于重复感知与频率增强的动态图推荐算法伪代码

输入: 动态图  $G=(U, I, E)$ , 目标节点 target\_node, 最大邻居数  $K$ , 采样深度  $L$ , 小波变换参数 wavelet\_params, 最大迭代次数 iter

输出: 最终模型参数  $\theta$  和预测结果  $\{y_{j,p}(t_m)\}$

BEGIN

1. 初始化模型参数  $\theta$

2. FOR epoch IN 1 to iter do:

3. # 遍历每个用户-物品交互

4. FOR  $(u, i, t)$  IN  $G$ :

5. # 重复感知邻居采样(详见 3.3)

6.  $N_u = \{i_k | (u, i_k, t) \in G, t_k < t, |N_u| \leq K\}$

7.  $N_i = \{u_k | (u_k, i, t) \in G, t_k < t, |N_i| \leq K\}$

8. # 编码层-处理邻居序列的时间依赖性(详见 3.4.1)

9.  $X_u' = X_{u,L}' + X_{u,T}' + X_{u,F}'$

10.  $X_i' = X_{i,L}' + X_{i,T}' + X_{i,F}'$

11. # 频率增强层-使用 CWT 进行频率分析(详见 3.4.2)

12.  $X_{u\_cwt} = \int X_u' \varphi^* \left( \frac{t-\tau}{s} \right) dt$  #  $\varphi$  为小波函数,  $\tau$  和  $s$  分别为时间平移和尺度参数

13.  $X_{i\_cwt} = \int X_i' \varphi^* \left( \frac{t-\tau}{s} \right) dt$

14. # 更新用户和物品的嵌入表示

15.  $X_{u\_final} = \sigma(w_f X_{u\_cwt} + b_f)$  #  $w_f \in \mathbf{R}^{d \times d}$   $b_f \in \mathbf{R}^d$

16.  $X_{i\_final} = \sigma(w_f X_{i\_cwt} + b_f)$

17. # 计算推荐得分(详见 3.4.3)

18.  $\text{score} = X_{u\_final}^\top X_{i\_final}$

19. # 计算 BPR 损失函数

20.  $\text{Loss} = \sum_{(u_j, i_p, i_p', t_m) \in \Omega} -\ln \sigma(y_{j,p}(t_m) - y_{j,p'}(t_m))$

21. # 反向传播并更新参数

22.  $\theta \leftarrow \theta - \eta \cdot \nabla_{\theta} \text{Loss}$  #  $\eta$  为学习率,  $\nabla_{\theta} \text{Loss}$  为梯度

23. END FOR

24. END FOR

25. RETURN score,  $\theta$

END

表 1 复杂度分析

不同模块	时间复杂度	空间复杂度	分析过程
重复感知邻居采样	$O(HK)$	$O(K)$	对于每个用户或物品, 需要遍历其历史交互记录以选择最近的 $K$ 个邻居节点. 时间复杂度取决于历史交互次数 $H$ 和邻居节点数量 $K$ . 空间复杂度主要由存储邻居节点序列决定, 与 $K$ 成正比.
编码层	$O(Lhd + Kd)$	$O(L(h+d) + Kd)$	复杂度由 RNN、时间编码和节点交互编码三部分构成. RNN 部分的时间复杂度取决于序列长度 $L$ 、隐藏状态维度 $h$ 和嵌入维度 $d$ . 时间编码部分的时间复杂度与序列长度 $L$ 成正比. 节点交互编码部分的时间复杂度取决于邻居数量 $K$ 和特征维度 $d$ . 空间复杂度由存储 RNN 隐藏状态、时间编码向量和交互频率特征向量决定.
连续小波变换	$O(NS)$	$O(NS)$	时间复杂度由信号长度 $N$ 和小波基函数数量 $S$ 决定. 空间复杂度由存储小波系数决定.
推荐和优化	$O(UId)$	$O(Ud + Id)$	时间复杂度由计算用户和物品的亲和力分数决定, 其中 $U$ 和 $I$ 分别为用户和物品数量, $d$ 为嵌入维度. 空间复杂度由存储用户和物品的嵌入表示决定, 与 $U$ 和 $I$ 成正比.

中节点是学生和课程内容单元(例如,视频和问题集). MovieLens:包含用户对电影的评分与观看行为的数据集,表示为一个用户与电影之间的二分交互图,其中边表示用户对电影的观看或评分记录.表2展示了实验数据集的详细相关信息,其中“—”表示没有显式的节点或边特征.本文使用密度分数量化图的稀疏度,计算公式为 $\frac{2|E|}{|V|(|V|-1)}$ ,其中 $|E|$ 和 $|V|$ 代表训练集中边和节点的数量,重复行为4个比率分别是指训练、验证、测试以及整个数据集中的重复交互的比例.许多现

实世界的动态网络包含很大一部分随着时间的推移而重复出现的边,图3展示了不同数据集在新边和重复边的时序演化模式上的差异.灰色条表示在历史时间步中观察到的边数,黄色条表示每个时间步中新观察到的边数,可以看出在设计动态链路预测任务的时候,考虑重复边和新边的相对分布是很重要的.因为MovieLens数据集的交互记录仅包含用户与电影之间的唯一交互,即同一用户对同一电影不会出现多个不同评分,所以图3中不对MovieLens数据集重复边和新边进行可视化分析.

表2 实验数据集相关信息

数据集	节点数量	交互数量	时间粒度	节点/边特征	密度	持续时间	重复行为比率
Wikipedia	9 277	157 474	Unix 时间戳	—/172	$4.30 \times 10^{-3}$	1 个月	87.44%/88.42%/88.35%/87.79%
UCI	1 899	59 835	Unix 时间戳	—/—	$4.30 \times 10^{-2}$	196 天	91.00%/60.52%/70.85%/65.83%
MOOC	7 144	411 749	Unix 时间戳	—/4	$8.51 \times 10^{-3}$	17 个月	55.61%/54.90%/59.13%/56.10%
MovieLens	9 992	1 000 209	Unix 时间戳	—/1	$4.19 \times 10^{-2}$	3 年	—

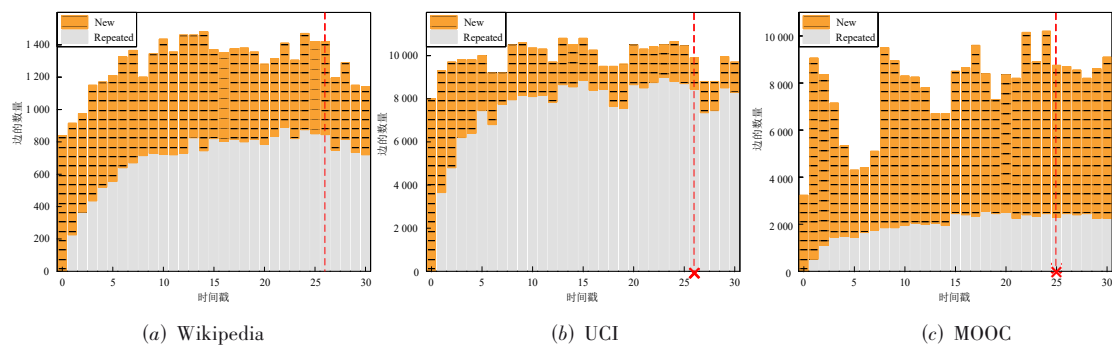


图3 数据集的可视化

#### 4.1.2 基准模型

本实验选取 DySAT、JODIE、TGA、TGN、GraphMixer、RepeatMixer 等推荐模型与 ReFDGRec 进行实验对比分析.

(1) DySAT<sup>[11]</sup>:一种基于自注意力机制的方法.它需要预先将时序图分割成多个快照图,首先将所有时间戳分成多个时间槽,然后合并每个时间槽的所有边.

(2) JODIE<sup>[20]</sup>:一种基于RNN的方法.基于RNN的时序模型,使用节点的时序嵌入,通过最近的交互时间更新节点表示,适用于捕捉时序交互模式.

(3) TGAT<sup>[18]</sup>:利用自注意力机制融合时间和空间信息,拼接节点特征与可训练时间编码,通过时序增强特征生成节点表示,应用于时序预测.

(4) TGN<sup>[19]</sup>:一种基于RNN和自注意力机制的方法.TGN首先使用RNN捕获时间信息(类似JODIE),然后用图注意力网络来联合捕获时间和空间信息.

(5) GraphMixer<sup>[26]</sup>:一种基于MLP架构的方法,它使用固定时间编码函数而不是可训练版本,并将其合

并到基于MLP混合器的链路编码器中,以从时间链路中学习.采用具有邻居均值池的节点编码器来聚合节点特征.

(6) RepeatMixer<sup>[31]</sup>:一种面向同构动态图,基于MLP架构的方法,它通过捕捉交互中的重复行为模式,增强时序图学习中的演化模式捕获能力.

#### 4.1.3 评估指标与实验设置

本文的评估以动态预测任务展开,采用平均精确度 AP (Average Precision) 和 ROC (Receiver Operating Characteristic) 曲线下与坐标轴围成的面积 AUC (Area Under the Curve) 作为评价指标来进行评估.该任务有两个设定.(1)直推式设置:在这种设置下,目标是预测训练过程中观察到的节点间未来交互.(2)归纳式设置:目标是预测未知节点之间的未来交互.为了进行更加全面的比较,实验采用随机、历史、归纳三种负采样策略来评估每种方法.表3中给出了三种负采样的实现方式以及优缺点对比.其中历史负采样和归纳负采样策略需特别注意时间上的泄露问题,为确保评估的

严格性,算法2中给出了历史负采样和归纳负采样策略的伪代码.为便于训练、验证和测试,本文将这些数据集按照70%、15%、15%的比例划分为三个时间顺序的子集.

为了确保公平比较,实验采用GraphMixer中基线模型的设置和性能指标.所有模型都通过早停策略训练最多200个epoch.选取在验证集上表现最好的模型

用于测试.对于所有模型,采用Adam优化器,学习率设置为0.0001,批量大小设置为200.采样策略中,在一阶和二阶邻居序列中选择最近的10个重复感知节点进行验证,滑动窗口 $W$ 设置为5.频率增强的MLP-Mixer层数为2.对于ReFDGRec模型,将 $d_T$ 设置为100,同时将 $\alpha$ 和 $\beta$ 均设置为10.实验都在NVIDIA RTX4090D和18核AMD EPYC 128-coreCPU的服务器上进行.

表3 三种负采样的实现方式及优缺点对比

负采样策略	实现方式	适用场景	优点	缺点
随机负采样	从图中所有可能的节点对中随机选择负样本,随机生成节点对,这些节点对在训练数据中没有交互记录	适用于简单任务,负样本分布均匀	实现简单,计算效率高.负样本分布均匀,适合评估模型对随机交互的预测能力	负样本可能包含训练阶段未见过的节点对,导致泛化能力评估不够准确
历史负采样	从历史交互中选择负样本,选择那些在历史时间戳中出现过但在当前时间戳未出现的边作为负样本	适用于需要捕捉时间变化的任务,例如评估模型对时间序列数据中交互模式变化的敏感性	负样本基于历史交互,能够更好地模拟真实场景中的交互变化.有助于评估模型对历史模式的捕捉能力	负样本生成依赖于历史数据,可能无法覆盖所有可能的节点对.如果历史数据稀疏,负样本数量可能不足
归纳负采样	从训练阶段未见过的节点对中选择负样本,选择那些在训练阶段从未出现过的节点对作为负样本	适用于需要评估模型泛化能力的任务,尤其是在测试阶段可能会遇到未见过的节点对的场景	负样本完全未出现在训练数据中,能够更好地评估模型的泛化能力.适合处理动态图中节点对的变化	负样本选择范围有限,可能无法覆盖所有可能的节点对.如果测试阶段的节点对分布与训练阶段差异较大,评估结果可能不够准确

算法2 历史/归纳负采样策略伪代码

```

输入:当前批次的交互边集合 $B=\{(u,i,t)\}$ ,所有交互边集合 $D$ ,所有可能的交互边集合 $D_{all}=U\times I$ ,训练阶段观察到的所有边集合 $D_{train}$ ,负样本数量 $K$ ,数据集中最早时间戳 $t_{earliest}$ ,当前批次的窗口 $[t_{start}, t_{end}]$ ,负采样策略 $strategy\in\{historical,inductive\}$ 
输出:负样本集合 $N$ 
BEGIN
1. # 构建历史边集合
2.  $H=\{(u,i,t)\mid\exists(u,i,t)\in D, t_{earliest}\leq t < t_{start}\}$ 
3.  $C_{batch}=\{(u,i,t)\mid\exists(u,i,t)\in B\}$ 
4. # 构建候选负样本池
5. IF  $strategy == historical$  THEN:
6.    $C=HC_{batch}$  # 历史负采样候选池
7.    $D_{cand}=D_{all}\setminus C_{batch}$ 
8. ELSE:
9.    $C=H\setminus(D_{train}\cup C_{batch})$  # 归纳负采样候选池
10.   $D_{cand}=D_{all}\setminus(D_{train}\cup C_{batch})$ 
11. END IF
12. IF  $|C|\geq K$  THEN:
13.    $N=UniformSample(C,K)$  # 候选池数量足够直接采样
14. ELSE:
15.    $N=C\cup RandomSample(D_{cand},K-|C|)$ 
16. END IF
17. RETURN  $N$ 
END

```

#### 4.1.4 性能比较

归纳设置下的实验结果如表4所示,其中加粗数据为每行的最优结果.在三种负采样策略的结果下,ReFDGRec模型在大多数数据集上实现了最优性能.为提高可读性,表4中的实验数据都在实际结果的基础上乘上了100.从实验数据可以看出:

(1)与只考虑单个节点采样最近邻居作为邻居序列的方法(TGN、JODIE)相比,ReFDGRec在采样一阶邻居时,特别考虑了交互的时间模式.这种方法能够捕获两个节点之间的相关性以及它们之间的配对时间行为,这对于时序表示学习至关重要.

(2)与RepeatMixer模型相比,ReFDGRec能够稳定地处理不同类型的负采样策略,这得益于其独特的小波变换增强机制,该机制能够自适应地捕捉用户行为中的周期性和动态变化.在MovieLens数据集上,ReFDGRec的AP显著高于RepeatMixer,而两者在AUC指标上表现相近,表明ReFDGRec在精确推荐方面表现突出,更适用于推荐任务.

(3)与捕提高阶时间信息的模型DyRep、TGAT、GraphMixer相比,ReFDGRec中考虑到表节点间的二阶邻居序列,以捕提高阶动态图中的相关时序关系.实验中ReFDGRec取得了较优的效果.

#### 4.2 重复感知邻居采样策略的影响

ReFDGRec模型通过引入了重复感知邻居采样策

表 4 归纳设置下的模型性能比较

单位:%

评估指标	负采样策略	数据集	JODIE	DyRep	TGAT	TGN	GraphMixer	RepeatMixer	ReFDGRec
AP	随机负采样	Wikipedia	94.82±0.20	92.43±0.37	96.22±0.07	97.83±0.04	96.65±0.02	98.50±0.03	<b>98.96±0.01</b>
		UCI	79.86±1.48	57.48±1.87	79.54±0.48	88.12±2.05	91.19±0.42	93.66±0.12	<b>95.08±0.03</b>
		MOOC	79.63±1.92	81.07±0.44	85.50±0.19	85.55±1.82	81.41±0.21	82.53±1.96	<b>93.11±0.04</b>
		MovieLens	66.50±0.23	66.84±0.73	63.46±3.28	67.71±0.45	65.75±0.42	69.45±0.19	<b>81.71±1.40</b>
	历史负采样	Wikipedia	68.69±0.39	62.18±1.27	87.17±0.22	81.76±0.32	<b>87.60±0.30</b>	86.54±0.69	82.82±0.25
		UCI	63.11±2.27	52.47±2.06	70.52±0.93	70.78±0.78	82.66±0.49	85.09±0.36	<b>85.34±0.31</b>
		MOOC	63.22±1.55	62.93±1.24	76.73±0.29	77.07±3.41	78.10±0.02	80.37±5.34	<b>81.41±0.42</b>
		MovieLens	49.72±1.93	53.44±0.79	52.43±2.76	56.70±2.78	50.16±1.83	83.37±1.09	<b>87.61±1.46</b>
	归纳负采样	Wikipedia	68.70±0.39	62.19±1.28	84.17±0.22	81.77±0.32	<b>87.60±0.29</b>	86.54±0.69	86.58±0.36
		UCI	63.16±2.27	52.47±2.09	70.49±0.93	70.73±0.79	81.64±0.49	<b>85.09±0.36</b>	84.31±0.28
		MOOC	63.22±1.55	62.92±1.24	76.72±0.30	77.07±3.40	73.99±0.97	80.36±5.34	<b>82.46±0.58</b>
		MovieLens	49.72±1.93	53.44±0.79	52.43±2.76	56.68±2.77	50.15±1.83	83.44±1.09	<b>87.74±1.49</b>
AUC	随机负采样	Wikipedia	94.33±0.27	91.49±0.45	95.90±0.09	97.72±0.03	96.30±0.04	98.38±0.02	<b>99.00±0.02</b>
		UCI	78.80±0.94	58.08±1.81	77.64±0.38	86.68±2.29	89.30±0.57	90.90±0.16	<b>93.05±0.03</b>
		MOOC	83.16±1.30	84.03±0.49	86.84±0.17	91.24±0.99	82.77±0.24	82.97±2.31	<b>93.94±0.05</b>
		MovieLens	64.72±0.35	66.04±0.74	64.87±3.56	67.30±1.09	65.44±0.33	<b>69.09±0.28</b>	66.86±2.79
	历史负采样	Wikipedia	61.86±0.53	57.54±1.09	78.38±0.20	75.75±0.29	<b>82.87±0.21</b>	79.14±0.65	76.94±0.19
		UCI	60.24±1.94	51.25±2.37	62.32±1.18	62.69±0.90	75.98±0.84	74.95±0.43	<b>77.31±0.13</b>
		MOOC	64.48±1.64	64.23±1.29	74.08±0.27	77.69±3.55	72.53±0.84	74.51±7.00	<b>82.98±0.34</b>
		MovieLens	42.87±1.02	48.61±0.62	47.10±7.75	50.05±2.06	46.39±1.29	<b>77.77±0.92</b>	76.21±2.93
	归纳负采样	Wikipedia	61.87±0.53	57.54±1.09	78.38±0.20	75.76±0.29	<b>82.88±0.21</b>	79.14±0.65	77.84±0.74
		UCI	60.27±1.94	51.26±2.40	62.29±1.17	62.66±0.91	75.97±0.85	74.95±0.43	<b>76.24±1.21</b>
		MOOC	64.48±1.64	64.22±1.29	74.07±0.27	77.68±3.55	72.52±0.84	74.50±7.00	<b>82.68±0.54</b>
		MovieLens	42.87±1.02	48.61±0.62	47.09±7.75	50.04±2.06	46.38±1.29	<b>77.73±0.92</b>	76.47±2.98

略,目的在于更好地捕捉节点之间的关系.如用户  $u$  在一段时间内多次购买商品 A,重复感知邻居采样策略会识别出商品 A 是用户的重复交互物品,将从用户  $u$  每次购买商品 A 之前的交互物品中采样邻居序列,以更好捕获用户  $u$  的长期、稳定偏好.实验将通过对比不同邻居采样策略和采样数量,评估该策略捕获节点交互时间模式的能力.为减少高阶邻居的影响,仅采用了一阶邻居序列进行验证.

#### 4.2.1 不同邻居采样策略的对比

本部分将重复感知邻居采样与三种邻居采样策略进行比较,包括模型中应用的最近邻居采样策略、统一邻居采样策略和时间感知邻居采样策略.最近邻居采样策略从节点的历史邻居序列中选择最近的邻居节点.统一邻居采样策略均匀地从节点的历史邻居序列中采样.时间感知邻居采样策略则引入了一个参数  $\beta$ ,以概率方式从历史序列中选择邻居,优先考虑最近或均匀采样.本文将  $\beta$  设置为 0.2.

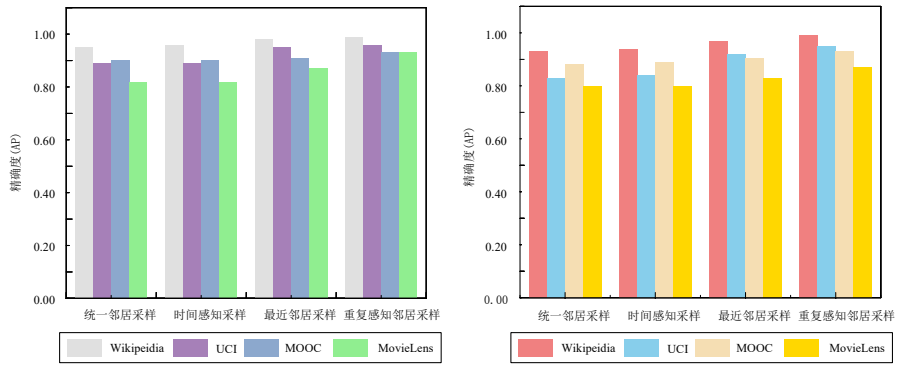
实验结果如图 4 所示,可以看出,本文的采样策略更好地捕获了节点间的时间重复行为和邻居序列的相关性.最近邻居采样策略虽然能够获取节点的最新行为,但忽略了节点间的时间联系.而统一邻居采样策略

试图平衡历史邻居的重要性.然而,最近邻居采样策略没有考虑到节点间的时间关系.另一方面,统一邻居采样策略和时间感知邻居采样策略没有考虑邻居序列中的连续时间模式,导致效果不佳.

#### 4.2.2 不同历史邻居采样数量对比

实验利用包含  $K$  个最近邻居的重复感知邻居序列,来探索其对动态图中节点交互行为的影响.

为进一步评估不同历史邻居长度对捕获节点时序信息的影响,在直推式设置和归纳式设置动态链路预测任务上进行实验,其中  $K$  的取值范围为  $\{10, 20, 30, 40, 50, 60\}$ ,从图 5 的结果可以看出,当历史邻居的数量落在特定范围时,模型表现出了最佳性能.在 Wikipedia、UCI、MOOC 和 MovieLens 四个数据集上,即使邻居数量变化显著,ReFDGRec 模型的性能也趋于稳定地波动.这也说明了从成对的角度采样邻居能够有效地过滤掉无关邻居,从而更好地提取两个节点之间的时间依赖关系.此外,当采样的邻居数量较少时,模型性能表现不佳,而随着采样数量的增加,模型性能提升,直到达到一个最优值.这也反映出模型需要足够多的邻居信息来有效捕捉“偏移”现象.需要注意的是,在归纳式设置下,Wikipedia 数据集的变化呈先降后升的趋势,

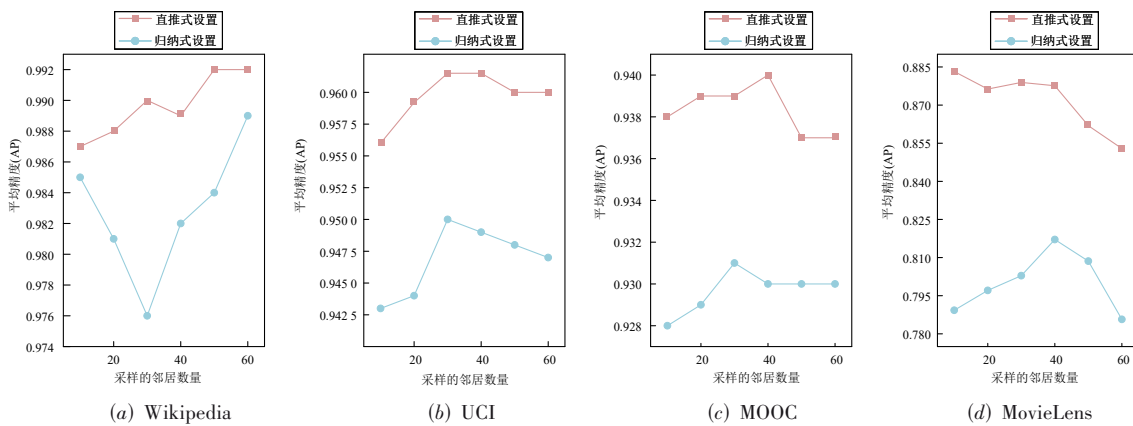


(a) 直推式设置下的动态链路预测准确度比较 (b) 归纳式设置下的动态链路预测准确度比较

图4 不同邻居采样策略的对比

与其他两个数据集有所不同. 这主要与数据集的特性相关, Wikipedia数据集的交互关系包含大量的重复编辑行为, 用户与相同页面在多个时间片中频繁交互, 因此在采样的邻居数量较少的情况下, 模型往往已能捕

提到较强的时序依赖信号, 表现出较高的性能. 但该数据集具有较强的稀疏性与异质性, 导致邻居数量在20~40时, 容易引入无关邻居, 从而导致模型性能受影响; 而当邻居数量继续增加, 模型性能表现较优.



(a) Wikipedia

(b) UCI

(c) MOOC

(d) MovieLens

图5 不同数据集的采样邻居数量对比

### 4.3 消融实验

对ReFDGRec模型进行消融实验分析, 以验证节点交互频率编码方法和连续小波变换增强层的有效性. 将不包含这两个模块的ReFDGRec模型分别称为“无节点交互频率编码(ReFDGRec-f)”和“无连续小波变换增强(ReFDGRec-c)”. 图6展示了基于随机负采样设置下的性能比较. 两种变体方法在所有数据集上表现均较差, 证明了ReFDGRec模型所设计模块的有效性, 特别是利用连续小波变换捕捉时间动态的能力. 在随机负采样设置下, 负样本通常是随机选择的节点, 与真实交互差异较大, 去掉CWT增强层的情况性能下降更显著, 体现了基于CWT的频率分析在捕获变化信号方面的重要作用. CWT能够有效地从真实信号中提取出时间动态特征, 有效提升了模型的判别能力. 节点交互频率也对模型性能提升有所贡献, 两者结合能够进一步提升模型对实践动态信息的捕捉能力.




图6 ReFDGRec组件消融实验

从图6还可以看出, 节点交互频率编码方法能够突出在不同时间窗口内反复出现的高频邻居; 连续小波变换增强层能够对用户交互序列进行时频分解, 捕捉潜在的周期性信号. 这表明节点交互频率编码方法和连续小波变换增强层在应对各种负采样策略方面具有互补性和鲁棒性, 由此验证了ReFDGRec模型在处理

“偏移”现象中的有效性.

### 4.4 时频方法对比实验

为进一步验证 ReFDGRec 模型中基于 CWT 进行频域分析方法的有效性,在 UCI 数据集上将其与短时傅里叶变换(Short-time Fourier Transform, STFT)与离散傅里叶变换(Discrete Fourier Transform, DFT)的时频分析方法进行实验对比.

实验结果如图 7 所示,在随机负采样设置下,三种方法在 AP 与 AUC 指标上差异不大,说明这三种方法都能够捕捉用户行为序列中的基本周期模式.然而在更具挑战性的历史负采样与归纳负采样设置下,CWT 的表现则普遍优于 STFT 和 DFT.




图 7 不同频方法的对比

DFT 作为全局频域分析方法能够揭示整体的频率分布,但无法反映行为信号随时间变化的局部特征,在处理非平稳序列时存在明显局限. STFT 在 DFT 的基础上为兼顾时频特性引入了时间分割,但其使用固定窗口会导致在捕捉快速波动与长期依赖并存的行为模式时难以取得平衡. ReFDGRec 模型使用的 CWT 能够精确地表征非平稳信号的时频演化特征,在推荐任务中展现出独特优势. 这种多尺度自适应能力与用户行为序列的动态性高度契合,在复杂负采样设定下展现出更突出的优势,更适合用于推荐任务中.

### 4.5 参数敏感性实验

为验证在归纳式设置下,不同滑动窗口大小和不同母小波函数类型对链路预测性能的影响,在 MOOC 和 UCI 数据集上分别进行了参数敏感性分析实验. 其中母小波参数类型的取值范围为 [‘cmor’, ‘mexh’, ‘morl’, ‘shan’], cmor、mexh、morl 和 shan 分别表示 Complex Morlet、Mexican Hat、Morlet 和 Shannon 母小波;滑动窗口大小的取值范围为 {3, 5, 10, 20}. 从图 8 可以看出,模型在不同参数设置下的表现具有一定差异.

在母小波类型的选择上,MOOC 数据集的用户行为在频率上较稳定,规律性强,在选用 Morlet 小波类型时,模型性能达到最优;而 UCI 数据集信号包含更复杂的频率成分,在母小波类型为 Complex Morlet 时,模型性能




图 8 参数敏感性分析

达到最优,说明母小波类型选择对模型的性能存在一定影响,不同数据集的信号特征差异会导致最优小波基的选择不同.

从滑动窗口大小的敏感性结果来看,在 MOOC 数据集上,当窗口大小为 3 时模型性能最佳,随着窗口的扩大,AP 性能逐渐下降并趋于稳定,这说明 MOOC 数据集中的交互行为具有明显的短期动态性,较小的时间窗口能够有效捕获用户兴趣的动态变化. 在 UCI 数据集上,模型在窗口大小为 5 时达到最佳性能,随着窗口进一步扩大,AP 性能出现下降. 表明在相对平稳的 UCI 数据集上,适当扩展滑动窗口能够带来更丰富的历史上下文信息,但当窗口过大时则会导致性能降低. 由此可以看出,ReFDGRec 在主要参数变化下具有一定可解释性.

## 5 结论

本文提出了一种基于重复感知与频率增强的动态图推荐算法 ReFDGRec,旨在缓解现有图神经网络推荐方法在捕捉用户兴趣演化和突发性偏好时存在的不足,特别是难以捕捉节点交互模式随时间演变的“偏移”现象. 实验结果表明,ReFDGRec 在多个基准数据集上实现了较优性能,且在处理不同类型的负采样策略方面具有明显的优势. 由此可见,ReFDGRec 通过融合重复感知邻居采样与频率域分析,可以实现更为精准的个性化推荐. 后续工作可以考虑如何将本文提出的方法扩展到处理包含文本、图像等多模态数据的场景,以更好增强推荐系统的多样性和准确性.

### 参考文献

[1] YU J L, YIN H Z, XIA X, et al. Self-supervised learning for recommender systems: A survey[J]. IEEE Transactions

- on Knowledge and Data Engineering, 2024, 36(1): 335-355.
- [2] GUO Q Y, ZHUANG F Z, QIN C, et al. A survey on knowledge graph-based recommender systems[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(8): 3549-3568.
- [3] WU C, WANG C K, XU J C, et al. Instant representation learning for recommendation over large dynamic graphs[C]// 2023 IEEE 39th International Conference on Data Engineering. Piscataway: IEEE, 2023: 82-95.
- [4] YUAN H N, SUN Q Y, FU X C, et al. Environment-aware dynamic graph learning for out-of-distribution generalization[EB/OL]. (2023-11-18)[2025-07-24]. <https://arxiv.org/abs/2311.11114>.
- [5] 郭向星, 周魏, 杨正益, 等. 基于自监督图卷积和注意力机制实现隐式反馈降噪的社交推荐[J]. 电子学报, 2025, 53(1): 151-162.  
GUO X X, ZHOU W, YANG Z Y, et al. Denoising implicit feedback with self-supervised graph convolution network and attention mechanism for social recommendation[J]. Acta Electronica Sinica, 2025, 53(1): 151-162. (in Chinese)
- [6] FENG Z Z, WANG R, WANG T X, et al. A comprehensive survey of dynamic graph neural networks: Models, frameworks, benchmarks, experiments and challenges[EB/OL]. (2024-05-01)[2025-07-24]. <https://arXiv.org/abs/2405.00476>.
- [7] SHENG Z Z, ZHANG T, ZHANG Y J, et al. Enhanced graph neural network for session-based recommendation[J]. Expert Systems with Applications, 2023, 213: 118887.
- [8] LI J C, WANG Y J, MCAULEY J. Time interval aware self-attention for sequential recommendation[C]//Proceedings of the 13th International Conference on Web Search and Data Mining. New York: ACM, 2020: 322-330.
- [9] 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.
- [10] 张其, 陈旭, 王叔洋, 等. 动态图神经网络链接预测综述[J]. 计算机工程与应用, 2024, 60(20): 49-67.  
ZHANG Q, CHEN X, WANG S Y, et al. Survey of dynamic graph neural network for link prediction[J]. Computer Engineering and Applications, 2024, 60(20): 49-67. (in Chinese)
- [11] SANKAR A, WU Y H, GOU L, et al. DySAT: Deep neural representation learning on dynamic graphs via self-attention networks[C]//Proceedings of the 13th International Conference on Web Search and Data Mining. New York: ACM, 2020: 519-527.
- [12] PAREJA A, DOMENICONI G, CHEN J, et al. EvolveGCN: Evolving graph convolutional networks for dynamic graphs[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(4): 5363-5370.
- [13] SHERSTINSKY A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. Physica D: Nonlinear Phenomena, 2020, 404: 132306.
- [14] TRIVEDI R, FARAJTBABAR M, BISWAL P, et al. Dyrep: Learning representations over dynamic graphs[C]//Proceedings of the 7th International Conference on Learning Representations, Appleton: ICLR, 2019.
- [15] CHEN Z Y, ZHANG W, YAN J C, et al. Learning dual dynamic representations on time-sliced user-item interaction graphs for sequential recommendation[C]//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. New York: ACM, 2021: 231-240.
- [16] ZHU Y F, CONG F P, ZHANG D, et al. WinGNN: Dynamic graph neural networks with random gradient aggregation window[C]//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2023: 3650-3662.
- [17] QI Q G, CHEN H Y, CHENG M H, et al. Input snapshots fusion for scalable discrete-time dynamic graph neural networks[C]//Proceedings of the 31st ACM SIGKDD Conference on Knowledge Discovery and Data Mining V.1. New York: ACM, 2025: 1138-1149.
- [18] XU D, RUAN C W, KORPEOGLU E, et al. Inductive representation learning on temporal graphs[EB/OL]. (2020-02-19)[2025-07-24]. <https://arXiv.org/abs/2002.07962>.
- [19] ROSSI E, CHAMBERLAIN B, FRASCA F, et al. Temporal graph networks for deep learning on dynamic graphs[EB/OL]. (2020-10-09)[2025-07-24]. <https://arXiv.org/abs/2006.10637>.
- [20] KUMAR S, ZHANG X K, LESKOVEC J. Predicting dynamic embedding trajectory in temporal interaction networks[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2019: 1269-1278.
- [21] FAN Z W, LIU Z W, ZHANG J W, et al. Continuous-time sequential recommendation with temporal graph collaborative transformer[C]//Proceedings of the 30th ACM

International Conference on Information & Knowledge Management. New York: ACM, 2021: 433-442.

- [22] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[EB/OL]. (2023-08-02)[2025-07-24]. <https://arxiv.org/abs/1706.03762>.
- [23] 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.
- [24] TANG H R, WU S Q, XU G D, et al. Dynamic graph evolution learning for recommendation[C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2023: 1589-1598.
- [25] YU L, SUN L, DU B, et al. Towards better dynamic graph learning: New architecture and unified library[EB/OL]. (2023-10-19)[2025-07-24]. <https://arxiv.org/abs/2303.13047>.
- [26] CONG W L, ZHANG S, KANG J, et al. Do we really need complicated model architectures for temporal networks? [EB/OL]. (2023-02-22)[2025-07-24]. <https://arxiv.org/abs/2302.11636>.
- [27] DESAI M H, SHAH M. An anatomization on breast can-

cer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN)[J]. Clinical EHealth, 2021, 4: 1-11.

- [28] 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.
- [29] LI Z C, TANG J H, MEI T. Deep collaborative embedding for social image understanding[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 41(9): 2070-2083.
- [30] YU H, LIU J. Community-aware temporal walks: Parameter-free representation learning on continuous-time dynamic graphs[EB/OL]. (2025-01-21)[2025-07-24]. <https://arxiv.org/abs/2501.11880>.
- [31] ZOU T, MAO Y H, YE J C, et al. Repeat-aware neighbor sampling for dynamic graph learning[C]//Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2024: 4722-4733.
- [32] IVANOVA I, RZADKOWSKI G. Triple Helix synergy and patent dynamics. cross country comparison[J]. Quality & Quantity, 2025, 59(3): 2891-2923.

#### 作者简介




**吴国栋** 男,1972年11月出生于安徽省安庆市.现为安徽农业大学副教授、硕士生导师.主要研究方向为人工智能、推荐系统.  
E-mail: wugd@ahau.edu.cn




**李景霞** 女,1976年5月出生于安徽省巢湖市.现为安徽农业大学讲师、硕士生导师.主要研究方向为智能推荐、服务计算.  
E-mail: jxiali@163.com



**黄雯婧** 女,2002年12月出生于安徽省合肥市.现为安徽农业大学硕士.主要研究方向为推荐系统.  
E-mail: 799558789@qq.com



**谢东辰** 男,2001年11月出生于江苏省镇江市.现为安徽农业大学硕士.主要研究方向为推荐系统.  
E-mail: 764361338@qq.com



**鲍宪立** 男,2001年11月出生于安徽省淮南市.现为安徽农业大学硕士.主要研究方向为推荐系统.  
E-mail: bxl694180128@163.com