

## 融合时间驻留信息的图神经网络会话推荐

孙克雷, 孙孜博

安徽理工大学 计算机科学与工程学院, 安徽 淮南 232001

**摘要:**目的 现有的基于图神经网络(GNN)的推荐方法忽略了会话中有价值用户在项目上的时间驻留信息,无法解决用户无意识点击带来的影响,同时忽略图神经网络中隐藏因素的表达能,针对以上问题,提出一种融合时间驻留信息的图神经网络会话推荐模型(Graph Neural Network Session-based Recommendation Based on Fusion of Time Resident Information, TRGNN)。**方法** 首先,对用户在各个项目上的驻留时间信息进行处理,通过时间图神经网络得到时间特征;其次,应用多头注意力机制增强因素的表达能更好地提取项目特征,TRGNN 将时间特征与项目特征进行融合得到最终特征,通过注意力网络得到全局上下文和局部上下文;最后,通过预测层得到最终推荐结果。**结果** 在 Diginetica 和 Yoochoose 两个真实数据集上进行对比实验,实验结果表明:相较于最优基线模型,本模型在 Mrr@20 评价指标下分别提升了 1.57% 和 3.30%,在 Recall@20 指标下分别提升了 1.10% 和 0.66%。**结论** 本模型实现了更好的推荐效果,能更好地挖掘隐藏信息,充分应用时间特征和项目隐藏特征来提高推荐准确率,降低用户误触对推荐准确率的影响。

**关键词:**推荐系统;会话推荐;驻留时间网络;注意力机制;图神经网络

**中图分类号:**TP391 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2025.0001.001

### Graph Neural Network Session-based Recommendation Based on Fusion of Time Resident Information

SUN Kelei, SUN Zibo

School of Computer Science and Engineering, Anhui University of Science and Technology, Anhui Huainan 232001, China

**Abstract: Objective** Existing recommendation methods based on graph neural networks (GNN) often overlook the time resident information of valuable users on items within sessions, fail to address the impact of unconscious clicks by users, and neglect the expressive ability of hidden factors in GNNs. To overcome these limitations, this paper proposed a graph neural network session-based recommendation model based on the fusion of time resident information (TRGNN). **Methods** This method first processed the time resident information of users on various items and extracted time features using a temporal graph neural network. Subsequently, it applied a multi-head attention mechanism to enhance the expressive ability of factors and better extract item features. TRGNN fused time features with item features to obtain final features, captured global and local contexts through an attention network, and ultimately obtained final recommendations through a prediction layer. **Results** Comparative experiments were conducted using two real datasets, Diginetica and Yoochoose. The experimental results indicated that, compared with the optimal baseline model, the proposed model achieved improvements of 1.57% and 3.30% in the MRR@20 evaluation indicators, and improvements of 1.10% and 0.66% in the Recall@20 indicators, respectively. **Conclusion** The proposed model demonstrates superior recommendation

**收稿日期:**2023-09-07 **修回日期:**2023-11-15 **文章编号:**1672-058X(2025)01-0001-08

**基金项目:**国家自然科学基金项目(61703005);安徽省高校科研重点项目(2022AH050821).

**作者简介:**孙克雷(1980—),男,副教授,博士,从事推荐系统、深度学习研究。

**通讯作者:**孙孜博(2000—),女,硕士研究生,从事推荐系统研究。Email:klsun@139.com.

**引用格式:**孙克雷,孙孜博.融合时间驻留信息的图神经网络会话推荐[J].重庆工商大学学报(自然科学版),2025,42(1):1-8.

SUN Kelei, SUN Zibo. Graph neural network session-based recommendation based on fusion of time resident information[J].

Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(1): 1-8.

performance, effectively mining latent information and fully utilizing temporal features and item latent features to enhance recommendation accuracy while reducing the impact of unintended user clicks on recommendation precision.

**Keywords:** recommendation system; session recommendation; time resident network; attention mechanism; graph neural network

## 1 引言

在互联网信息爆炸时代,无论是电子商务还是社交媒体网络平台,推荐系统都至关重要,它能够及时有效地提供用户感兴趣的信息<sup>[1]</sup>。现有的推荐系统模型依赖于一种假设,即用户的历史交互信息被连续记录,历史信息可以随时被访问。但是在许多实际应用场景中,用户的身份信息是未知的,在推荐过程中仅有用户当前的交互信息是可用的。这种情况下,现有的大多数推荐方法都不适用。因此,基于会话的推荐系统应运而生<sup>[2]</sup>。

现有会话推荐方法可分为两种:传统方法和基于深度学习的方法。传统会话推荐方法主要基于马尔可夫链(Markov Chain, MC)<sup>[3]</sup>和矩阵分解(Matrix factorization, MF)<sup>[4]</sup>。矩阵分解是一种著名的传统推荐方法,但该方法无法学习项目的序列变换,因此,Steffen Rendle 等<sup>[5]</sup>将矩阵分解和一阶马尔可夫链(MC)相结合进行推荐,实现分解的个性化 MC(FPMC),该模型有效地学习了物品和长期爱好的会话转换,但是不能学习更复杂项之间的关系和交互。

传统会话推荐方法在分析用户交互数据时无法捕获项目间的连续信息。但用户的下一个交互项目通常会受到历史交互记录的影响,因此关注项目间的序列信息十分必要。随着深度学习的兴起,会话推荐迎来了新的发展。Hidasi 等<sup>[6]</sup>提出一种并行 RNN 模型,该模型采用多特征并行方法进行建模,解决了不能学习会话中表达能力更强大的项目表示问题,但它不能很好地学习用户的长期偏好;Li 等<sup>[7]</sup>提出神经注意力推荐机制(NARM),NARM 可以同时学习用户的短期和长期偏好,结合短期和长期偏好更好地了解用户的购物习惯,这种方法在长时间的训练中表现非常好,但对于用户行为序列中长期依赖关系的建模能力有限,在处理复杂用户行为序列时表现不佳;Liu 等<sup>[8]</sup>提出短期注意/记忆优先级(STAMP)模型,可以同时从会话上下文的长期记忆和短期记忆中捕获用户的兴趣,克服用户在长时间会话中无意识点击引起的兴趣漂移问题,但在长时间会话情况下,该模型效果不佳。

近些年来,随着 GNN 的改进,基于 GNN 的推荐方法在推荐系统中也得到了广泛的应用。Chen 和贾等<sup>[9-10]</sup>提出一种基于图的协同过滤方法;该方法将用户-项目交互行为视为一个二部图;Wu 等<sup>[11]</sup>提出

SRGNN 模型,将 GNN 应用于会话推荐,使模型能够将用户的历史会话信息作为图结构进行建模,具有捕捉历史行为和兴趣演化的优势以及处理长期依赖关系的能力,但在任务定义和模型复杂度方面存在一些限制;Yu 等提出<sup>[12]</sup>针对不同目标对象设计目标感知注意机制,自适应地捕捉其他用户的兴趣,采用邻域信息池化的方式将集成的邻域信息与节点的隐藏状态进行迭代更新,帮助模型更好地捕捉用户历史会话和当前会话之间的相关性,从而提供更准确的建议,但需要结合其他方法来提高推荐性能并且计算复杂度较高,模型的可伸缩性不强;Xie 等<sup>[13]</sup>提出 PSR-GAT 模型,它考虑用户在不同项目上停留时间的差异,更多地关注有向图的边缘,补充了会话中项目之间的连接信息,在处理具有复杂关系的数据时表现出色,但对输入数据的依赖性较高,对于不同类型的图结构和特征表示可能需要进行调整和优化。

综上所述,虽然基于 GNN 的方法取得了良好的效果,但仍然存在一些局限:上述方法没有考虑会话中项目本身具有的有价值用户在项目上的驻留时间信息。每个项目含有一定数量的时间信息,并在用户从一个项目移动到下一个项目时提供有关用户首选项的指示性信息。例如,用户在感兴趣的项目上花费了大量时间,而在无意中输入或不感兴趣的项目上花费的时间特别短。如果不考虑驻留时间,可能很难区分用户感兴趣的项目和不重要的项目,难以处理用户误触带来的影响。上述方法都是通过 GRU 来获取单层会话中的隐藏信息,不能动态地学习图神经网络中物品交互与用户交互的过程,因此难以充分挖掘隐藏因素的表达能力。

为了解决这些问题,本文提出了一种融合时间驻留信息的图神经网络会话推荐系统模型(TRGNN),TRGNN 改进了典型的会话特征学习过程。首先对数据预处理,TRGNN 从数据集中的时间框架构建时间会话,时间会话包含会话中用户对每个项目的驻留时间信息,引入时间图神经网络(Temporal Graph Neural Network, TGNN)从时间会话中学习时间特征。其次,针对现有模型不能挖掘图神经网络中隐藏因素的问题,TRGNN 采用多头注意力机制增强隐藏因素的表达。最后,将项目特征与时间特征进行特征融合,得到最终的特征表达来改进会话推荐,从而提升推荐效果。

本文的主要贡献:提出一个会话推荐模型 TRGNN,

引入时间图神经网络提取时间特征,利用时间特征辅助推荐提升推荐效果;引入多头注意力机制捕捉输入序列中的不同关系和语义信息来提供更丰富的项目特征表示,可以同时关注不同的位置和特征,具有更高的并行性。在 Diginetica 和 Yoochoose 两个数据集上的实验结果表明:融合时间驻留信息的图神经网络会话推荐模型预测得分有一定的提高。

## 2 模型框架

融合时间驻留信息的图神经网络会话推荐整体模型框架如图 1 所示,从项目特征和时间特征 2 个角度提取用户兴趣。TRGNN 有 4 个主要模块:项目特征提取、

时间特征提取、特征融合和评分预测。其中,项目特征提取模块将会话序列构成会话图,引入多头注意力机制动态地学习图神经网络中物品交互与用户交互过程,使其能够关注不同位置不同表示子空间的数据,增强隐藏特征的表达能力,从而更好地提取项目特征。时间特征提取模块通过时间图神经网络处理用户在项目上的驻留时间信息来提取时间特征。特征融合模块融合时间特征和项目特征,通过注意力网络提取得到最终项目向量,从而得到全局上下文。将最后一次交互作为局部上下文,然后结合所有信息以了解每个项目的贡献,从而预测下一个用户感兴趣的项目。

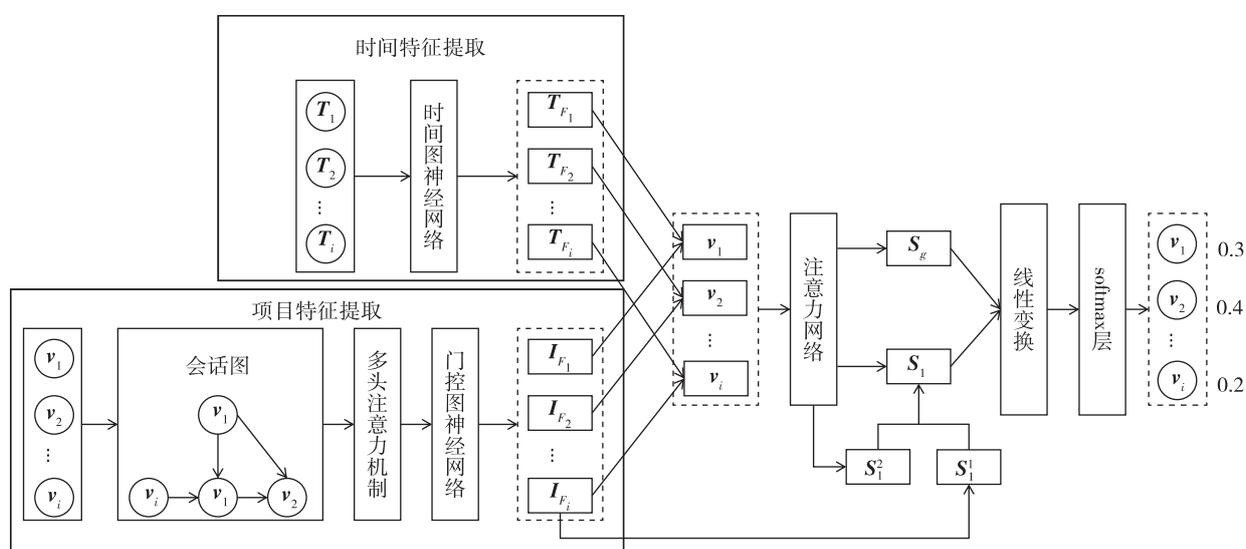


图 1 模型整体研究框架

Fig. 1 Overall research framework of the model

### 2.1 问题定义

会话推荐的任务定义为使用基于历史行为的会话信息来预测未来可能的单击项。在会话推荐任务中,  $v = \{v_1, v_2, v_3, \dots, v_m\}$  表示所有会话中不同项的集合,  $s = \{s_1, s_2, s_3, \dots, s_{|s|}\}$  表示整个会话集,  $s_i = \{s_{n,1}, s_{n,2}, s_{n,3}, \dots, s_{n,n}\}$  表示推荐过程中时间戳为  $t(t > 1)$  的一个会话,其中  $v_{n,1} \in v$  表示会话  $s_i$  中用户的一个点击项。对于会话  $s_i$  可以得到概率  $\hat{y}$ 。

### 2.2 项目建模及特征提取

在 TRGNN 中,将每个独立的会话图表示为  $G_s = (V_s, \epsilon_s, A_s)$ ,其中  $V_s, \epsilon_s, A_s$  表示节点集、边集和连接矩阵。在  $G_s$  中,每个节点表示一个项目  $v_{s,i} \in v$ ,并且每个边  $(v_{s,i-1}, v_{s,i}) \in \epsilon_s$  表示用户从  $v_{s,i-1}$  访问项目到  $v_{s,i}$ 。此时,  $A_s$  定义为两个邻接矩阵  $A_s^{(out)}$  和  $A_s^{(in)}$  的连接,分别表示会话图中出边和入边的加权连接。例如,假设会话  $s = [v_1, v_2, v_3, v_4]$  对应的会话图和矩阵  $A_s$  如图 2 所示。参考 SRGNN<sup>[11]</sup> 的构图方法,可以为构造会话图提供不同的连接矩阵,使用不同策略构造会话图,连接矩

阵  $A_s$  也会进行相应改变。当节点中存在描述和类别信息等内容特征时,可将特征与节点向量串联起来处理这类信息。

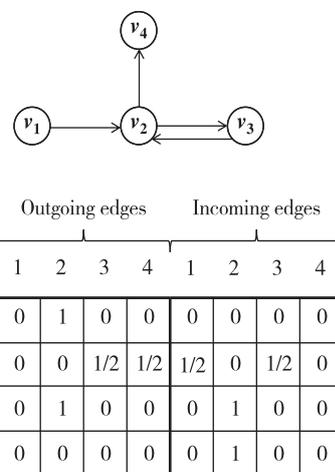


图 2 会话图和连接矩阵  $A_s$  的实例

Fig. 2 An example of session graph and connection matrix  $A_s$

在构建会话图之后,每个节点  $v_i \in v$  都可以转化为

一个可学习的嵌入空间。项目嵌入是每个会话的表示,它使用 GNN 生成节点表示,对复杂项进行建模。因为 GNN 非常适用于会话推荐,所以使用它学习项目嵌入模型,得到项目  $v_i \in \mathbf{R}^d$  的  $d$  维表示后,用门控图神经网络(Gated Graph Neural Network, GGNN)学习节点向量,对应计算公式分别如式(1)一式(5)所示:

$$\mathbf{a}_{s,i}^t = \mathbf{A}_{s,i}^T [\mathbf{v}_1^{t-1}, \dots, \mathbf{v}_{s_n}^{t-1}]^T + \mathbf{b} \quad (1)$$

$$\mathbf{z}_{s,i}^t = \sigma(\mathbf{W}_z \mathbf{a}_{s,i}^t + \mathbf{U}_z \mathbf{v}_i^{t-1}) \quad (2)$$

$$\mathbf{r}_{s,i}^t = \sigma(\mathbf{W}_r \mathbf{a}_{s,i}^t + \mathbf{U}_r \mathbf{v}_i^{t-1}) \quad (3)$$

$$\widetilde{\mathbf{I}}_{F_i}^t = \tanh(\mathbf{W}_o \mathbf{a}_{s,i}^t + \mathbf{U}_o (\mathbf{r}_{s,i}^t \odot \mathbf{I}_{F_i}^{t-1})) \quad (4)$$

$$\mathbf{I}_{F_i}^t = (1 - \mathbf{z}_{s,i}^t) \odot \mathbf{I}_{F_i}^{t-1} + \mathbf{z}_{s,i}^t \odot \widetilde{\mathbf{I}}_{F_i}^t \quad (5)$$

其中,  $t$  是时间戳,  $\mathbf{A}_{s,i}$  是矩阵  $\mathbf{A}_s$  中第  $i$  行对应节点  $v_{s,i}$ ,  $\mathbf{b}$  是偏差参数,  $\sigma$  是 sigmoid 函数,  $\odot$  是逐元素乘法运算符,  $\mathbf{z}_{s,i}$  和  $\mathbf{r}_{s,i}$  分别是重置门和更新门向量,  $[\mathbf{v}_1^{t-1}, \mathbf{v}_2^{t-1}, \dots, \mathbf{v}_{s_n}^{t-1}]$  是会话  $s$  中的节点向量列表。

在矩阵  $\mathbf{A}_s$  给出的约束条件下,式(1)用于不同节点之间的信息传播。具体来说,由它提取邻域的潜在向量,并将潜在信息输入到图神经网络中。然后,由更新门和重置门分别决定需要保留和丢弃的信息<sup>[14]</sup>,最后可以得到前一状态、当前状态和复位门构造候选状态。在更新门的控制下,最后的状态是前一个隐藏状态与当前候选状态的组合。在会话图中更新每个节点直至收敛后,就可以得到最终的节点向量。具体步骤如图 3 所示。

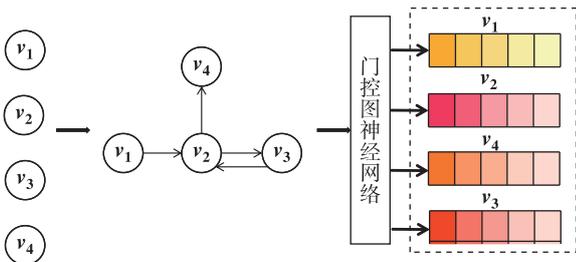


图 3 会话图的最终节点向量生成

Fig. 3 Generation of final node vector in session graph

特征向量的表示学习过程实质上就是图神经网络中物品交互与用户交互的过程<sup>[15]</sup>。以往的研究都是通过 GRU 来获取单层会话中的隐藏信息,不能动态地学习这一交互过程。多头注意改进了该模型,使其能够关注不同位置不同表示子空间的数据,增强了隐藏因素的表达能力。第  $i$  层的迭代过程如式(6)所示:

$$\mathbf{h}_i^{l+1} = \sum_{V_j \in S} \sigma \left( \frac{\mathbf{Q}^l \mathbf{h}_i^l \cdot (\mathbf{K}^l \mathbf{h}_i^l)^T}{\sqrt{d_k}} \right) \quad (6)$$

其中,  $\mathbf{h}_i^l$  为会话  $s$  中  $l$  层第  $j$  项的隐藏状态;  $\mathbf{Q}^l$ 、 $\mathbf{K}^l$ 、 $\mathbf{V}^l$  分别为查询、键、值,  $\sigma$  为 softmax 操作;  $\mathbf{Q}^l$ 、 $\mathbf{K}^l$ 、 $\mathbf{V}^l$  是可学习参数,并行更新而不是顺序更新;  $d_k$  是一个超参

数,表示变换中线性层的维数。

### 2.3 时间特征提取

对数据集进行处理可以获得临时会话。对于每个会话可以得到每个项目  $T_0$  的时间戳 =  $\{t_{s_1}, t_{s_2}, t_{s_3}, \dots, t_{s_i}\}$ , 然后使用式(7)计算每个项的停留时间,删除不符合条件的项,在归一化停留时间后,得到临时会话  $\mathbf{T} = \{t_1, t_2, t_3, \dots, t_i\}$ 。

$$t_{i-1} = t_{s_i} - t_{s_{i-1}} \quad (7)$$

图 4 显示了如何处理用户对各个项目的停留时间以获得可用的时间会话并对其进行标准化。

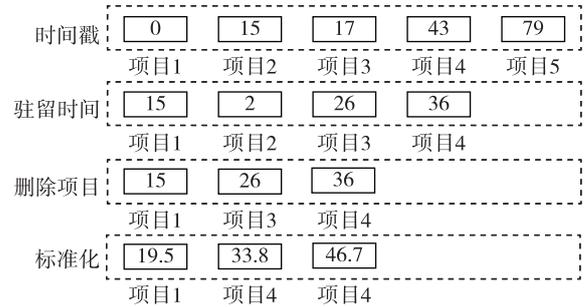


图 4 用户在项目上停留时间信息的处理

Fig. 4 Processing of user's residence time information on the project

在本模型中,时间会话被考虑在内。引入 TGNN 捕捉时间特征得到时间会话  $\mathbf{T}$ 。更新公式如式(8)、式(9):

$$s_i = \tan(\mathbf{U}t_i + \mathbf{W}s_{i-1}) \quad (8)$$

$$\mathbf{T}_{F_i} = \mathbf{T}_{s_i} \quad (9)$$

其中,  $\mathbf{T}_{F_i}$  是第  $i$  个项目的特征。

将时间特征  $\mathbf{T}_{F_i}$  和项目特征  $\mathbf{I}_{F_i}^t$  相结合,得到总体特征。而项目向量可以表示为  $\mathbf{v}_i$ ,公式如式(10)所示:

$$\mathbf{v}_i = \text{concat}(\mathbf{I}_{F_i}^t, \mathbf{T}_{F_i}) \quad (10)$$

### 2.4 特征融合

通过 2.2 节和 2.3 节学习到项目特征和时间特征后,将它们进行特征融合得到全局会话嵌入。全局会话嵌入代表了用户在许多领域的长期兴趣偏好,用户访问的每个项对全局会话嵌入都有不同的影响。访问的最后一个项目将显著影响全局会话嵌入的生成。应用软注意机制来映射最后访问的项目与会话依赖关系中涉及的每个项目之间的依赖关系。公式如式(11)、式(12):

$$\beta_i = \mathbf{q}^T \sigma(\mathbf{W}_1 s_i^1 + \mathbf{W}_2 \mathbf{v}_i) \quad (11)$$

$$\mathbf{s}_g = \sum_{i=1}^{S_n} \beta_i \mathbf{v}_i \quad (12)$$

其中,  $\mathbf{q} \in \mathbf{R}^d$ ,  $s_i^1$  为最后点击项,  $\mathbf{W}_1$ 、 $\mathbf{W}_2$  为权重参数。

考虑会话的局部嵌入,对于会话  $s$ ,局部嵌入可以定义为最后点击项,即  $s_i^1 = \mathbf{T}_{F_i}$ ,  $s_i^2 = \mathbf{v}_i$ ,通过线性转换  $s_i^1$

和  $s_i^2$  的连接来生成一个当前会话,如式(13)所示:

$$s_i = W_3(s_i^1 \oplus s_i^2) \quad (13)$$

其中,  $\oplus$  表示两个特征之间的连接操作,  $W_3$  为权重参数。

## 2.5 预测层

在获取全局上下文和局部上下文后,通过项目嵌入与会话嵌入的内积计算出每个目标项目的推荐分数,然后利用 softmax 函数得到最终概率  $\hat{y}$ ,公式如式(14)、式(15)所示:

$$\hat{z}_i = s_i^T v_i \hat{y} \quad (14)$$

$$\hat{y} = \text{softmax}(\hat{z}) \quad (15)$$

其中,  $\hat{y}$  表示节点出现为会话是  $s$  中下一次点击的概率,在模型训练过程中,损失函数被定义为预测结果与真实标签的交叉熵。交叉熵损失函数为式(16):

$$L(\hat{y}) = - \sum_{i=1}^n y_i \log(\hat{h}_i) + (1 - y_i) \log((1 - y_i)) \quad (16)$$

其中,  $y_i$  表示真实项的 one-hot 编码向量。最后,利用时间反向传播算法对模型进行训练。

## 3 实验与结果分析

### 3.1 数据集介绍

本模型使用的数据集为 Diginetica 和 Yoochoose。Yoochoose 数据集来自 2015 年 RecSys 挑战赛,该挑战赛由 6 个月内电子商务网站的一系列点击组成,选择最近的 1/64 Yoochoose 训练序列。Diginetica 是 2016 年 CIKM 杯的数据集,它具有适合基于会话推荐的数据。

首先,对两个数据集进行预处理得到用户在每个项目上的驻留时间;其次,删除在数据集中出现少于 5 次的项目,也删除只包含一个项目的会话;然后对数据集进行扩展和分割,在 Diginetica 中选择最近 7 天的数据作为测试集,在 Yoochoose 中使用最近 1/64 的数据作为测试集,其余的数据是训练集;最后,删除测试集和训练集中不存在的项目。预处理数据集中含有用户点击次数、项目数以及会话长度等。具体数据统计信息如表 1 所示。

表 1 数据集的基本信息

Table 1 Basic information of the dataset

数据集	Yoochoose1/64	Diginetica
点击次数	536 177	940 311
训练会话	705 916	350 408
测试会话	59 948	54 812
项目数	42 729	16 582
会话长度	5.27	5.99

### 3.2 评价指标和参数设置

使用  $N_{\text{Recall}}$  和  $N_{\text{Mrr}}$  来评价本文提出模型的性能。 $N_{\text{Recall}}$  被广泛用于推荐评价,它表示正确推荐的项目在所有推荐项目中的比例; $N_{\text{Mrr}}$  代表平均排名的倒数。两种评价方法的具体内容如下:

$N_{\text{Recall}}$  计算如式(17)所示:

$$N_{\text{Recall}} = \frac{\sum_{e(s) \in E(s)} |r(s) \cap e(s)|}{|E(s)|} \quad (17)$$

其中,  $e(s)$  表示一个会话中的推荐目标,  $E(s)$  表示测试集中所有会话的目标集合,  $r(s)$  为前  $n$  个推荐目标。

$N_{\text{Mrr}}$  计算如式(18)所示:

$$N_{\text{Mrr}} = \frac{1}{Q} \sum_{i=1}^{|Q|} \frac{1}{i_{\text{rank}}} \quad (18)$$

其中,  $Q$  为用户数量,  $i_{\text{rank}}$  为第  $i$  个用户推荐列表结果中第一个项目的排列位置。

TRGNN 模型在 Yoochoose 数据集上隐藏维度设置为 90,在 Diginetica 数据集上隐藏维度设置为 100,所有数据集的批量大小设置为 100,Adam 的初始学习速率被设定为 0.01,高斯分布初始化所有参数,均值为 0,标准差为 0.1。

### 3.3 对比模型结果与分析

为验证本文所提出模型的有效性,选取 GRU4REC、NARM、SRGNN、TAGNN、TASRec、SEDGN 和 CAGL 7 个其他会话推荐模型进行对比实验。对比模型介绍如下:

Item-KNN<sup>[16]</sup>: 推荐与该序列最相似的前  $N$  个项目。

NARM<sup>[7]</sup>: 在 RNN 模型中加入注意机制,捕捉用户在会话中的长期和短期行为,找到用户在此会话中的偏好。

SRGNN<sup>[11]</sup>: 使用具有注意力机制的 GNN 融合局部和全局特征获取上下文,进而得到用户的偏好。

TAGNN<sup>[12]</sup>: 在注意机制模块中添加目标项,以适应不同用户对其他目标的兴趣。

TASRec<sup>[17]</sup>: 使用时间增强图神经网络构建高效时间图以捕捉动态的用户兴趣,从而提升推荐效果。

SEDGN<sup>[18]</sup>: 使用序列增强的去噪技术处理会话中的噪声,从而提高推荐的准确性和效率。

CAGL<sup>[19]</sup>: 使用注意力机制和图卷积神经网络来学习用户行为序列之间的关系,并预测用户下一个可能感兴趣的项目。

表 2 对比实验结果

Table 2 Results of comparative experiments

实验模型	Yoochoose1/64		Diginetica	
	Recall@ 20	Mrr@ 20	Recall@ 20	Mrr@ 20
Item-KNN	51.60	21.81	35.75	11.57
NARM	68.32	28.63	49.7	16.17
SRGNN	70.87	30.94	50.73	17.59
TAGNN	71.02	31.12	51.37	18.03
TASRec	68.16	30.36	50.39	17.72
SEDGN	71.32	31.15	51.91	18.22
CAGL	71.26	31.21	52.91	18.42
TRGNN	71.79	32.24	53.49	18.71
提升比例/%	0.66	3.30	1.10	1.57

通过对比实验可知,在 Yoochoose1/64 数据集中 TRGNN 与 TAGNN 和 SRGNN 相比,Recall@ 20 指标分别提升了 0.9% 和 1.09%;Mrr@ 20 指标分别提升了 2.54% 和 3.20%。在 Diginetica 数据集中,TRGNN 与 TAGNN 和 SRGNN 相比,Recall@ 20 指标分别提升了 4.13% 和 5.44%;Mrr@ 20 指标分别提升了 3.77% 和 6.37%。

在 Yoochoose1/64 数据集中,TRGNN 与 TASRec、SEDGN 和 CAGL 3 个模型相比,Recall@ 20 指标分别提升了 5.33%、0.66% 和 0.74%;Mrr@ 20 指标分别提升了 6.19%、3.50% 和 3.30%。在 Diginetica 数据集中,TRGNN 与 TASRec、SEDGN 和 CAGL 相比,Recall@ 20 指标分别提升了 6.15%、3.04% 和 1.1%;Mrr@ 20 指标分别提升了 5.59%、2.69% 和 1.57%。

与不使用驻留时间信息和多头注意力机制的模型相比,本文的模型效果更好。说明考虑驻留时间因素和使用多头注意力机制对推荐效果的提升有一定的促进作用。TAGNN、SRGNN、SEDGN 和 CAGL 等没有考虑时间嵌入对推荐的影响,也没有挖掘隐藏信息,TASRec 仅考虑时间因素但并没有考虑项目特征,TRGNN 引入了多头注意力机制和时间嵌入,深入挖掘时间特征和项目特征,并融合了两者的总特征,通过利用更丰富的信息提高了模型的性能。

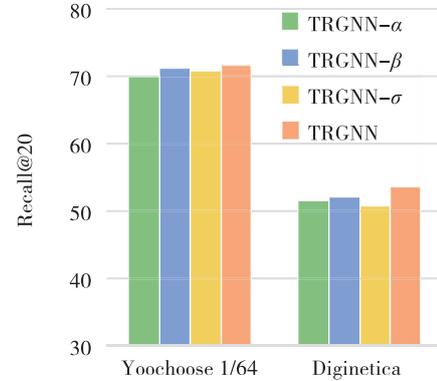
### 3.4 消融实验结果与分析

为了了解模型各个模块对整体性能的影响,本文进行了一系列的消融实验,总结了最优模型和其他变体在 Diginetica 和 Yoochoose1/64 数据集上的性能。变体如下:

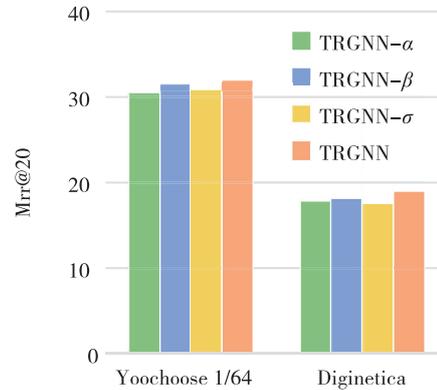
(1) TRGNN- $\alpha$ : 移除项目特征提取模块的多头注意力机制;

(2) TRGNN- $\beta$ : 移除驻留时间信息输入;

(3) TRGNN- $\sigma$ : 移除项目特征提取模块的多头注意力机制和驻留时间信息输入。



(a) Recall@20 指标下的消融实验



(b) Mrr@20 指标下的消融实验

图 5 消融实验结果对比

Fig. 5 Comparison of ablation experiment results

通过对比结果可知:移除多头注意力机制之后,模型总体性能在 Diginetica 和 Yoochoose1/64 两个数据集上分别下降 5.18% 和 4.50%,说明该模块的存在能更好地挖掘项目中的隐藏因素,有助于提高模型性能;去除时间信息输入之后,模型总体性能在 Diginetica 和 Yoochoose1/64 两个数据集上分别下降 3.70% 和 1.38%,说明时间信息的引入有助于模型推荐能力的提升;去除项目特征提取模块的多头注意力机制和时间信息输入,模型整体在 Diginetica 和 Yoochoose1/64 两个数据集上分别下降 6.98% 和 3.1%,说明使用时间驻留信息的模型性能优于不使用时间信息的模型,多头注意力机制的特征提取性能优于普通神经网络组成的注意力机制。

### 3.5 时间网络对训练时间的影响

本节研究了不同时间网络对训练时间的影响,3 种方法的 10 轮训练时间如图 6 所示。

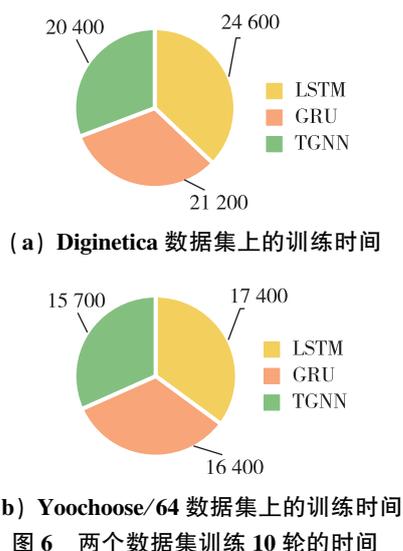


图 6 两个数据集训练 10 轮的时间

Fig. 6 Training time for 10 rounds on two data sets

从图 6 中可以观察到 TGNN 在两个数据集上都是最快的,而 LSTM 是最慢的,这是因为 TGNN 结构相对简单,训练速度快,而 LSTM 结构最复杂,训练速度慢。其次,对于 3 种方法,Diginetica 的训练时间都比 Yoochoose 的训练时间长,这是因为训练时间的长短与训练集的大小正相关,Diginetica 由于规模较大,比 Yoochoose 需要更长的训练时间。

### 3.6 隐藏维度对模型的影响

在本节中研究了不同隐藏维度对模型效果的影响。通过实验测试不同隐藏维度取值对 TRGNN 模型性能的影响,隐藏维度的取值范围为 0~120。

选择 Recall@20 为评价指标,在 Diginetica 和 Yoochoose 数据集上进行实验,实验结果如图 7 所示。从图中可以观察到随着隐藏维度的不断增加,TRGNN 的性能也随之提升。对于 Yoochoose 数据集,当隐藏维度为 90 时,模型性能不再增长。对于 Diginetica 数据集,当隐藏维度为 100 时,模型性能不再增长。

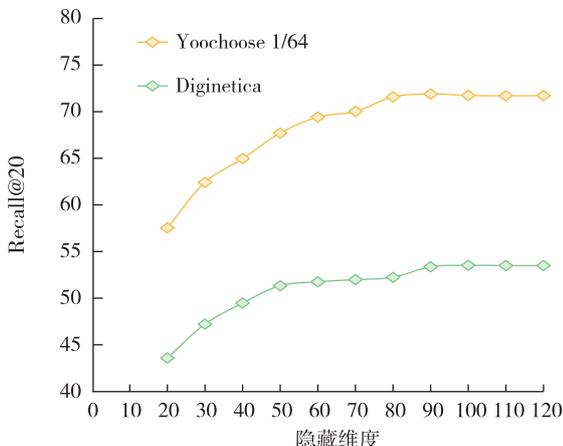


图 7 Recall@20 指标下不同隐藏维度的性能对比

Fig. 7 Performance comparison of different hidden dimensions under Recall@20 indicators

选择 Mrr@20 为评价指标,在 Diginetica 和 Yoochoose 数据集上进行实验,实验结果如图 8 所示。从图中可以观察到随着隐藏维度的增加,TRGNN 的性能也随之提升。对于 Yoochoose 数据集,当隐藏维度为 90 时模型性能达到最优。对于 Diginetica 数据集,当隐藏维度为 100 时模型性能达到最优。

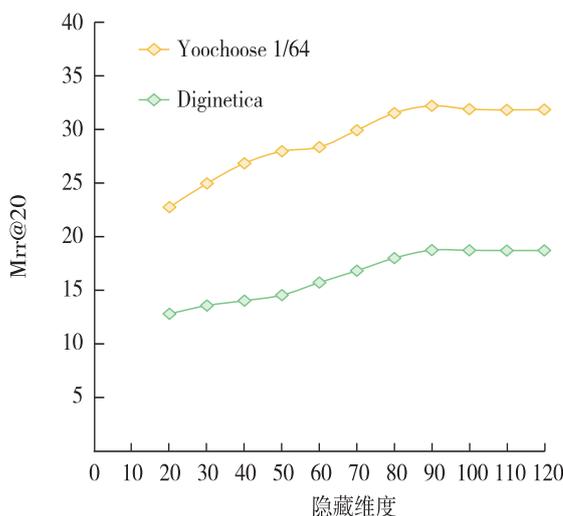


图 8 Mrr@20 指标下不同隐藏维度的性能对比

Fig. 8 Performance comparison of different hidden dimensions under Mrr@20 indicators

### 3.7 Adam 初始学习率设置

Adam 的初始学习速率被设定为 0.01,是为了平衡算法模型的效率和效果。如果初始学习率设置得太高会导致模型在训练初期发散,无法收敛,为了避免这种情况,通常将 Adam 的初始学习率设置为 0.01 左右,以平衡模型的效率和效果。

## 4 结论

本文在传统的基于 GNN 的会话推荐模型基础上进行改进,利用时间图神经网络提取用户在项目上的驻留时间信息;利用多头注意力机制挖掘隐藏的项目信息从而更好地提取用户的兴趣,通过特征融合得到具有更丰富信息的融合特征,以解决用户误触带来的兴趣漂移和推荐准确率下降问题。由两个公共数据集 Diginetica 和 Yoochoose 上的实验数据可知,本文模型的效果优于其他现有的模型。实验结果表明,利用用户在项目上的驻留时间信息和多头注意力机制可以有效提高推荐准确率。

虽然 TRGNN 提升了推荐准确率,但在未来研究方面仍面临以下挑战:TRGNN 虽然提高了推荐的效率但计算复杂度较高,接下来将探索一些提高效率的算法来进一步改善模型。针对用户的历史行为较少,冷启动时模型效果不佳等问题,可以通过引入用户和商品的特征信息来解决。

## 参考文献(References):

- [1] 于蒙, 何文涛, 周绪川, 等. 推荐系统综述[J]. 计算机应用, 2022, 42(6): 1898-1913.  
YU Meng, HE Wen-tao, ZHOU Xu-chuan, et al. Review of recommendation system[J]. Journal of Computer Applications, 2022, 42(6): 1898-1913.
- [2] 陈晋鹏, 李海洋, 张帆, 等. 基于会话的推荐方法综述[J]. 中文信息学报, 2023, 37(3): 1-17, 26.  
CHEN Jin-peng, LI Hai-yang, ZHANG Fan, et al. Review on session-based recommendation methods[J]. Journal of Chinese Information Processing, 2023, 37(3): 1-17, 26.
- [3] HE R, MCAULEY J. Fusing similarity models with Markov chains for sparse sequential recommendation[C]//Proceedings of the IEEE 16th International Conference on Data Mining. Piscataway: IEEE Press, 2016: 191-200.
- [4] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems [J]. Computer, 2009, 42(8): 30-37.
- [5] 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. NewYork: ACM, 2010: 811-820.
- [6] HIDASI B, QUADRANA M, KARATZOGLOU A, et al. Parallel recurrent neural network architectures for feature-rich session-based recommendations[C]//Proceedings of the 10th ACM Conference on Recommender Systems. NewYork: ACM, 2016: 241-248.
- [7] LI J, REN P, CHEN Z, et al. Neural attentive session-based recommendation[C]//Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. NewYork: ACM, 2017: 1419-1428.
- [8] LIU Q, ZENG Y, 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. NewYork: ACM, 2018: 1831-1839.
- [9] CHEN L, WU L, HONG R, et al. Revisiting graph based collaborative filtering: a linear residual graph convolutional network approach[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(1): 27-34.
- [10] 贾志洋, 石宜金, 李丁, 等. 基于协同过滤的在线教学视频推荐方法[J]. 重庆工商大学学报(自然科学版), 2012, 29(7): 103-107.  
JIA Zhi-yang, SHI Yi-jin, LI Ding, et al. Online teaching video recommendation method based on collaborative filtering [J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2012, 29(7): 103-107.
- [11] WU S, TANG Y, ZHU Y, et al. Session-based recommendation with graph neural networks[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 346-353.
- [12] YU F, ZHU Y, LIU Q, et al. TAGNN: target attentive graph neural networks for session-based recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. NewYork: ACM, 2020: 1921-1924.
- [13] XIE Y, LI Z, QIN T, et al. Personalized session-based recommendation using graph attention networks[C]//Proceedings of the International Joint Conference on Neural Networks. Piscataway: IEEE Press, 2021: 1-8.
- [14] 贾中浩, 宾辰忠, 古天龙, 等. 基于知识图谱和用户长短期偏好的个性化景点推荐[J]. 智能系统学报, 2020, 15(5): 990-997.  
JIA Zhong-hao, BIN Chen-zhong, GU Tian-long, et al. Personalized attraction recommendation based on the knowledge graph and users' long-term and short-term preferences [J]. CAAI Transactions on Intelligent Systems, 2020, 15(5): 990-997.
- [15] 孙克雷, 许峰, 周华平. 运用上下文增强和分层注意力机制的社交推荐[J]. 厦门理工学院学报, 2022, 30(5): 35-43.  
SUN Ke-lei, XU Feng, ZHOU Hua-ping. Social recommendation based on context enhancement and hierarchical attention mechanism [J]. Journal of Xiamen University of Technology, 2022, 30(5): 35-43.
- [16] SARWAR B, KARYPIS G, KONSTAN J, et al. Item-based collaborative filtering recommendation algorithms[C]//Proceedings of the 10th international conference on World Wide Web. NewYork: ACM, 2001: 285-295.
- [17] ZHOU H, TAN Q, HUANG X, et al. Temporal augmented graph neural networks for session-based recommendations[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. NewYork: ACM, 2021: 1798-1802.
- [18] ZHANG C, ZHENG W, LIU Q, et al. SEDGN: Sequence enhanced denoising graph neural network for session-based recommendation[J]. Expert Systems with Applications, 2022, 203: 117391.
- [19] CAI F, PAN Z. Co-attentive graph learning for session-based recommendation[C]//Proceedings of the 5th International Conference on Data Science and Information Technology. Piscataway: IEEE Press, 2022. 2022: 1-5.

责任编辑:李翠薇