

融合时间和知识信息的生成对抗网络序列推荐算法

李忠伟¹, 周洁¹, 刘昕^{2*}, 吴金燊², 李可一²

(1. 中国石油大学(华东)海洋与空间信息学院, 山东 青岛 266580;

2. 中国石油大学(华东)计算机科学与技术学院, 山东 青岛 266580)

摘要: 序列推荐作为一种常用的推荐系统技术, 通过对用户的历史交互序列进行建模来预测下一个可能交互的项目。现有的序列推荐方法主要利用用户交互序列和上下文信息进行推荐, 忽略了序列中交互项目之间的时间间隔信息, 交互项目之间的组合依赖以及上下文信息中存在噪声的问题, 导致推荐结果受限。针对以上问题, 提出一种基于生成对抗网络的序列推荐模型 TKWGAN, 该模型包含一个生成器和一个判别器。生成器结合了用户历史交互序列和各项目之间的时间间隔信息对用户偏好进行建模并生成预测, 判别器则引入了知识图谱信息对项目进行语义扩充, 从而能更准确地对生成器的预测进行合理性判断。针对用户交互序列和知识图谱信息中可能存在噪声的问题, 提出一种基于小波变换的多核卷积神经网络来构造判别器, 以更全面、准确地捕获用户的潜在兴趣, 提高推荐的准确性。在 MovieLens-1M、Amazon Books 和 Yelp2018 这 3 个公开数据集上的实验结果表明, 与 8 个序列化推荐算法相比, 提出的 TKWGAN 模型在命中率(HR@N)和归一化折损累计增益(NDCG@N)指标上均有显著提升。

关键词: 推荐算法; 序列推荐; 生成对抗网络; 知识图谱; 小波卷积网络

源代码链接: <https://github.com/vjviolet521/TKWGAN>

中图分类号: TP18

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0068300

Sequence Recommendation Algorithm Based on Generative Adversarial Network Integrating Time and Knowledge Information

LI Zhongwei¹, ZHOU Jie¹, LIU Xin^{2*}, WU Jinyu², LI Keyi²

(1. College of Oceanography and Space Information, China University of Petroleum(East China), Qingdao 266580, Shandong, China;

2. College of Computer Science and Technology, China University of Petroleum(East China), Qingdao 266580, Shandong, China)

【Abstract】 Sequential recommendation is a pivotal technique within the realm of recommendation systems and is employed to predict subsequent interaction items by modeling the users' historical sequences of engagements. Nonetheless, contemporary sequential recommendation methods predominantly emphasize user interaction sequences and contextual data in their recommendations. This approach inadvertently disregards the salient temporal interval information between interaction items, the intricate interdependencies among these items, and potential perturbations in contextual information. Consequently, the efficacy of the resulting recommendations is constrained. To address these inherent limitations, this study proposes an innovative sequential recommendation model called TKWGAN, which is founded on a Generative Adversarial Network(GAN). This model consists of a generator and a discriminator. The generator seamlessly integrates the users' historical interaction sequences with temporal interval data pertaining to items within the sequence. This synthesis of information enables the accurate modeling of user preferences and the subsequent generation of predictions. The discriminator introduces salient insights offered by the knowledge graph to enrich the semantic context of the items. This augmentation of the contextual information facilitates a judicious assessment of the predictions formulated by the generator. To address the potential noise inherent in both user interaction sequences and knowledge graph data, a multikernel Convolutional Neural Network(CNN) augmented with wavelet transformation is introduced for the discriminator. This discerning approach enables a comprehensive exploration of users' latent interests, consequently elevating the precision of the recommendations. An empirical evaluation conducted on widely recognized datasets, specifically MovieLens-1M, Amazon Books, and Yelp2018, underscores the superiority of the TKWGAN model. In contrast to eight state-of-the-art sequential recommendation algorithms, the TKWGAN model demonstrates a marked enhancement in the Hit Rate(HR@N) and Normalized Discounted Cumulative Gain(NDCG@N) indicators.

【Key words】 recommendation algorithm; sequential recommendation; Generative Adversarial Network(GAN);

收稿日期: 2023-08-28 **修回日期:** 2023-12-14

基金项目: 国家重点研发计划(2018YFC1406204)。

通信作者 E-mail: * lx@upc.edu.cn

knowledge graph; wavelet convolution network

0 引用

随着互联网技术的不断发展,信息过载问题日益严重,如何从海量数据中挖掘出用户真正感兴趣的内容受到了大家的普遍关注。推荐系统作为一种信息过滤技术已被广泛应用于电子商务、社交媒体、在线视频和新闻等多个领域。在实际生活中,用户的交互行为和偏好往往是随着时间而变化的,因此序列推荐成为了推荐算法近些年的研究热点。序列推荐^[1-2]是通过对用户历史交互序列的建模,学习用户偏好的变化过程,从而预测用户下一个可能交互的项目。

现有的序列推荐方法^[3-5]主要是通过用户的历史交互序列来对用户偏好进行挖掘,这些方法虽然有效但是却存在一定的局限性。首先,用户与项目的交互是受到多种因素影响的。在新闻推荐中,同一个类别、同一个关键字可能会成为用户感兴趣的重要因素。而将知识图谱^[6]信息作为辅助信息整合到推荐系统的做法不仅可以提高推荐系统的准确性,而且也能提高推荐系统的可解释性。其次,用户交互项目的时间间隔也包含着重要信息。若有两个交互项目完全相同的序列,当序列中交互项目之间时间间隔不同时,其下一个可能交互的项目也会不同。此外,由于用户行为的不确定性,部分交互序列中可能会存在一些噪声或不相关的交互。

为了解决上述问题,本文受生成对抗网络(GAN)^[7-8]启发,提出了一种融合时间间隔信息和知识图谱信息的生成对抗网络序列推荐模型 TKWGAN。该模型包含两个模块,一个模块是基于 Transformer 模型的生成器,另一个模块是基于小波变换的判别器。在生成器模块中,本文提出了基于时间间隔感知的自注意力机制,将任意 2 个交互项的时间间隔都加入模型中。在判别器模块中,本文融合了经过预处理的知识图谱信息来挖掘用户和项目之间潜在的高阶关系,此外,提出了基于小波变换的卷积神经网络(CNN)来过滤序列和知识图谱中的噪声。本文将判别器的输出作为奖励信号,并通过基于策略梯度的强化学习方法将该信号反馈给生成器,用于指导生成器的训练。生成器与判别器之间不断博弈,使得生成器的生成更接近用户的真实意图,从而提高推荐的准确性。

本文的创新点和主要工作包括:

1)提出了融合时间间隔信息的生成器模型,使

其能更好地捕获用户随时间变化的动态偏好,提高生成器生成的准确性。

2)提出了融合知识图谱信息的判别器,通过建模其复杂的属性关系来挖掘用户和项目间的潜在联系,从而增强判别器的判断能力。

3)提出了基于小波变换的多核卷积神经网络来过滤用户交互序列和知识图谱中的噪声或无关信息,以提高推荐的准确性。

1 相关工作

本节将简要介绍与本文研究密切相关的推荐方法,其中包括生成对抗网络、知识感知推荐以及离散小波变换(DWT)。

1.1 生成对抗网络

生成对抗网络^[9-10]由 GOODFELLOW 等提出后,在图像生成、音乐生成及自然语言生成等领域大获成功。近些年,一些研究者开始尝试将生成对抗网络应用于推荐系统^[11],但目前生成对抗网络尚未被广泛使用。IRGAN^[12]是一种开创性的方法,首次展示了生成对抗网络在信息检索领域的优秀性能。CHAE 等^[13]提出了 CFGAN,该模型基于条件生成对抗网络,同时引入了协同过滤方法来进行非序列化推荐。MFGAN^[14]是首个将生成对抗网络用于序列推荐的模型,其采用自注意力机制来建模用户历史交互信息,并根据不同影响因素来构造多判别器,提高了推荐系统的可解释性。

1.2 知识感知推荐

知识感知推荐主要是指将知识图谱作为辅助信息用于推荐系统。知识图谱是由实体和关系组成的多关系图,包含着丰富的结构化知识和语义信息,因此可以帮助丰富用户和项目的描述,深层次地发现用户可能的偏好。知识图谱嵌入(KGE)^[15]通过图嵌入的方法将实体和关系映射到连续的向量空间中进行表征,从而扩充现有用户和项目的嵌入表征。该方法一经提出,便成为推荐系统领域的研究热点。KGAT 模型^[16]将用户历史交互数据和知识图谱结合起来构造协同知识图,并用 TransR 方法对图信息进行预训练得到其嵌入表征,接着使用基于自注意力机制的图网络结构得到推荐结果。KSR 模型^[17]将知识图谱中实体的嵌入表征与用户历史交互数据相关联从而得到用户的细粒度动态特征,有效地提高了新闻推荐的准确性。

1.3 离散小波变换

离散小波变换被广泛应用于图像处理、信号处理、时序数据分析等领域。通过对数据进行小波变换,可以将其转换到小波域中,从而更好地捕捉数据的局部细节和频率信息。Mallat 算法是最常用的快速小波变换算法之一,其通过多级迭代的方式将信号分解成不同尺度和频率的小波系数。梁小慧等^[18]提出基于自适应小波分解的时序模型,将小波变换与自注意力机制相结合从而获取时间序列的长短期特征。WCLR^[19]是基于小波卷积的对比学习

推荐方法,该方法利用自监督信号对序列推荐模型进行预训练,结合卷积神经网络来捕捉序列间的组合信息,从而提高推荐的准确率。

2 融合时间和知识信息的生成对抗网络序列推荐算法

本节主要介绍 TKWGAN 模型的问题定义、总体框架以及生成器、判别器这两大模块的具体实现方法。模型的整体框架如图 1 所示(彩色效果见《计算机工程》官网 HTML 版,下同)。




图 1 融合时间和知识信息的生成对抗网络序列推荐模型

Fig. 1 Sequential recommendation model based on generative adversarial network integrating time and knowledge information

2.1 问题定义

TKWGAN 模型的任务是根据用户的历史交互序列以及序列中不同项目之间的时间间隔信息和知识图谱信息来预测用户下一时刻感兴趣的项目,接下来对本文使用的符号进行说明。

$U=\{u_1, u_2, \dots, u_{|U|}\}$ 表示用户集合, $I=\{i_1, i_2, \dots, i_{|I|}\}$ 表示物品集合, 其中, $|U|$ 和 $|I|$ 分别表示用户总数和物品总数。每个用户 $u \in U$, $S_u = \{s_{u,1}, s_{u,2}, \dots, s_{u,|S_u|}\}$ 表示该用户的历史交互序列, 其中, $s_{u,t}$ 表示用户 u 在 t 时刻交互的项目。 $T_u = \{t_{u,1}, t_{u,2}, \dots, t_{u,|T_u|}\}$ 表示用户历史交互序列所对应的时间戳序列, 其中, $t_{u,t}$ 表示项目 $s_{u,t}$ 所对应的时间戳, R_u 表示用户 u 交互序列中项目之间时间间隔的集合。除此之外, 用三元组 $\langle e_{\text{head}}, r, e_{\text{tail}} \rangle$ 定义知识图谱, 其中 e_{head} 、 r 、 e_{tail} 分别表示头实体、关系、尾实体。

本文模型的生成器旨在根据用户在 t 时刻之前所有的交互项以及项目之间的时间间隔来预测用户在 $t+1$ 时刻将会交互的项目, 而判别器的目标是通过知识图谱提供的辅助信息来判断生成器的输出是否合理。该模型的最终目标是从候选项目中排序出用户最有可能交互的前 K 个项目。

2.2 融合时间信息的生成器

本文将 G_θ 作为 TKWGAN 模型的生成器, 其中, θ 表示 G_θ 中各种相关参数。通过自注意力机制构建的生成器的主干网络由嵌入表征层、自注意力块和预测层组成, 其框架图如图 2 所示。生成器通过捕获用户交互序列和项目时间间隔之间的潜在联系, 预测用户下一个时刻可能会交互的项目。本节将详细介绍各部分的实现细节, 重点介绍如何融合时间间隔信息。




图 2 融合时间间隔的生成器

Fig.2 Generator integrating time interval

2.2.1 相对时间间隔

本文只考虑用户的前 n 个交互项目,将用户交互序列设为固定长度序列 $s = (s_1, s_2, \dots, s_n)$ 。同理,将序列所对应的时间戳序列表示设为 $t = (t_1, t_2, \dots, t_n)$,其中, n 表示模型能处理的最长序列长度。由于每个用户的交互频率是不同的,即时间间隔偏好是不同的,因此仅考虑每一个用户交互序列中的相对时间间隔。用 $|t_i - t_j|$ 表示项目 i 和项目 j 之间的时间间隔,令 R_u 表示用户 u 所有交互项之间时间间隔的集合,其中, $|t_i - t_j| \in R_u$ 。用 $r_{\max} = \frac{\max R_u}{\epsilon}$ 表示一个交互序列中最大的相对时间间隔,用超参数 ϵ 来调节 $r_{\max}$ 的大小,接着通过以下方法得到预处理后的相对时间间隔:

$$r_{u,i,j} = \left\lfloor \frac{\min(|t_i - t_j|, r_{\max})}{r_{\max}} \right\rfloor \quad (1)$$

式中: $r_{u,i,j} \in \mathbb{N}$ 。值得注意的是,如果 t_i, t_j 之间的时间间隔过大,表示项目之间的影响力将过小,这就导致项目 i 和项目 j 失去其原有参考价值,因此,本文使用 $\min(|t_i - t_j|, r_{\max})$ 将所有的时间间隔控制在合理范围内。

2.2.2 融合时间信息的自注意力机制

在嵌入层中,首先构造一个包含所有项目的嵌入矩阵 $\mathbf{M}_I \in \mathbb{R}^{|I| \times d}$,其中, $|I|$ 表示所有项目的个数, d 表示嵌入维度。给定用户的前 n 个交互项目,通过在 $\mathbf{M}_I$ 中查询,得到该用户交互项目的嵌入矩阵 $\mathbf{E}_I \in \mathbb{R}^{|I| \times d}$:

$$\mathbf{E}_I = \begin{bmatrix} m_{s_1} \\ m_{s_2} \\ \vdots \\ m_{s_n} \end{bmatrix} \quad (2)$$

式中: $m_{s_i} \in \mathbb{R}^d$ 。依据文献[20]中的方法,使用两个可学习的矩阵 $\mathbf{M}_{P,K} \in \mathbb{R}^{n \times d}$ 和 $\mathbf{M}_{P,V} \in \mathbb{R}^{n \times d}$ 分别表示自注意力机制中的键和值这两个权重矩阵,对序列中的位置信息的键和值进行映射后得到 $\mathbf{E}_{P,K} \in \mathbb{R}^{n \times d}$ 和 $\mathbf{E}_{P,V} \in \mathbb{R}^{n \times d}$:

$$\mathbf{E}_{P,K} = \begin{bmatrix} p_{k,1} \\ p_{k,2} \\ \vdots \\ p_{k,n} \end{bmatrix} \quad \mathbf{E}_{P,V} = \begin{bmatrix} p_{v,1} \\ p_{v,2} \\ \vdots \\ p_{v,n} \end{bmatrix} \quad (3)$$

为了更好地融合时间间隔信息,采用与位置信息嵌入表征相同的方法得到 $\mathbf{E}_{R,K} \in \mathbb{R}^{n \times n \times d}$ 和 $\mathbf{E}_{R,V} \in \mathbb{R}^{n \times n \times d}$:

$$\mathbf{E}_{R,K} = \begin{bmatrix} r_{k,1,1} & r_{k,1,2} & \cdots & r_{k,1,n} \\ r_{k,2,1} & r_{k,2,2} & \cdots & r_{k,2,n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{k,n,1} & r_{k,n,2} & \cdots & r_{k,n,n} \end{bmatrix} \quad \mathbf{E}_{R,V} = \begin{bmatrix} r_{v,1,1} & r_{v,1,2} & \cdots & r_{v,1,n} \\ r_{v,2,1} & r_{v,2,2} & \cdots & r_{v,2,n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{v,n,1} & r_{v,n,2} & \cdots & r_{v,n,n} \end{bmatrix} \quad (4)$$

上述嵌入表征将会被用于融合时间间隔信息的自注意力块中来计算权重信息并生成预测。

在分别得到项目、位置和时间间隔的键映射矩阵和值映射矩阵之后,将它们送入多层自注意力块。该模块包含一个自注意力子层和一个前馈神经网络。令 $\mathbf{Z} = (z_1, z_2, \dots, z_n)$ 表示该模块的输出序列,其中, z_i 是项目嵌入矩阵 $\mathbf{E}_I$ 通过加权线性变换得到的:

$$z_i = \sum_{j=1}^n \alpha_{i,j} (m_{s_j} \mathbf{W}_V + r_{v,i,j} + p_{v,j}) \quad (5)$$

式中: $\mathbf{W}_V \in \mathbb{R}^{d \times d}$ 表示自注意力机制中值的权重矩阵; $m_{s_j} \in \mathbf{E}_I$, $p_{v,j} \in \mathbf{E}_{P,V}$, $r_{v,i,j} \in \mathbf{E}_{R,V}$ 。每一个权重系数 $\alpha_{i,j}$ 通过下式进行计算:

$$\alpha_{i,j} = \frac{\exp e_{i,j}}{\sum_{k=1}^n \exp e_{i,k}} \quad (6)$$

$e_{i,j}$ 通过下式进行计算:

$$e_{i,j} = \frac{m_{s_i} \mathbf{W}_Q (m_{s_j} \mathbf{W}_K + r_{k,i,j} + p_{k,j})^T}{\sqrt{d}} \quad (7)$$

式中: $\mathbf{W}_Q \in \mathbb{R}^{d \times d}$, $\mathbf{W}_K \in \mathbb{R}^{d \times d}$ 分别表示自注意力机制中查询的权重矩阵和键的权重矩阵。在序列推荐中,当预测用户在 $t+1$ 时刻可能交互的项目时,只有前 t 个时刻的项目信息可以被利用,因此,本文将对自注意力机制进行遮罩处理。对输出结果依次进行线性变换、层归一化、残差连接等操作:

$$\text{FFN}(z_i) = \max(0, x \mathbf{W}_1 + b_1) \mathbf{W}_2 + b_2 \quad (8)$$

$$\mathbf{Z}_i = z_i + \text{Droupout}(\text{FFN}(\text{LayerNorm}(z_i))) \quad (9)$$

式中: $\mathbf{W}_1$ 、 $\mathbf{W}_2$ 、 b_1 、 b_2 都是可训练的参数。

为了得到生成器的预测,使用 Softmax 函数来计算用户对所有项目的偏好得分:

$$G_\theta(s_{t+1} | s_{i:t}) = \text{Softmax}(\mathbf{Z}_{L,t} \mathbf{M}_{I,i})_{[s_{t+1}]} \quad (10)$$

2.3 融合知识信息的判别器

如上文所述,判别器的任务是判断生成器的预测是否合理。本文用 D_ϕ 来表示判别器,其中, ϕ 表示 D_ϕ 中的一系列相关参数。在判别器中,本文将知识图谱信息进行编码用于探索用户和项目之间的潜在联系,同时设计了基于小波变换的多核卷积网络来过滤用户交互序列与知识图谱信息的噪声及不相关信息,从而提高判别器的辨别能力。

2.3.1 融合知识信息的小波变换模块

为了利用知识图谱信息,本文通过通用知识图谱 Freebase 找到对应的项目进行实体关联,使用 TransH 方法将包含的实体元素映射到一个连续的向量空间中,使得项目获得更加丰富的嵌入向量。

将利用 TransH 算法得到的实体嵌入向量和序列中相对应的项目嵌入向量相加,以此来对项目的嵌入表征进行语义扩充。用 $\mathbf{E}_{KG}$ 表示项目知识图谱的嵌入表征,其中,项目 m_s 所对应的语义向量为 $\mathbf{m}_{KG}$, $\mathbf{m}_{KG} \in \mathbf{E}_{KG}$ 。两个嵌入表征矩阵进行相加 $\mathbf{E}_D = \mathbf{E}_{I,G} + \mathbf{E}_{KG}$ 作为判别器的输入,即对生成器生成序列的嵌入表征进行语义扩充,其中, $\mathbf{E}_{I,G}$ 表示生成序列的嵌入表征。

该模块对输入矩阵 $\mathbf{E}_D$ 进行离散小波变换提取项目的多种特征。将 $\mathbf{E}_D$ 通过自适应的小波变换,分解为高频子序列和低频子序列,再对 2 个子序列进行分解,最后生成 3 个小波系数,其过程如图 3 所示。




图 3 离散小波变换

Fig.3 Discrete wavelet transform

小波分解后将高频分量丢弃以降低输入的噪声,得到 $\mathbf{E}_w$:

$$\mathbf{E}_w = \text{DWT}(\mathbf{E}_D) = \mathbf{D}_{LH} + \mathbf{A}_{HL} + \mathbf{A}_{LL} \quad (11)$$

2.3.2 多核卷积模块

多核卷积神经网络提取用户交互序列中的依赖关系和用户的潜在兴趣,其中包括水平卷积层和垂直卷积层。水平卷积层通过不同尺寸的卷积核捕捉序列之间的组合依赖,垂直卷积层则是通过大小固定的卷积核对每个潜在维度的信息进行聚合,下面介绍实现的具体细节。

通过水平卷积层,可以从用户交互序列中提取组合依赖,其中包含 m 个水平滤波器 $\mathbf{H}_k \in \mathbb{R}^{h \times d}$, $1 \leq k \leq m$,滤波器 $\mathbf{H}_k$ 高度为 h ,宽度与 $\mathbf{E}_w$ 的维度相同为 d 。 $\mathbf{H}_k$ 将在输入矩阵 $\mathbf{E}_w$ 上滑动提取交互特征,其滑动范围是 $1 \leq i \leq n - h + 1$,其中, i 表示 $\mathbf{E}_w$ 的第 i 行,则第 i 次的计算结果为:

$$c_{k,i} = \varphi_c(\mathbf{E}_{i,i-h+1} \odot \mathbf{H}_k) \quad (12)$$

式中: $\varphi_c(\cdot)$ 表示卷积神经网络的激活函数。每个水平滤波器进行 $n - h + 1$ 次卷积,水平卷积层的最终结果是 $\mathbf{O}_h$:

$$\mathbf{c}_k = [c_{k,1}, c_{k,2}, \dots, c_{k,n-h+1}] \quad (13)$$

$$\mathbf{O}_h = \text{Pool}_{\max}(\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_k, \dots, \mathbf{c}_m) \quad (14)$$

使用最大池化操作来处理 $\mathbf{c}_k$ 以得到其最显著的特征。

在垂直卷积层中,通过 p 个 $n \times 1$ 维的矩阵来构造垂直滤波器 $V_k \in \mathbb{R}^{n \times 1}$, $1 \leq k \leq p$, 其中, n 表示用户交互序列的长度。每个垂直卷积滤波器 V_k 在嵌入矩阵 E_w 从左向右移动并进行内积操作,该操作实际上是嵌入矩阵 E_w 的 n 行加权和,权重是垂直滤波器中每个元素的值,其内积结果如下:

$$v_k = \sum_{l=1}^n V_{k,l} \cdot E_w$$

$$O_v = [v_1, v_2, \dots, v_k, \dots, v_p] \quad (15)$$

得到水平卷积层和垂直卷积层的结果后,将其整合输入全连接层以获得其更高阶的特征:

$$z = \varphi_c \left(W \begin{bmatrix} O_h \\ O_v \end{bmatrix} + b \right) \quad (16)$$

式中: W 是全连接层的权重矩阵; $\varphi_c(\cdot)$ 是激活函数。

最终要判断生成器所生成的预测是否合理,这里将采用多层感知机对多核卷积神经网络的输出结果进行处理得到一个合理性程度预测:

$$y = \text{MLP}(z) \quad (17)$$

y 即表示判别器对于生成序列合理性程度的评分,该评分反映了判别器认为该序列来自真实数据分布的概率,将会作为奖励信号反馈给生成器,以指导生成器的学习。

2.4 训练方法

如上文所述,本文首先训练了一个生成器 G_θ , 根据用户历史交互序列和序列中项目之间的时间间隔信息来预测用户下一时刻将会感兴趣的项目。同时训练了一个判别器,通过融合知识图谱信息来扩

$$\nabla_\theta J(\theta) = \nabla_\theta \sum_{s_{t+1} \in I} G_\theta(s_{t+1} | s_{1:t}, r_{1:t}) \cdot R(s_{1:t}, s_{t+1}) = \sum_{s_{t+1} \in I} \nabla_\theta G_\theta(s_{t+1} | s_{1:t}, r_{1:t}) \cdot R(s_{1:t}, s_{t+1}) =$$

$$\sum_{s_{t+1} \in I} G_\theta(s_{t+1} | s_{1:t}, r_{1:t}) \nabla_\theta \log_a G_\theta(s_{t+1} | s_{1:t}, r_{1:t}) \cdot R(s_{1:t}, s_{t+1}) =$$

$$E_{s_{1:t+1} \sim G_\theta} [\nabla_\theta \log_a G_\theta(s_{t+1} | s_{1:t}, r_{1:t}) \cdot R(s_{1:t}, s_{t+1})] \quad (21)$$

本文使用梯度上升来更新生成器的参数,如下所示:

$$\theta \leftarrow \theta + \gamma \nabla_\theta J(\theta) \quad (22)$$

综上所述,生成器根据用户历史交互序列和序列中项目的时间间隔信息生成要推荐的项目,并根据判别器反馈的奖励信号,采用策略梯度方式来更新参数,以达到最佳效果。训练判别器时,本文将生成的序列作为负样本,而将真实的交互序列作为正样本进行参数更新,以更好地区分生成序列和真实序列。此过程持续到模型收敛方可结束。

充项目的语义表征,判别生成序列的合理程度,并产生反馈信号指导生成器的训练。

由于从项目集中采样是一个离散的过程,因此不能直接使用梯度下降的方法。根据文献[21],本文采用基于策略梯度的强化学习方法来联合训练 G_θ 和 D_ϕ 。接下来将详细描述其实现过程。

将当前的用户交互序列定义为状态 s , 即 $s_{1:t} = \{s_1, s_2, \dots, s_t\}$, 动作 B 表示预测用户下一个时刻交互的项目,那么在生成器中可以被符号化为 $G_\theta = (s_{t+1} | s_{1:t})$ 。如果当前状态 s 为 $s = s_{1:t}$, 采取的动作 $B = s_{t+1}$, 那么状态 s 将会转换到一个新的状态 $s' = s_{1:t+1}$, 其中, $s_{1:t+1} = \{s_1, s_2, \dots, s_{t+1}\}$ 。每采取一个动作,判别器 D_ϕ 都将产生一个奖励 R 。根据上述策略定义生成器的目标函数为 $J(\theta)$, 即要最大化奖励 R 。

$$J(\theta) = \sum_{s_{t+1} \in I} G_\theta(s_{t+1} | s_{1:t}, r_{1:t}) \cdot R(s_{1:t}, s_{t+1}) \quad (18)$$

$R(s_{1:t}, s_{t+1})$ 表示根据当前状态 s 采取动作 B 所产生的奖励,其定义如下:

$$R(s_{1:t}, s_{t+1}) = \omega y \quad (19)$$

式中: ω 是一个调节参数。

接着将通过最小化损失函数来优化判别器,使其区分真实的数据分布与生成序列,如下所示:

$$\min_{\phi} \{ -E_{s_{1:t+1} \sim P_{\text{data}}} [\log_a D_\phi(s_{1:t+1})] - E_{s_{1:t+1} \sim G_\theta} [\log_a (1 - D_\phi(s_{1:t+1}))] \} \quad (20)$$

式中: P_{data} 表示真实的数据分布。每次更新完判别器后,使用判别器提供的反馈信号来更新生成器,其具体计算如下:

3 实验

本节将详细描述实验的设置与结果以验证本文模型的有效性,将使用 3 个不同领域、不同稀疏度的经典数据集来评估该模型的性能。

3.1 数据集

本文将使用 MovieLens-1M(ML-1M)、Amazon Books(Books)和 Yelp2018 作为实验数据集,由于 Amazon Books 数据集过于庞大,因此本文在保证随机性的前提下选取了其中的一部分。数据集详细信息如表 1 所示。

表 1 数据集的统计信息

Table 1 Statistic of datasets

数据集	用户数/个	项目数/个	交互次数/次	用户平均交互次数/次	实体数/个	关系数/个
ML-1M	6 040	3 416	1 000 209	166	441 674	43
Books	70 595	24 915	846 097	10	88 572	39
Yelp2018	45 919	45 538	1 414 444	24	90 961	42

本文将用户的历史交互记录按照时间戳信息升序排列作为用户历史交互序列。为了构建知识图谱嵌入表征,本文通过通用知识图谱 Freebase 找到对应的项目进行实体关联,接着使用 TransH 方法得到项目的语义表征信息。本文移除了出现频率不高的实体关系,因其对模型性能提升没有较大的作用。

3.2 评价指标

本文的目的是向用户推荐预测概率最高的前 K 个物品,使用命中率($HR@N$)和归一化折损累计增益($NDCG@K$)作为 TKWGAN 模型的评价指标。 $HR@N$ 用于衡量预测结果的准确率,表示前 N 项预测正确的项目所占比例,计算公式为:

$$HR@N = \frac{1}{n} \sum_{i=1}^n n_{hit} \quad (23)$$

式中: n 表示样本数量,当正确物品在推荐的前 N 项时, $n_{hit} = 1$, 否则, $n_{hit} = 0$ 。

$NDCG@N$ 用于衡量推荐列表的质量,即给位于推荐列表前面的正确项目赋予高分,给位于推荐列表尾端的正确项目赋予低分,总得分越高就表明推荐质量越好,计算公式为:

$$NDCG@N = \sum_{i=1}^N \frac{1}{lb(rank_i + 1)} \quad (24)$$

式中: $rank_i$ 表示正确项目在推荐列表中的位置。

根据文献[14],从未与用户交互过的项目中随机抽取 100 个项目作为负样本集,与用户实际交互项目排列在一起作为 TKWGAN 模型的输入并对其进行排序。本文设置 $N=10$ 来展示模型的评估结果。

3.3 对比方法

本文在 MFGAN 模型,即基于自注意力生成对抗网络序列推荐算法的基础上,引入时间间隔信息和知识图谱信息改进了生成器模型和判别器模型,另外增加了小波变换模型用于过滤序列中的噪声信息。所以在实验部分,首先验证了时间间隔信息和知识图谱信息对于推荐算法的有效性,以 IRGAN、MFGAN、TiSASRec 模型为基线与本文模型进行比较。为了验证生成对抗网络模型的性能,本文与基于自注意力机制主干网络的代表性模型 SASRec 和基于 MLP 主干网络的代表性模型 FMLP-Rec 进行比较。其次,为了充分验证模型的有效性,本文还

选取了 FPMC、GRU4Rec、Caser 进行对比,其中, FPMC 是传统的推荐模型,GRU4Rec、Caser 分别是具有不同主干网络的序列推荐模型。对比模型介绍如下:

1) IRGAN^[12]: 是首个将生成对抗网络应用于推荐系统的模型,其最初目的是用于统一信息检索领域,即生成器预测与查询最为相关的项目,判别器用来尽可能准确区分真正相关的项目与生成器生成的项目。

2) FPMC^[4]: 是一种融合了矩阵分解和马尔可夫链的模型,可以用来同时捕捉用户的长期偏好和动态信息。

3) GRU4Rec^[22-23]: 是将循环神经网络(RNN)用于序列推荐的开创性模型,通过对用户交互序列的建模来进行推荐。

4) Caser^[24]: 将 CNN 引入了序列推荐,通过多个卷积层对用户的长期偏好及短期兴趣进行提取,从而提高推荐的准确性。

5) SASRec^[5]: 是目前大多数基于序列化推荐算法常用的基准模型,其基于自注意力机制的序列推荐,考虑用户序列中不同交互的重要程度。

6) TiSASRec^[25]: 是一种基于自注意力机制的序列推荐算法,不仅考虑了项目的绝对位置,还考虑了序列中项目之间的时间信息。

7) MFGAN^[14]: 是首个将 GAN 引入序列推荐的模型,其生成器用于生成用户可能交互的项目,多个判别器来评估不同因素对推荐的影响。

8) CCL^[26]: 本文提出了一个新的损失函数 Cosine Contrastive Loss(CCL),将其合并到统一的协同过滤模型框架中,命名为 simpleX。

9) FMLP^[27]: 本文通过一系列分析实验发现该场景下滤波算法可以减少该过拟合问题,提出一个纯多层感知机(MLP)架构的模型以进行用户历史序列的编码并完成推荐任务。

3.4 参数设置

TKWGAN 模型基于自注意力机制构造生成器,基于小波变换的多核卷积神经网络构造判别器,其中生成器中融合了项目间时间间隔信息,判别器中融合了知识图谱信息。TKWGAN 模型是基于

Tensorflow 实现,利用 Adam 优化器进行优化的。根据文献[14,21]中的方法,本文使用传统最大似然估计(MLE)方法预训练该模型的生成器来加快模型的收敛速度。为了保证对比公平,对于所有模型中的通用超参数,运用网格搜索在验证集上寻找最优参数设置。考虑学习率取值范围为 $\{0.000\ 1, 0.000\ 2, 0.000\ 3, 0.000\ 4, 0.000\ 5\}$,数据集的最大序列长度取值范围为 $\{10, 20, 30, 40, 50\}$,知识图谱嵌入表征维度和序列嵌入表征维度相同,其取值范围为 $\{10, 20, 30, 40, 50\}$ 。所有其他超参数设置和初始化策略与文献[14]中保持一致。下面将通过实验找出最优超参数的设置。本文模型是在 PyTorch 框架中实现的,文中提及的所有深度学习模型都是在配备 Intel Core CPU i9-10900k、96 GB RAM 和 NVIDIA RTX 3090 的计算机上进行实验的。

3.5 对比实验

表 2 展示了本文模型 TKWGAN 与 8 个对比模型在 3 个公共数据集上的性能比较,评价指标为 HR@10 和 NDCG@10,加粗数据表示最优值。根据实验结果对比可得:

表 2 各模型实验结果对比

Table 2 Performance comparison of different models

数据集	评估指标	IRGAN	FPMC	GRU4Rec	Caser	SASRec	TiSASRec	MFGAN	CCL	FMLP	TKGAN
ML-1M	NDCG@10	0.236 3	0.397 1	0.433 4	0.533 4	0.564 8	0.571 1	0.598 4	0.589 1	0.597 7	0.604 3
	HR@10	0.430 2	0.618 2	0.652 2	0.760 5	0.803 1	0.803 5	0.821 7	0.812 5	0.820 9	0.831 4
Books	NDCG@10	0.277 5	0.485 6	0.570 1	0.507 4	0.579 7	0.578 1	0.599 7	0.597 2	0.600 1	0.610 8
	HR@10	0.586 7	0.710 9	0.777 4	0.724 7	0.789 9	0.791 3	0.807 4	0.801 3	0.808 9	0.817 4
Yelp2018	NDCG@10	0.315 7	0.479 7	0.569 8	0.522 4	0.574 4	0.577 6	0.590 4	0.591 2	0.594 4	0.601 3
	HR@10	0.676 2	0.778 7	0.838 4	0.803 9	0.847 8	0.852 5	0.857 9	0.853 2	0.872 0	0.864 1

3.6 消融实验

本节将在 3 个数据集上进行消融实验来评估本文模型中所加入信息的有效性,TiSASRec 模型将作为基线方法进行比较。本文提出了两种变体模型 KWGAN 和 TWGAN 来分别分析时间间隔信息和知识图谱信息对本文模型的影响。其中,KWGAN 表示生成器中仅考虑用户交互序列不考虑项目间的时间间隔,TWGAN 表示判别器未加入知识图谱嵌入表征进行扩充。实验选择 HR@10 和 NDCG@10 作为评估指标,各模型实验结果如图 4 所示。

从实验结果中可以得出,未引入知识图谱信息的模型 TWGAN,其推荐性能较 TKWGAN 模型有明显下降,但是优于 TiSASRec。这表明引入知识图谱信息进行语义扩充对本文模型的性能至关重

1)在非序列推荐的模型中,基于 GAN 的模型 IRGAN 是首次将生成对抗网络模型用于信息检索领域的尝试,因此推荐性能较差。

2)与非序列推荐模型相比,序列推荐模型的推荐效果有较为明显的提升。在序列推荐的模型中,Caser、GRU4Rec、SASRec、TiSASRec 显示出较 FPMC 更优秀的性能,展现出了深度神经网络较强的特征提取能力。基于自注意力机制的模型 SASRec、TiSASRec 模型在每个数据集上的表现均强于基于 RNN、CNN 架构的模型,这是由于基于自注意力机制的编码器可以更好地捕获序列特征。TiSASRec 比 SASRec 推荐效果更佳,因其不仅考虑了项目的位置信息,也考虑了项目间的时间间隔信息。MFGAN 因其采用了多判别器的生成对抗网络对不同影响因素进行评估,推荐效果最佳。

3)本文所提出的 TKWGAN 模型显示出较基线方法更优的推荐性能,得益于该模型使用了融合时间间隔信息的自注意力机制作为生成器,使用了融合知识图谱信息的多核卷积网络作为判别器。下文将通过实验详细阐述模型各个部分的有效性。




图 4 TKWGAN 消融实验结果(NDCG@10)

Fig.4 Ablation experiment results of TKWGAN model(NDCG@10)

要。未在交互序列中引入时间间隔信息的模型 KWGAN,其推荐效果较 TKWGAN 模型也有明显下降。同时也可以发现,在不同的数据集上时间信

息和知识图谱信息对推荐结果的影响程度是不同的,如在 ML-1M 数据集上,知识图谱信息对推荐性能的影响大于时间间隔信息对其的影响,而在 Books 和 Yelp2018 数据集上,时间间隔信息对推荐性能的影响更大。

3.7 超参数实验

如上文所述,在进行对抗训练之前,本文利用最大似然估计对生成器进行预训练。预训练次数的取值范围为 $\{10, 50, 100, 150, 200\}$,不同预训练次数对于本文模型的影响如图 5 所示,不同预训练次数与模型损失之间的关系如图 6 所示。




图 5 不同预训练次数对应的损失

Fig.5 Loss with different pre-training epochs




图 6 不同预训练次数对应的模型性能(NDCG@10)

Fig.6 Performance with different pre-training epochs(NDCG@10)

从实验结果中可以得出:当预训练次数为 10 次时,模型的收敛速度很慢;当预训练次数为 200 次时,模型收敛得最快且性能最优。该实验说明对生成器进行充分预训练后,推荐结果最优。

另外,本文还探索了微调阶段不同的序列长度取值对推荐性能的影响。最大序列长度的选择范围为 $\{10, 20, 30, 40, 50\}$,评价指标为 NDCG@10,实验结果如图 7 所示。

实验结果显示了最大长度 n 从 10 到 50 的 NDCG@10 的变化,同时保持其他最佳超参数不变。

当考虑更长的序列时,性能会提高并最终开始收敛。




图 7 最大序列长度 n 对性能的影响(NDCG@10)

Fig.7 Effect of maximum sequence length n on performance(NDCG@10)

4 结束语

本文充分考虑了影响用户下一时刻交互项目的时间间隔信息和知识图谱信息,提出一种基于生成对抗网络的序列推荐算法。为充分挖掘用户的动态偏好,使用融合了时间间隔信息的自注意力机制对用户交互序列进行建模,同时使用基于小波变换的多核卷积神经网络过滤交互序列和知识图谱中的噪声,利用扩充的语义信息充分挖掘用户的潜在偏好,提高推荐的准确率。本文采用生成对抗网络作为主干网络,在此过程中,生成器采用基于自注意力机制的算法来拟合历史交互序列中项目的特征,生成虚假的生成样本,判别器负责将知识图谱数据融合进来从而将真实数据和生成数据分开来并指导生成器的训练,两者不断优化,最终达到最优效果,生成器能够生成符合历史交互序列特征的样本数据。在 3 个数据集上的实验结果表明,TKWGAN 模型优于现有的序列推荐算法,但是由于生成对抗网络的不稳定性,该模型需进行多次训练才能达到稳定。下一步将探索其他生成网络,如扩散模型在序列推荐中的推荐性能,以获得更高效更准确的推荐结果。

参考文献

- [1] BIAN S Q, ZHAO W X, WANG J P, et al. A relevant and diverse retrieval-enhanced data augmentation framework for sequential recommendation[C]//Proceedings of the 31st ACM International Conference on Information and Knowledge Management. New York, USA: ACM Press, 2022: 2923-2932.
- [2] ZHOU K, WANG H, WEN J R, et al. Enhancing multi-view smoothness for sequential recommendation models[J]. ACM Transactions on Information Systems, 2023, 41(4): 1-27.
- [3] HE R N, MCAULEY J. Fusing similarity models with Markov chains for sparse sequential recommendation[C]//Proceedings of the IEEE International Conference on Data

- Mining (ICDM). Washington D. C., USA: IEEE Press, 2016; 191-200.
- [4] RENDLES, FREUDENTHALER C, SCHMIDT-THIEME L. Factorizing personalized Markov chains for next-basket recommendation[C]//Proceedings of the 19th International Conference on World Wide Web. New York, USA: ACM Press, 2010; 811-820.
- [5] KANG W C, MCAULEY J. Self-attentive sequential recommendation[C]//Proceedings of the IEEE International Conference on Data Mining (ICDM). Washington D. C., USA: IEEE Press, 2018; 197-206.
- [6] 汪雨竹, 彭涛, 朱蓓蓓, 等. 基于元学习的小样本知识图谱补全[J]. 吉林大学学报(理学版), 2023, 61(3): 623-630.
- WANG Y Z, PENG T, ZHU B B, et al. Few-shot knowledge graph completion based on meta learning[J]. Journal of Jilin University(Science Edition), 2023, 61(3): 623-630. (in Chinese)
- [7] QIU R H, HUANG Z, YIN H Z. Memory augmented multi-instance contrastive predictive coding for sequential recommendation[C]//Proceedings of the IEEE International Conference on Data Mining (ICDM). Washington D. C., USA: IEEE Press, 2021; 519-528.
- [8] NIS, ZHOU W, WEN J H, et al. Enhancing sequential recommendation with contrastive Generative Adversarial Network[J]. Information Processing & Management, 2023, 60(3): 103331.
- [9] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [10] LIU M Y, TUZEL O. Coupled generative adversarial networks[J]. Advances in Neural Information Processing Systems, 2016, 29.
- [11] BHARADHWAJ H, PARK H, LIM B Y. RecGAN: recurrent generative adversarial networks for recommendation systems[C]//Proceedings of the 12th ACM Conference on Recommender Systems. New York, USA: ACM Press, 2018; 372-376.
- [12] WANG J, YU L T, ZHANG W N, et al. IRGAN: a minimax game for unifying generative and discriminative information retrieval models[C]//Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2017; 515-524.
- [13] CHAED K, KANG J S, KIM S W, et al. CFGAN: a generic collaborative filtering framework based on generative adversarial networks[C]//Proceedings of the 27th ACM International Conference on Information and Knowledge Management. New York, USA: ACM Press, 2018; 137-146.
- [14] REN R Y, LIU Z Y, LI Y L, et al. Sequential recommendation with self-attentive multi-adversarial network[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2020; 89-98.
- [15] WANG Z, ZHANG J W, FENG J L, et al. Knowledge graph embedding by translating on hyperplanes[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2014, 28(1): 1112-1119.
- [16] WANG X, HE X N, CAO Y X, et al. KGAT: knowledge graph attention network for recommendation [C] // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York, USA: ACM Press, 2019; 950-958.
- [17] BAI J M, HUANG X, LI M, et al. KSR: knowledge-based sequential news recommendation system[J]. IOP Conference Series: Materials Science and Engineering, 2020, 799(1): 012042.
- [18] 梁小慧, 郭晟楠, 万怀宇. 基于自适应小波分解的时间序列分类方法[J]. 计算机工程, 2022, 48(4): 81-88, 98.
- LIANG X H, GUO S N, WAN H Y. Time series classification method based on adaptive wavelet decomposition [J]. Computer Engineering, 2022, 48(4): 81-88, 98. (in Chinese)
- [19] 许凤, 杨兴耀, 于炯, 等. 小波卷积增强的对比学习推荐算法[J]. 计算机工程, 2023, 49(5): 105-111, 121.
- XU F, YANG X Y, YU J, et al. Wavelet convolution enhanced contrastive learning recommendation algorithm[J]. Computer Engineering, 2023, 49(5): 105-111, 121. (in Chinese)
- [20] SHAW P, USZKOREIT J, VASWANI A. Self-attention with relative position representations[C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. New Orleans, USA: Association for Computational Linguistics, 2018; 464-468.
- [21] YU L T, ZHANG W N, WANG J, et al. SeqGAN: sequence generative adversarial nets with policy gradient [EB/OL]. [2023-04-15]. <https://arxiv.org/pdf/1609.05473.pdf>.
- [22] HIDASI B, KARATZOGLOU A, BALTRUNAS L, et al. Session-based recommendations with recurrent neural networks[EB/OL]. [2023-04-15]. <https://arxiv.org/pdf/1511.06939.pdf>.
- [23] 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. New York, USA: ACM Press, 2016; 241-248.
- [24] TANG J X, WANG K. Personalized top-N sequential recommendation via convolutional sequence embedding[C]//Proceedings of the 11th ACM International Conference on Web Search and Data Mining. New York, USA: ACM Press, 2018; 565-573.
- [25] 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, USA: ACM Press, 2020; 322-330.
- [26] MAO K, ZHU J, WANG J, et al. SimpleX: a simple and strong baseline for collaborative filtering[C]//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. New York, USA: ACM Press, 2021; 1243-1252.
- [27] ZHOU K, YU H, ZHAO W X, et al. Filter-enhanced MLP is all you need for sequential recommendation [C] // Proceedings of the ACM Web Conference. New York, USA: ACM Press, 2022; 2388-2399.