

文章编号:1671-6833(2026)04-0100-08

基于自适应双向信息流的序列推荐方法

马丽^{1,2}, 刘文哲¹, 李雨豪¹

(1. 河北地质大学 信息工程学院, 河北 石家庄 052161; 2. 河北地质大学 智能传感物联网技术河北省工程研究中心, 河北 石家庄 052161)

摘要:通过分析序列推荐中历史与未来信息融合效率欠佳及噪声干扰的问题,提出了一种基于自适应双向信息流的序列推荐方法。在双路径编码器架构基础上,整合了层次化历史总结模块以提炼用户长期偏好,并引入动态频域滤波来抑制数据噪声。所提方法充分考虑了历史与未来信息间的依赖性和交互性,采用自适应双向信息流机制,通过不确定性感知动态调节二者的融合权重,从而精准地刻画用户偏好的演变轨迹。为了验证方法的有效性,在 Beauty、Sports、Yelp 和 ML1M 这4个公开数据集上进行了实验,并与10种主流方法进行对比分析。实验结果表明:所提方法在 *NDCG*、*HR*、*MRR* 这3个指标上均优于对比的基线方法。相较于 FMLP-Rec、DualRec 与 Oracle4Rec 这3个头部基线模型,所提方法的 *HR@20* 在 Beauty 和 Yelp 数据集上分别为 0.652 0 和 0.913 3,比三者的平均水准分别提升了 2.08 个百分点和 2.89 个百分点;*NDCG@20* 在 Beauty 和 Yelp 数据集上分别达到 0.394 4 和 0.564 5,比三者的平均水准分别提升了 2.67 个百分点和 2.72 个百分点。

关键词:序列推荐; 自适应双向信息流; 动态偏好建模; 频域滤波; 注意力机制

中图分类号:TP391.3; TP183; F724.6

文献标志码:A

doi:10.13705/j.issn.1671-6833.2026.04.003

当前互联网环境中,信息过载问题日益严重,作为帮助用户高效获取个性化内容的关键技术,推荐系统重要性持续凸显^[1]。序列推荐技术通过分析用户历史交互行为中的动态偏好模式,在电子商务、数字内容平台等多个领域展现出重要应用价值。早期推荐系统主要采用基于矩阵分解的方法,通过从用户-物品交互矩阵^[1]中提取低维隐向量进行推荐,但这类方法往往会忽略用户行为数据的时序特性及其动态演化规律。

为更精准地捕捉用户动态偏好,序列推荐模型经历了从循环神经网络(recurrent neural network, RNN)到 Transformer 架构的技术演进。最初,以 Hidasi 等^[2]提出的以 GRU4Rec 为代表的 RNN 方法率先实现了对用户交互时序的有效建模。随后,基于自注意力机制的模型,如 Kang 等^[3]提出的 SASRec 和 Sun 等^[4]提出的 BERT4Rec,因其在捕捉序列中长距离依赖关系方面的优越表现而成为研究热点。与此同时,另一类研究思路是将用户会话序列转化

为图结构,利用图神经网络^[5-7](graph neural network, GNN)来挖掘物品间更为复杂的转移关系。然而,自注意力机制在对历史行为进行密集计算时,可能导致关键信号被噪声信息干扰,于是 Yao 等^[8]提出 RETR 模型,通过动态规划稀疏注意力路径来更高效地捕捉关键行为。但无论是基于 RNN、Transformer 还是 GNN,主流推荐方法^[9]均存在显著局限:它们过度依赖单向历史信息传递,未能充分利用未来行为中包含的反向引导信息,从而出现动态偏好建模存在偏差^[10]和信息利用效能不足^[11]的问题。

针对上述技术瓶颈,近期研究开始探索历史与未来信息的融合策略。Zhang 等^[12]提出的 DualRec 通过构建双通道网络来解耦并分别建模这两类信息;而 Xia 等^[13]的 Oracle4Rec 创新性地利用未来行为作为监督信号,以指导历史偏好学习。但深入分析发现,这些方法仍存在明显不足:首先是在信息融合时采用静态权重分配策略,难以适应用户兴趣的突变情况;其次是缺乏对用户长期稳定兴趣的有效

收稿日期:2026-01-20; **修订日期:**2026-03-15

基金项目:国家自然科学基金资助项目(62476078);河北省教育科学规划课题(2303121);河北地质大学博士科研启动基金(BQ2017045)

作者简介:马丽(1977—),女,河北张家口人,河北地质大学副教授,博士,主要从事知识发现与粒计算、机器学习的研究, E-mail: mali_new@163.com。

引用本文:马丽,刘文哲,李雨豪. 基于自适应双向信息流的序列推荐方法[J]. 郑州大学学报(工学版), 2026, 47(4): 100-107. [Ma Li, Liu Wenzhe, Li Yuhao. Sequential recommendation method based on adaptive bidirectional information flow[J]. Journal of Zhengzhou University (Engineering Science), 2026, 47(4): 100-107.]

提炼,历史编码过程容易受到局部噪声影响。

为此,本文提出双向动态信息流推荐 BDFRec (bidirectional dynamic flow for recommendation) 模型,通过自适应双向信息流 (adaptive bidirectional information flow, ABF) 机制突破现有技术限制。采用解耦的双路径编码器架构分别处理历史和未来信息,通过二者独立建模来规避信息泄露风险。其核心创新体现在 3 个方面:设计了一个层次化历史总结模块,用于从长序列中提取抗噪声干扰的长期偏好表征;引入了动态频域滤波机制,通过数据驱动的阈值有效抑制序列噪声;提出自适应双向信息流机制,该机制能够通过不确定性感知动态调节历史与未来信息的融合权重,从而充分利用未来信息对历史建模进行反向校正。通过这种设计,模型能够更精准地刻画用户偏好的演变轨迹,从而提升推荐的准确性与鲁棒性。

1 基于自适应双向信息流的序列推荐建模

1.1 问题定义

给定推荐系统中的用户集合 U 与物品集合 V , 分别包含 m 个用户与 n 个物品。每个用户 u 的交互行为可表征为时序序列 $S_u = \{v_1, v_2, \dots, v_{|S_u|}\}$ 。其中, $\forall v_i \in V$ 。本文旨在基于用户历史行为预测其下一次交互目标 $v_{|S_u|+1}$ 。针对待预测的交互项 v_t , 设定最大序列长度 L 和未来序列长度 FL (其中 $L > FL$), 需构建两类序列:其一为局部上下文的历史序列 $H_u^t = \{v_{t-(L-FL)}, \dots, v_{t-1}\}$, 由紧邻在预测位置之前的 $L-FL$ 个物品构成;其二为扩展上下文的全局序列 $G_u^t = \{v_{t+FL-L}, \dots, v_{t+FL-1}\}$, 由 FL 个未来物品及其

历史上下文共 L 个物品构成。在这两种情况下,若序列的起始位置小于 1,则在左侧进行填充以保证长度。需强调,全局序列 G_u^t 仅在训练阶段可用,预测阶段则仅依赖 H_u^t 以避免信息泄露。

1.2 双路径编码器架构设计

信息泄露风险是序列融合的核心障碍。若将历史序列与未来序列直接拼接输入单一编码器,模型在训练阶段会隐式学习未来信息的分布特征,导致预测阶段产生表征偏移。这种训练-预测不一致性已被证明会使 $NDCG$ 指标下降 12% ~ 18%^[12]。为消除此隐患,必须采用解耦的双路径编码架构。历史编码器专注于从已观测行为中提炼确定性偏好模式;未来编码器则捕捉潜在趋势信号。二者在共享嵌入空间但独立参数化的设计下,既能确保特征可比性,又能避免信息污染。本文的 BDFRec 模型采用双路径编码器架构,分别对用户历史行为与未来潜在偏好进行独立建模,通过两条编码路径捕获时序依赖中的动态特性。每条路径均包含嵌入模块、频域滤波模块和时序注意力模块,并通过自适应双向信息流动态协调历史与未来信号的交互权重。BDFRec 模型结构如图 1 所示。其中,模型的输入为用户的历史交互物品序列,图 1 中不同形状的图标代表了不同物品的向量表征。

1.2.1 共享嵌入层

在 BDFRec 模型中,层次化位置感知嵌入模块负责将离散的物品序列转换为连续的稠密向量表示,同时显式地编码物品的位置信息。

对于用户历史交互序列中的每一个物品,本模型通过可学习的嵌入矩阵 $E_v \in \mathbf{R}^{|V| \times d}$ 将其映射




图 1 BDFRec 模型结构图

Figure 1 BDFRec model architecture diagram

到一个 d 维稠密向量空间^[14]。其中, $|V|$ 表示物品集合的大小; d 为嵌入维度。物品 v_i 的嵌入向量计算如下所示:

$$\mathbf{e}_i = \mathbf{E}_v[v_i], \mathbf{e}_i \in \mathbf{R}^d. \quad (1)$$

为增强时序感知能力,模型引入位置嵌入 $\mathbf{E}_p \in \mathbf{R}^{L \times d}$, 显式地编码物品在序列中的位置信息。对于序列中的第 i 个位置,其位置嵌入为

$$\mathbf{p}_i = \mathbf{E}_p[i], \mathbf{p}_i \in \mathbf{R}^d. \quad (2)$$

最终物品表征通过逐元素相加融合语义与位置信息得到:

$$\hat{\mathbf{e}}_i = \mathbf{e}_i + \mathbf{p}_i. \quad (3)$$

1.2.2 频域滤波模块

用户行为序列天然地包含噪声,例如偶然的误点击或短暂的、非典型的兴趣探索。从信号处理的角度看,这些可以被视作序列信号中的“高频噪声”,会干扰模型对用户核心、稳定兴趣的捕捉。频域滤波通过分离用户行为序列中的长期稳定模式与短期噪声,为时序推荐提供了一种物理可解释的特征增强范式。FMLP-Rec^[7] 模型包括可学习频域滤波器,对序列嵌入 $\mathbf{F}_1 \in \mathbf{R}^{B \times L \times d}$ 进行傅里叶变换后,利用参数矩阵 $\mathbf{W} \in \mathbf{R}^{K \times d}$ 对频域分量进行加权,即

$$\begin{cases} \tilde{\mathbf{X}} = \mathbf{W} \odot \mathbf{F}(\mathbf{F}_1); \\ \tilde{\mathbf{F}}_1 = \mathbf{F}^{-1}(\tilde{\mathbf{X}}). \end{cases} \quad (4)$$

然而,该方法存在两个关键缺陷:可学习滤波器 $\mathbf{W}$ 的参数量随序列长度线性增长,导致长序列场景下优化困难;频率权重缺乏明确的物理意义,可能过度抑制隐含用户短期兴趣的高频分量^[15]。为此,本文提出动态量化滤波机制,通过数据驱动阈值^[16] 替代参数化滤波^[17]。

首先,对输入序列执行傅里叶变换 $\mathbf{X} = \mathbf{F}(\mathbf{F}_1)$ 并计算频率能量谱 $\boldsymbol{\omega} = \mathbf{E}_b[|\mathbf{X}|] \in \mathbf{R}^K$ 。基于预设频域滤波保留比例 ρ , 动态确定分位数阈值 $\xi = Q_\rho(\boldsymbol{\omega})$, 其中 $Q_\rho(\cdot)$ 为分位数函数。对频域信号进行硬阈值滤波:

$$\tilde{\mathbf{x}}_k = \begin{cases} \mathbf{x}_k, & |\mathbf{x}_k| \leq \xi; \\ 0, & \text{其他}. \end{cases} \quad (5)$$

滤波后频域信号经逆变换重构为时域表征 $\tilde{\mathbf{F}}_1 = \mathbf{F}^{-1}(\tilde{\mathbf{X}})$, 并通过残差连接与层归一化稳定训练过程:

$$\mathbf{F}_1^{\text{out}} = \text{LayerNorm}(\tilde{\mathbf{F}}_1 + \mathbf{F}_1). \quad (6)$$

通过频域滤波模块的处理,模型在序列数据中的噪声抑制能力显著提升,从而进一步增强了对用

户行为的建模能力和推荐效果。

1.2.3 多头自注意力

针对用户行为序列中存在的长程依赖与时序动态性建模需求,本模型参照 SASRec^[3] 方法,使用了一种多头自注意力编码机制^[18]。该机制并行地从不同的表示子空间^[19] 中提取信息,从而提升模型的表达能力。

多头自注意力机制的第一步是通过线性变换将输入序列映射到查询、键和值 3 个向量空间:

$$\begin{cases} \mathbf{Q} = \mathbf{X}\mathbf{W}_q; \\ \mathbf{K} = \mathbf{X}\mathbf{W}_k; \\ \mathbf{V} = \mathbf{X}\mathbf{W}_v. \end{cases} \quad (7)$$

式中: $\mathbf{X}$ 为输入张量; $\mathbf{W}_q$ 、 $\mathbf{W}_k$ 和 $\mathbf{W}_v$ 分别为查询、键和值的权重矩阵。查询和键用于计算元素之间的相关性,而值则用于加权求和生成最终的上下文表示,用如下公式来计算注意力得分:

$$\mathbf{S}^{\text{Att}} = \mathbf{Q}\mathbf{K}^T / \sqrt{d_k}. \quad (8)$$

为了防止模型关注无关的信息,在计算注意力得分 $\mathbf{S}^{\text{Att}}$ 后,应用掩码 $\mathbf{M}$ 将无效位置的注意力得分设置为负无穷,然后应用 Softmax 对得分进行归一化,得到注意力权重 $\mathbf{P}$:

$$\mathbf{P} = \text{Softmax}(\mathbf{S}^{\text{Att}} + \mathbf{M}). \quad (9)$$

通过将注意力权重与值向量加权求和,生成每个位置的上下文向量,并将各个头的输出进行拼接,并通过线性变换映射回原始维度:

$$\mathbf{C} = \mathbf{P}\mathbf{V}; \quad (10)$$

$$\mathbf{C}_{\text{final}} = \text{Concat}(\mathbf{C}_1, \mathbf{C}_2, \dots, \mathbf{C}_h) \mathbf{W}_o. \quad (11)$$

拼接后的输出通过全连接层进行线性变换,生成最终的隐藏状态,并通过残差连接与原始输入相加,然后应用 LayerNorm 进行标准化:

$$\mathbf{H}_{\text{final}} = \text{LayerNorm}(\mathbf{H}_{\text{fin}} + \mathbf{X}). \quad (12)$$

式中: $\mathbf{H}_{\text{fin}}$ 为经过全连接层处理后的输出。此步骤帮助避免梯度消失,确保模型的训练效率和稳定性。

1.2.4 历史信息总结模块

标准自注意力编码器虽能捕捉全局依赖,但对长序列的扁平化处理会稀释关键偏好信号。当用户行为超过 50 项时,偶然的近期交互可能掩盖长期稳定兴趣。于是本文认为需要一个专门的模块来对历史表征进行层次化的提炼与总结,该模块采用时序依赖建模-注意力聚合的双阶段架构,实现过程如下。

给定长度为 L 的历史行为序列表征矩阵 $\mathbf{H} \in \mathbf{R}^{L \times d}$, 通过双向 LSTM 网络捕获时序依赖关系:

$$(\overrightarrow{h}_t, \overleftarrow{h}_t) = \text{LSTM}(h_t, h_{t-1}), t = 1, 2, \dots, L. \quad (13)$$

式中: $\vec{h}_t \in \mathbf{R}^d$ 和 $\overleftarrow{h}_t \in \mathbf{R}^d$ 分别为前向和后向隐藏状态。

将双向状态拼接后得到时序增强表征:

$$\mathbf{Z} = [\vec{H}; \overleftarrow{H}] \mathbf{W}_e + \mathbf{b}_e, \quad \mathbf{Z} \in \mathbf{R}^{L \times d}. \quad (14)$$

式中: $\mathbf{W}_e \in \mathbf{R}^{2d \times d}$ 为降维投影矩阵; $\mathbf{b}_e$ 为偏置项。为识别对长期偏好建模具有显著贡献的关键行为,设计基于双层感知器的注意力机制:

$$\mathbf{e}_t = \mathbf{v}^T \tanh(\mathbf{W}_a \mathbf{z}_t + \mathbf{b}_a); \quad (15)$$

$$\alpha_t = \frac{\exp(\mathbf{e}_t)}{\sum_{k=1}^L \exp(\mathbf{e}_k)}. \quad (16)$$

式中: $\mathbf{W}_a \in \mathbf{R}^{d \times d}$ 为参数矩阵; $\mathbf{z}_t \in \mathbf{R}^d$ 为序列中第 t 个时序增强向量; $\mathbf{v} \in \mathbf{R}^d$ 为注意力向量; α_t 为注意力权重。

通过加权聚合获得用户长期偏好摘要:

$$\mathbf{s} = \sum_{t=1}^L \alpha_t \mathbf{c}_t. \quad (17)$$

1.3 自适应双向信息流机制

1.3.1 动态权重分配

在 ABF 机制中,为了有效建模历史信息与未来信号之间的相互作用,首先对历史行为表征 $\mathbf{h}_p \in \mathbf{R}^d$ 和未来交互表征 $\mathbf{h}_f \in \mathbf{R}^d$ 进行特征交互,通过线性交互计算动态门控权重 $\mathbf{g}$,反映未来信息对历史行为的影响程度:

$$\mathbf{g} = \sigma(\mathbf{W}_g(\mathbf{h}_p \odot \mathbf{h}_f) + \mathbf{b}_g). \quad (18)$$

式中: $\odot$ 表示逐元素乘积; $\mathbf{W}_g \in \mathbf{R}^{d \times d}$ 为权重矩阵; $\sigma(\cdot)$ 为 Sigmoid 激活函数。此外,本文引入温度缩放因子 τ 来控制 Softmax 分布的集中度:

$$\alpha = \text{Softmax}(\mathbf{g}/\tau). \quad (19)$$

当 $\tau \rightarrow 0$ 时, α 趋于 one-hot 分布,强调主导特征;当 $\tau \rightarrow +\infty$ 时, α 趋于均匀分布,从而减轻过拟合的风险。ABF 据此动态调整信息融合强度,适配不同信号特性。

1.3.2 不确定性感知修正

考虑到未来信号可能包含噪声^[11],为了应对这一问题,本文借鉴贝叶斯深度学习^[20]中的思想,在训练过程中引入蒙特卡罗 Dropout 扰动^[21]以模拟不确定性。本文通过对未来信号应用 Dropout 操作来获得多次扰动后的表征:

$$\mathbf{h}_f^{\text{mc}} = \mathbf{h}_f \odot \mathbf{m}, \mathbf{m} \sim \text{Bernoulli}(0.9). \quad (20)$$

式中: $\mathbf{m}$ 为服从伯努利分布的随机掩码,使用 Dropout 操作对未来信号进行扰动,从而得到多个样本的输出。本文计算扰动后表征的方差 u 作为未来信号的不确定性估计:

$$u = \text{Var}(\mathbf{h}_f^{\text{mc}}). \quad (21)$$

该不确定性估计 u 可动态调整 α :

$$\alpha' = \alpha(1 - u) + 0.5u. \quad (22)$$

当不确定性估计 u 较高时,权重 α' 会趋向于 0.5,减小未来信号的贡献;而当 u 较低时,历史信号的权重将得到增强。此设计使得模型在处理含噪声数据时,能够根据信号的可靠性自适应调整历史与未来信息的融合比例,提升模型的鲁棒性。

1.3.3 残差特征融合

为了避免投影过程中出现语义失真,ABF 将 $\mathbf{h}_p$ 和 $\mathbf{h}_f$ 分别映射到一个共享的特征空间,通过投影矩阵 $\mathbf{W}_p, \mathbf{W}_f \in \mathbf{R}^{d \times d}$,得到投影后的特征:

$$\begin{cases} \mathbf{h}_p^{\text{proj}} = \mathbf{W}_p \mathbf{h}_p; \\ \mathbf{h}_f^{\text{proj}} = \mathbf{W}_f \mathbf{h}_f. \end{cases} \quad (23)$$

历史和未来信息的加权融合被表达为

$$\mathbf{h}_{\text{fused}} = \text{LayerNorm}(\alpha' \mathbf{h}_p^{\text{proj}} + (1 - \alpha') \mathbf{h}_f^{\text{proj}} + \mathbf{h}_f). \quad (24)$$

这一设计不仅实现了跨时序信息的交互,还通过残差连接保留了原始未来信息,从而避免了信息丢失。残差连接有助于稳定梯度的传播,避免在深层网络中出现梯度消失问题。

1.3.4 双向协同机制与动态训练策略

与传统的单向信息融合方法不同,ABF 通过双向交互^[22]实现信息的迭代修正,在前向传播过程中,历史信息通过门控机制引导历史总结模块对未来信息进行修正;后向传播过程中,修正后的信息再次作为历史输入,优化历史信号。该双向交互过程能够充分考虑历史与未来信号间的相互依赖关系,并形成闭环优化系统。这种双向协同机制可以形式化为以下的迭代过程:

$$\mathbf{h}_{\text{fused}}(t) = F_{\text{ABF}}(\mathbf{h}_p(t-1), \mathbf{h}_f(t)). \quad (25)$$

式中: t 表示时序迭代步。通过多次迭代,ABF 能够逐步消除历史偏差和未来噪声的影响,在长期的优化过程中获得更加精确的推荐结果。

为优化训练过程,本文采用两阶段策略,即在训练初期,仅训练历史信息编码器和历史信息总结模块,通过学习全局交互序列 G_u^i 中的模式,计算损失函数 L_i 并通过梯度下降更新其参数。在下一阶段,解冻未来信息编码器,并通过双向信息流机制联合优化历史信息编码器和未来信息编码器的参数,这部分损失函数为

$$L_{\text{total}} = - \sum_{i \in \mathbf{H}_u^i} \lg P(y_i | \mathbf{H}_p) + \beta \|\mathbf{H}_p - \mathbf{H}_f\|^2. \quad (26)$$

式中: $\mathbf{H}_p$ 为历史编码器的输出; $\mathbf{H}_f$ 为未来编码器的输出; y_i 为真实交互标签; β 为历史建模精度与双向

信息融合强度平衡系数。

2 实验验证

2.1 实验设置

本文在 4 个公开数据集 Beauty^[23]、Sports^[23]、Yelp^[24] 以及 ML1M^[25] 上进行了实验。实验前对所有数据集进行预处理,根据 FMLP-Rec 的做法,过滤掉了不受欢迎的商品和交互记录少于 5 次的非活跃用户。4 个数据集信息如表 1 所示。

表 1 数据集信息			
Table 1 Information of the dataset			
数据集	用户数	项目数	交互数
Beauty ^[23]	22 364	12 102	198 502
Sports ^[23]	35 599	18 358	296 337
Yelp ^[24]	30 499	20 068	317 182
ML1M ^[25]	6 041	3 417	999 611

对于通用的训练参数,本文主要遵循了 FMLP-Rec 模型^[7] 的设置。实验采用 Adam 优化器,其中学习率设置为 0.001,动量参数 β_1 和 β_2 分别为 0.900 和 0.999,批次大小为 256。为防止过拟合,所有模型中的注意力概率丢弃率与隐层丢弃率均设为 0.5。此外,实验统一采用早停策略,当验证集性能在连续 10 个 *epoch* 内未能提升时即终止训练,最大训练轮次设为 300。对于本文模型 BDFRec 特有的 3 个关键超参数,即温度缩放因子 τ 、频域滤波保留比例 ρ 以及未来序列长度 FL ,通过在验证集上进行系统的参数敏感性分析来确定其最优值。具体的分析过程与结果详见 2.2.4 节超参数分析。基于该分析,最终确定 $\tau=0.5$, $\rho=0.7$, $FL=10$ 。

在数据处理阶段,最大序列长度被设定为 50,

即仅保留每个用户最近 50 次的交互行为,该设定同样参考了主流基线方法的实践。所有实验均在统一的软硬件环境下进行,以保证结果的一致性。硬件环境包括: Intel Core i7 处理器、32 GB 内存、1 TB SSD 存储以及 NVIDIA GeForce RTX 4060 GPU。软件环境方面,操作系统为 Windows 10,深度学习框架采用 PyTorch 2.1.0,CUDA 版本为 12.1,Python 版本为 3.9。

2.2 实验结果及分析

2.2.1 不同模型结果对比分析

为了验证本文提出的 BDFRec 模型的有效性,将其与 10 个主流的序列推荐模型进行了对比,这些模型包括经典的基于循环神经网络的 GRU4Rec、基于卷积神经网络的 Caser,以及多种运用自注意力机制和图神经网络的先进模型,如 SASRec、BERT4Rec、SRGNN 等。采用 $HR@k$ 、 $NDCG@k$ 及 MRR 为性能评价指标,表现对比如表 2 所示。由表 2 可知,相比当前最优的 Oracle4Rec 模型,BDFRec 通过自适应双向信息流与历史总结模块的协同设计,进一步提升了推荐精度,如在稀疏的 Beauty 数据集上,BDFRec 的 $NDCG@20$ 达到 0.394 4,较 Oracle4Rec 提升 1.37 百分点,验证其通过历史总结提炼长期偏好的能力。而在包含丰富噪声的 Yelp 数据集上,BDFRec 的 MRR 为 0.458 1,较 FMLP-Rec 提升 2.90 百分点,体现了 BDFRec 具有较好的鲁棒性和噪声处理能力。与 FMLP-Rec、DualRec 及 Oracle4Rec 这 3 个头部基线模型的平均性能进行比较,本方法在 Beauty 和 Yelp 数据集上的 $HR@20$ 指标分别高出 2.08 百分点和 2.89 百分点, $NDCG@20$ 指标则分别高出 2.67 百分点和 2.72 百分点,进一步验证了所提模型在综合性能上的优越性。

表 2 不同模型在不同数据集上的表现对比												
Table 2 Comparison of performance of different models on different datasets												
方法	$HR@20$				$NDCG@20$				MRR			
	Beauty	Sports	Yelp	ML1M	Beauty	Sports	Yelp	ML1M	Beauty	Sports	Yelp	ML1M
Caser ^[1]	0.512 7	0.480 3	0.770 3	0.824 6	0.300 1	0.241 2	0.428 3	0.536 5	0.226 4	0.202 8	0.340 9	0.460 7
GRU4Rec ^[2]	0.553 7	0.530 5	0.839 7	0.841 0	0.328 2	0.288 6	0.474 5	0.547 5	0.263 3	0.239 1	0.377 0	0.468 9
SASRec ^[3]	0.586 2	0.583 0	0.858 0	0.854 5	0.336 5	0.314 3	0.489 0	0.574 3	0.286 5	0.263 2	0.391 5	0.498 2
BERTRec ^[4]	0.555 3	0.552 1	0.840 6	0.838 7	0.328 0	0.296 7	0.494 1	0.558 4	0.263 5	0.249 6	0.401 7	0.485 7
SRGNN ^[5]	0.576 6	0.565 2	0.828 4	0.823 7	0.330 0	0.301 7	0.486 4	0.549 8	0.276 8	0.255 2	0.396 6	0.481 1
GCSAN ^[6]	0.605 8	0.544 9	0.847 9	0.844 5	0.349 8	0.321 8	0.503 5	0.574 0	0.294 0	0.274 3	0.411 3	0.504 2
FMLP-Rec ^[7]	0.622 0	0.630 8	0.871 6	0.856 0	0.357 0	0.335 1	0.526 4	0.575 7	0.309 2	0.282 3	0.429 1	0.502 4
RETR ^[8]	0.620 3	0.625 8	0.874 4	0.845 3	0.357 9	0.335 3	0.523 2	0.571 6	0.306 9	0.276 8	0.436 2	0.498 6
DualRec ^[12]	0.625 4	0.618 9	0.876 9	0.840 0	0.365 5	0.349 6	0.532 6	0.566 4	0.317 8	0.297 7	0.442 1	0.490 1
Oracle4Rec ^[13]	0.646 3	0.654 5	0.904 7	0.875 6	0.380 7	0.364 3	0.552 8	0.588 1	0.319 5	0.299 7	0.451 3	0.512 9
BDFRec	0.652 0	0.671 6	0.913 3	0.888 4	0.394 4	0.380 0	0.564 5	0.601 0	0.328 5	0.304 1	0.458 1	0.516 7

2.2.2 消融实验

为验证模型中各核心组件的必要性,在 Beauty、Sports、ML1M 这 3 个数据集上对比了完整模型 BDFRec 与 3 个变体。其中,BDFRec/A 为移除自适应双向信息流模块;BDFRec/F 为禁用频域滤波机制;BDFRec/H 为移除历史总结模块;BDFRec 为包含全部模块的完整模型。消融实验结果如表 3 所示。

表 3 消融实验结果
Table 3 Ablation experiment results

数据集	模型	HR@ 10	NDCG@ 10	MRR
Beauty ^[23]	BDFRec/A	0.509 7	0.341 9	0.306 1
	BDFRec/F	0.514 9	0.345 9	0.310 1
	BDFRec/H	0.522 3	0.357 0	0.321 9
	BDFRec	0.530 9	0.364 2	0.328 5
Sports ^[23]	BDFRec/A	0.518 1	0.317 8	0.279 6
	BDFRec/F	0.522 7	0.325 0	0.280 4
	BDFRec/H	0.535 7	0.334 8	0.291 7
	BDFRec	0.541 9	0.347 2	0.304 1
Yelp ^[24]	BDFRec/A	0.776 5	0.506 1	0.426 8
	BDFRec/F	0.789 2	0.514 0	0.435 5
	BDFRec/H	0.801 5	0.528 1	0.449 5
	BDFRec	0.808 3	0.537 9	0.458 1
ML1M ^[25]	BDFRec/A	0.794 2	0.559 3	0.492 5
	BDFRec/F	0.801 5	0.563 3	0.500 8
	BDFRec/H	0.808 1	0.574 8	0.511 0
	BDFRec	0.813 4	0.582 0	0.516 7

由表 3 可知,BDFRec 去除任一部分均会导致指标下降,说明自适应双向信息流、频域滤波及历史总结模块均能提升模型效果。BDFRec 在移除双向信息流后,在 3 个数据集上的指标均有明显下降,在 Sports 数据集中 NDCG@ 10 下降了 2.94 百分点。禁用频域滤波会导致模型对噪声敏感,使模型在 Beauty 数据集上的 NDCG@ 10 和 MRR 分别下降了 1.83 百分点和 1.84 百分点。消融实验证实,自适应双向信息流、频域滤波与历史总结模块在模型性能优化方面三者缺一不可。

2.2.3 时序编码器动态交互机制分析

为了验证本文设计的自适应双向信息流机制的先进性,通过多数据集对比实验,探究不同时序编码器交互策略对用户动态偏好建模的影响。本文在 Beauty、Sports、Yelp 以及 ML1M 数据集上对比以下 4 种编码器配置方案:①仅使用历史编码器,不引入未来信息;②仅使用未来编码器,直接利用未来交互序列预测当前兴趣;③使用未来辅助历史,固定未来编码器参数,通过单向信息流修正历史表征;④使用自适应双向信息流,允许历史与未来编码器通过自适应门控双向协同。实验采用 HR@ 5 与 NDCG@ 5 作

为核心指标,结果如图 2 所示。




图 2 不同编码器在不同数据集上的实验结果
Figure 2 Experiment results of different encoders on different datasets

从图 2 可以看出,本文提出的自适应双向信息流机制的 HR@ 5 和 NDCG@ 5 指标在所有 4 个数据集上均优于其他编码器交互策略。与仅使用历史编码器相比,本文方法在 Beauty 数据集上,HR@ 5 和 NDCG@ 5 分别高出 2.03 百分点和 0.84 百分点;在数据更密集的 ML1M 数据集上,也分别高出 1.38 百分点和 1.57 百分点。相较于使用未来辅助历史的方法,本文方法依然表现更优,在 Beauty 数据集上的 HR@ 5 和 NDCG@ 5 分别高出 0.69 百分点和 0.56 百分点,在 ML1M 数据集上则分别高出 0.76 百分点和 0.84 百分点。这表明自适应双向信息流机制在多种编码器交互策略中表现出色,能够有效提升动态偏好的建模能力,进一步验证了该方法在个性化推荐系统中的潜力与优势。

2.2.4 超参数分析

针对 BDFRec 中的关键超参数,包括温度缩放因子 τ 、频域滤波保留比例 ρ 和未来序列长度 FL 进行敏感性分析,探究其对模型性能的影响规律。实验在 Sports 数据集上进行,结果如图 3 所示。温度缩放因子 τ 控制注意力权重分布的平滑性,通过缩放门控权重调节历史与未来信息的融合强度。当 $\tau=0.5$ 时,模型在 4 个评价指标上均达到峰值。此时权重分布既聚焦核心信号,又保留潜在长尾

关联。频域滤波保留比例 ρ 决定滤波后的低频成分比例。当 $\rho = 0.7$ 时,模型过滤掉 30% 的高频噪声并保留 70% 低频语义,此时模型效果达到最优,降低 ρ 会过度滤波,从而丢失有效信号;提高 ρ 则不能够有效抑制高频噪声,从而影响最终效果。

未来序列长度 FL 控制未来编码器的输入窗口大小。过短的未来序列长度会导致未来信号不足,难以修正历史偏差;而过长的未来序列长度则容易引入远期噪声干扰,使模型的性能降低。最终 FL 取值为 10。




图 3 超参数敏感性分析

Figure 3 Hyperparameter sensitivity analysis

3 结论

本文提出一种基于自适应双向信息流的序列推荐模型,通过层次化历史总结模块提取长期偏好表征,结合自适应双向信息流机制动态调节历史与未来信息的融合权重,并引入动态频域滤波抑制噪声,有效解决了序列推荐中动态偏好建模偏差及历史与未来信息融合效率低下的问题。在 4 个公开数据集上的实验表明,本文提出的 BDFRec 方法在多个评价指标上显著优于现有方法,验证了其通过双向信息流与噪声抑制模块提升推荐效果的优越性。消融实验进一步证实了自适应双向信息流、动态量化频域滤波及历史总结模块在模型性能优化中的关键作用。未来将探索自适应双向信息流机制在不同稀疏度数据上的泛化能力,并结合更复杂的用户行为特征,进一步提升模型的推荐性能与鲁棒性。

参考文献:

[1] Tang Jiayi, Wang Ke. Personalized top-N sequential recommendation via convolutional sequence embedding[C]// Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. New York: ACM, 2018: 565-573.

[2] Hidasi B, Karatzoglou A, Baltrunas L, et al. Session-based recommendations with recurrent neural networks [PP/OL]. V4. arXiv (2016-03-29) [2025-12-01]. <https://arxiv.org/abs/1511.06939>.

[3] Kang Wangcheng, McAuley J. Self-attentive sequential recommendation[C]//Proceedings of the 2018 IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE, 2018: 197-206.

[4] Sun Fei, Liu Jun, Wu Jian, et al. BERT4Rec: sequential recommendation with bidirectional encoder representa-

tions from transformer[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: ACM, 2019: 1441-1450.

[5] Wu Shu, Wu Shu, Tang Yuyuan, et al. Session-based recommendation with graph neural networks [C] // Proceedings of the Thirty-Third AAAI Conference on Artificial Intelligence and Thirty-First Innovative Applications of Artificial Intelligence Conference and Ninth AAAI Symposium on Educational Advances in Artificial Intelligence. New York: ACM, 2019: 346-353.

[6] Xu Chengfeng, Zhao Pengpeng, Liu Yanchi, et al. Graph contextualized self-attention network for session-based recommendation [C] // Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. New York: ACM, 2019: 3940-3946.

[7] Zhou Kun, Yu Hui, Zhao W X, et al. Filter-enhanced MLP is all you need for sequential recommendation[C]// Proceedings of the ACM Web Conference 2022. New York: ACM, 2022: 2388-2399.

[8] Yao Zhiyu, Chen Xinyang, Wang Sinan, et al. Recommender transformers with behavior pathways [C] // Proceedings of the ACM Web Conference 2024. New York: ACM, 2024: 3643-3654.

[9] Gao Jingtong, Zhao Xiangyu, Li Muyang, et al. SMLP4Rec: an efficient all-MLP architecture for sequential recommendations[J]. ACM Transactions on Information Systems, 2024, 42(3): 1-23.

[10] Liu Langming, Cai Liu, Zhang Chi, et al. LinRec: linear attention mechanism for long-term sequential recommender systems[C] // Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2023: 289-299.

[11] Yu Junliang, Xia Xin, Chen Tong, et al. XSimGCL: towards extremely simple graph contrastive learning for recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(2): 913-926.

[12] Zhang Hengyu, Yuan Enming, Guo Wei, et al. Disen-

- tangling past-future modeling in sequential recommendation via dual networks[C]//Proceedings of the 31st ACM International Conference on Information & Knowledge Management. New York: ACM, 2022: 2549–2558.
- [13] Xia Jiafeng, Li Dongsheng, Gu Hansu, et al. Oracle-guided dynamic user preference modeling for sequential recommendation[C]//Proceedings of the Eighteenth ACM International Conference on Web Search and Data Mining. New York: ACM, 2025: 363–372.
- [14] Siami-Namini S, Tavakoli N, Namin A S. The performance of LSTM and BiLSTM in forecasting time series[C]//Proceedings of the 2019 IEEE International Conference on Big Data (Big Data). Piscataway: IEEE, 2019: 3285–3292.
- [15] Wang Wenjie, Feng Fuli, He Xiangnan, et al. Denoising implicit feedback for recommendation[C]//Proceedings of the 14th ACM International Conference on Web Search and Data Mining. New York: ACM, 2021: 373–381.
- [16] Bai Jiawang, Yuan Li, Xia Shutao, et al. Improving vision transformers by revisiting high-frequency components [C]//Computer Vision—ECCV 2022. Cham: Springer, 2022: 1–18.
- [17] Mikhail M, Ouali M S, Yacout S. A data-driven methodology with a nonparametric reliability method for optimal condition-based maintenance strategies [J]. Reliability Engineering & System Safety, 2024, 241: 109668.
- [18] Xu Ling, Ding Feng, Zhang Xiao, et al. Novel parameter estimation method for the systems with colored noises by using the filtering identification idea[J]. Systems & Control Letters, 2024, 186: 105774.
- [19] Kang H, Yang M H, Ryu J. Interactive multi-head self-attention with linear complexity [PP/OL]. V1. arXiv (2024-02-27) [2025-12-01]. <https://arxiv.org/abs/2402.17507>.
- [20] Guo Xudong, Guo Xun, Lu Yan. SSAN: separable self-attention network for video representation learning [C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2021: 12613–12622.
- [21] Zhao Rui, Wang Kui, Xiao Yang, et al. Leveraging Monte Carlo dropout for uncertainty quantification in real-time object detection of autonomous vehicles [J]. IEEE Access, 2024, 12: 33384–33399.
- [22] Huang Yuanxin, Zhi Xiyang, Hu Jianming, et al. FDD-BA-NET: frequency domain decoupling bidirectional interactive attention network for infrared small target detection [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5004416.
- [23] McAuley J. Recommender systems and personalization datasets [DS/OL]. [2025-12-01]. <https://jmcauley.ucsd.edu/data/amazon/>.
- [24] Yelp. Yelp open dataset [DS/OL]. [2025-12-01]. <https://business.yelp.com/data/resources/open-dataset/>.
- [25] GroupLens. MovieLens datasets [DS/OL]. [2025-12-01]. <https://grouplens.org/datasets/movielens/>.

Sequential Recommendation Method Based on Adaptive Bidirectional Information Flow

MA Li^{1,2}, LIU Wenzhe¹, LI Yuhao¹

(1. College of Information Engineering, Hebei GEO University, Shijiazhuang 052161, China; 2. Intelligent Sensor Network Engineering Research Center of Hebei Province, Hebei GEO University, Shijiazhuang 052161, China)

Abstract: To address the challenges of inefficient information fusion and noise interference in sequential recommendation, a novel method based on an adaptive bidirectional information flow was proposed. Built upon a dual-path encoder architecture, a hierarchical history summarization module was integrated to distill long-term user preferences, and dynamic frequency-domain filtering was introduced to suppress data noise. The approach fully considered the dependency and interactivity between past and future information by employing an adaptive bidirectional information flow mechanism. This mechanism dynamically adjusted fusion weights via uncertainty perception, enabling a precise characterization of the evolution of user preferences. To validate its effectiveness, experiments were conducted on four public datasets including Beauty, Sports, Yelp, and ML1M. And a comparative analysis was performed against 10 mainstream methods. The experimental results demonstrated that the proposed method outperformed the baseline models in three key metrics: *NDCG*, *HR*, and *MRR*. Compared to three leading baseline models of FMLP-Rec, DualRec, and Oracle4Rec, the proposed method's *HR@20* reached 0.652 0 and 0.913 3 on the Beauty and Yelp datasets, which was 2.08 percentage points and 2.89 percentage points higher than their average performance, respectively. Furthermore, its *NDCG@20* on the Beauty and Yelp datasets reached 0.394 4 and 0.564 5, outperforming the average of the three baselines by 2.67 percentage points and 2.72 percentage points, respectively.

Keywords: sequential recommendation; adaptive bidirectional information flow; dynamic preference modeling; frequency-domain filtering; attention mechanism