

跨使用者協同與序列建模的推薦系統

Cross-user Collaborative and Sequential Modeling for Recommendation

Qiao-Ying He, Yi-En Chen, Kuan-Yu Chen

Department of Computer Science and Information Engineering

National Taiwan University of Science and Technology

qiaoyinghe.cs@gmail.com, yechen.research@gmail.com, kychen@mail.ntust.edu.tw

摘要

多行爲推薦系統透過引入輔助行爲，有效緩解了目標行爲的稀疏性問題。現有方法大致可分爲兩類：序列模型能夠捕捉個體的時序動態，但往往忽略跨用戶的協同資訊；圖模型則能挖掘用戶間的協同模式，卻缺乏對時序依賴的建模。爲此，本文提出整合序列模型與圖模型：前者專注於建模用戶行爲序列的時序依賴，後者則統計並挖掘跨用戶的行爲路徑。最終，通過融合兩者的預測結果，實現更爲精確的推薦效能。在兩個電商資料集 Taobao 和 RetailRocket 上，整合方法相比最強基準 MB-STR，HR@10 和 NDCG@10 均提升約 1%。實驗結果表明，即使在強大的序列模型基礎上，引入跨用戶協同訊息仍能帶來穩定的性能提升。

Abstract

Multi-behavior recommendation leverages auxiliary behaviors to effectively alleviate the sparsity of target behaviors. Existing approaches can be broadly categorized into two paradigms: sequential models that capture individual temporal dynamics but often omit cross-user information, and graph-based models that mine collaborative patterns yet lack temporal dependency modeling. To address these limitations, this paper proposes an integrated approach that combines sequential and graph modeling: the former focuses on learning temporal dependencies within user behavior sequences, while the latter captures cross-user behavior paths. By fusing the predictions from both components, the method achieves more accurate recommendations. Experiments on two e-commerce datasets, Taobao and RetailRocket, show that the integrated model outperforms the strong baseline MB-STR by about 1% in both HR@10 and NDCG@10. These results indicate that incorporating cross-user collaborative information consistently improves

performance, even on top of strong sequential models.

關鍵字：多行爲推薦、序列模型、圖模型、稀疏性

Keywords: Multi-Behavior Recommendation, Sequential Models, Graph-based Models, Sparsity

1 引言

推薦系統在現代電子商務平台中扮演著關鍵角色，透過預測用戶偏好來緩解資訊過載問題。在實際應用中，用戶與項目的互動呈現多行爲特性，包括點擊、收藏、加入購物車和購買等多種行爲類型。這些不同類型的行爲反映了用戶不同層次的興趣和意圖：點擊代表初步興趣，加入購物車顯示購買意願，而購買則是最終的目標行爲。多行爲推薦系統旨在利用這些豐富的輔助行爲來改善對稀疏目標行爲的預測。

近年來，多行爲推薦研究主要沿著兩個方向發展。第一個方向是序列建模方法，如 MB-STR (Yuan et al., 2022)、DMT (Gu et al., 2020) 等，這些方法將用戶的多行爲交互視爲時序序列，利用 RNN 或 Transformer 架構捕捉行爲之間的時序依賴關係。這類方法能夠精確地爲個人行爲的演化過程建模，理解用戶興趣的動態變化。然而，它們僅關注單一用戶的歷史序列，忽略了其他用戶的行爲模式可能提供的有價值資訊。

第二個方向是基於圖結構的方法，包括利用圖神經網路的 MBGCN (Jin et al., 2020)、MB-GMN (Xia et al., 2021)，以及基於模式挖掘的 BPMR (Li et al., 2024)。這些方法將用戶-項目交互建模爲圖結構，通過分析圖中的連接模式來進行推薦。特別是 BPMR，它通過統計用戶-項目二部圖中的多條路徑（如「用戶 A 瀏覽項目 X → 用戶 B 也瀏覽項目 X → 用戶 B 購買項目 Y」）來發現跨用戶的行爲模式。這類方法有效利用了群體智慧，但在處理

時序資訊和個人化建模方面存在不足。

這兩種範式各有優勢但也存在明顯的互補性。序列方法擅長建模個人化行為模式，通過捕捉用戶歷史交互的時序演化來理解個體偏好的動態變化；而跨用戶方法擅長挖掘協同訊息，通過分析群體行為模式來發現集體智慧和用戶間的相似性。一個理想的推薦系統應該能夠同時考慮這兩個維度：既要精確建模個人行為的時序動態，又能有效利用跨用戶的協同模式。

有鑑於此，本文提出一個整合框架，將個人序列建模與跨用戶模式挖掘結合。我們的主要貢獻包括：

- 整合框架：設計了一個簡潔的融合機制，通過 MLP 處理 MB-STR 序列表徵與 BPMR 跨用戶統計的串接結果，實現兩種訊息源的整合。
- 實驗驗證：在兩個真實資料集上進行實驗，驗證了即使採用簡單的融合策略，整合方法仍能帶來穩定的性能提升，為多行為推薦中不同訊息源的結合提供實證支持。

2 相關研究

2.1 序列推薦

序列推薦系統從用戶的歷史交互序列中學習時序模式以預測下一個項目。早期研究使用馬可夫鏈方法建模項目間的轉換關係 (Rendle et al., 2010)。隨著深度學習的發展，循環神經網路首先被應用於序列建模，如 GRU4Rec (Hidasi et al., 2015) 利用 GRU 網路處理點擊序列，展現了深度學習在捕捉複雜序列依賴上的潛力。卷積神經網路也被用於序列推薦，Caser (Tang and Wang, 2018) 將序列嵌入視為圖像，通過卷積操作提取局部序列模式。Transformer 架構的引入為序列推薦帶來突破性進展。SASRec (Kang and McAuley, 2018) 採用單向自注意力機制，有效捕捉項目間的長程依賴關係。BERT4Rec (Sun et al., 2019) 進一步引入雙向注意力和掩碼語言模型，通過預訓練提升序列表徵質量。TiSASRec (Li et al., 2020) 考慮時間間隔訊息，增強了時序建模能力。這些基於注意力的方法相比 RNN 具有更好的並行性和長程依賴建模能力。在多行為場景下，序列建模面臨新的挑戰。DMT (Gu et al., 2020) 使用多任務學習框架同時建模多種行為序列，但採用固定的行為模式。DIPN (Guo et al., 2019) 通過層級注意力網路建模行為間關係，但仍在行為層級聚合。MB-STR (Yuan et al., 2022) 提出多行為 Transformer

層，通過行為特定的注意力機制和位置編碼捕捉異質行為序列的細粒度依賴。然而，這些方法都侷限於單一用戶的歷史序列，未能利用跨用戶的協同訊息。

2.2 基於圖的多行為推薦

基於圖的多行為推薦將用戶-項目交互建模為異質圖結構，利用圖學習技術進行推薦。早期方法通過矩陣分解處理多行為數據，如 CMF (Singh and Gordon, 2008) 同時分解多個行為矩陣並共享嵌入。隨著圖神經網路的發展，研究者開始利用 GNN 的強大表徵學習能力處理多行為圖結構。圖神經網路方法通過消息傳遞機制聚合鄰居資訊。MBGCN (Jin et al., 2020) 在統一的用戶-項目圖上進行圖卷積，並通過行為特定的圖學習行為語義。GHCF (Chen et al., 2021) 設計層級圖卷積網路，分別建模每種行為的貢獻度。MB-GMN (Xia et al., 2021) 採用元學習網路自適應地學習不同行為的權重。MGNN (Zhang et al., 2020) 利用多層網路結構同時學習共享和行為特定的嵌入。最近的 MBCGCN (Cheng et al., 2023) 通過級聯圖卷積顯式建模行為間的依賴關係。除了神經網路方法，統計模式挖掘提供了另一種視角。BPMR (Li et al., 2024) 不同於 GNN 的隱式表徵學習，通過統計用戶-項目二部圖中的多跳路徑（如 $\text{view} \rightarrow \text{view} \rightarrow \text{purchase}$ ）來挖掘跨用戶的行為模式。這種方法提供了可解釋的統計特徵，能夠直接量化不同行為模式對推薦的影響。相比 GNN 需要多層傳播可能導致的過平滑問題，BPMR 通過顯式的路徑計數保留了細粒度的行為轉換訊息。儘管圖方法有效利用了跨用戶資訊，但在處理時序動態方面存在不足。現有工作要麼完全忽略時間訊息，要麼僅將其作為額外特徵，未能充分建模用戶興趣的時序演化。本文旨在結合序列建模與圖結構方法的優勢，同時捕捉個人時序動態和跨用戶協同模式。

3 預備知識

3.1 問題定義

在這一節中，我們將對多行為推薦問題進行形式化定義。

首先，我們考慮一個存在多種交互行為的推薦場景。該場景包含一個用戶集合 $\mathcal{U} = \{u_1, u_2, \dots, u_{|\mathcal{U}|}\}$ 和一個項目集合 $\mathcal{I} = \{i_1, i_2, \dots, i_{|\mathcal{I}|}\}$ 。用戶與項目之間存在多種類型的交互行為，我們將這些行為類型定義為一個集合 $\mathcal{B} = \{b_1, b_2, \dots, b_{|\mathcal{B}|}\}$ 。其中， $b_{|\mathcal{B}|}$ 表示我們的目標行為（例如購買），而其餘的 $b_1, \dots, b_{|\mathcal{B}|-1}$ 則為輔助行為（例如瀏覽、收藏、

加入購物車等)。

基於上述設定，每個用戶的歷史行為可以被記錄為一個時間有序的序列。

定義 3.1 (多行為交互序列). 對於任一用戶 $u \in \mathcal{U}$ ，其多行為交互序列定義為 $S_u = [(i_1^u, b_1^u), (i_2^u, b_2^u), \dots, (i_{|S_u|}^u, b_{|S_u|}^u)]$ 。序列中的每一個元組 (i_j^u, b_j^u) 表示用戶 u 在某個時間點對項目 $i_j^u \in \mathcal{I}$ 執行了行為 $b_j^u \in \mathcal{B}$ 。整個序列 S_u 嚴格按照交互發生的時間戳升序排列。為了在模型中進行批次處理，我們將所有用戶的序列處理為固定長度 n 。若序列的原始長度超過 n ，則保留最近的 n 次交互；若長度不足 n ，則在序列的開頭填充特殊的 $[PAD]$ 標記。

除了用戶自身的行為序列，用戶與項目之間的協同關係也蘊含了豐富的訊息。我們可以將所有交互行為建模為一個用戶-項目圖，並從中提取高階的關聯模式。

定義 3.2 (跨用戶行為模式). 給定一個由所有交互 (u, i, b) 構成的用戶-項目圖 $G = (\mathcal{U} \cup \mathcal{I}, E)$ ，一個長度為 l 的行為模式路徑可以表示為 $p = n_1 \xrightarrow{b_1} n_2 \xrightarrow{b_2} \dots \xrightarrow{b_l} n_{l+1}$ ，其中節點 $n_i \in \mathcal{U} \cup \mathcal{I}$ 。該路徑揭示了節點之間通過一系列特定行為 $R = b_1 \circ b_2 \circ \dots \circ b_l$ 所形成的關聯模式。

本文的目標是進行多行為推薦。具體而言，給定用戶 u 的定長多行為交互序列 S_u 以及一組從圖中提取的跨用戶行為模式 P ，我們的任務是預測用戶 u 在下一個時間步(即 $n+1$)對任意候選項目 $i \in \mathcal{I}$ 執行目標行為 $b_{|\mathcal{B}|}$ 的概率，記為 $P(i, b_{|\mathcal{B}|} | S_u, P)$ 。

4 模型架構

本節詳述我們的模型架構，該架構整合序列建模與跨用戶模式挖掘兩種互補方法。整體框架包含三個主要部分：序列行為建模模組、跨用戶模式提取模組，以及一個融合預測的模組。

4.1 序列行為建模

在本研究中，我們採用 MB-STR (Yuan et al., 2022) 模型來進行序列行為建模。MB-STR 包含多行為 Transformer 層 (MB-Trans)、多行為序列模式生成器 (MB-SPG) 和行為感知預測模組 (BA-Pred)。

給定用戶 u 的多行為序列 $S_u = [(i_1^u, b_1^u), \dots, (i_n^u, b_n^u)]$ ，我們首先僅使用項目 ID 序列來構建 Transformer 的初始輸入表徵 $\mathbf{H}^{(0)}$ ：

$$\mathbf{H}^{(0)} = \mathbf{E}_{item}(i_1^u, \dots, i_n^u)$$

其中 \mathbf{E}_{item} 為項目嵌入矩陣。對應的行為序列 $\mathcal{B}_u = (b_1^u, \dots, b_n^u)$ 將作為獨立的輸入，傳遞給後續的 Transformer 層，用於實現行為感知的計算。

接著，MB-STR 採用行為感知的多頭自注意力。對於查詢位置 i 和鍵位置 j ，其對應的行為分別為 b_i 和 b_j 。注意力分數的計算結合了內容資訊和行為模式偏置：

$$A_{i,j} = \frac{(Q_i W_{b_i, b_j} K_j^T)}{\sqrt{d}} + P_{b_i, b_j}(j - i)$$

其中 W_{b_i, b_j} 是根據行為對 (b_i, b_j) 選擇的特定變換矩陣。 $P_{b_i, b_j}(j - i)$ 是由 MB-SPG 模組根據行為序列 \mathcal{B}_u 和相對位置 $(j - i)$ 動態生成的偏置項。

每層的輸出會通過一個行為特定的多層感知器 (BS-MLP)，該模組為每種行為類型都維護一組獨立的參數。整體採用 L 層堆疊結構，最終得到精煉後的序列表徵 $\mathbf{H}^{(L)} \in \mathbb{R}^{n \times d}$ 。

4.2 跨用戶的協同資訊

另一方面，我們採用 BPMR (Li et al., 2024)，通過統計用戶-項目交互圖中的行為路徑來捕捉跨用戶的協同資訊。

首先，我們考慮長度 $l \in \{1, 3\}$ 的行為模式路徑。長度為 1 的路徑表示直接的用戶-項目交互 (如 $u \xrightarrow{\text{buy}} i$)，長度為 3 的路徑則捕捉跨用戶的協同模式 (如 $u \xrightarrow{\text{view}} i' \xleftarrow{\text{view}} u' \xrightarrow{\text{buy}} i$)。BPMR 同時統計這兩種長度的路徑數量，用於計算貝葉斯評分。

接著，我們對預定義的模式集合 T 中的每種模式 $R \in T$ 進行統計，並計算其對數貝葉斯分數。我們將用戶 u 與項目 i 之間的模式總分簡記為 $s_{u,i}^{\text{patt}}$ ：

$$s_{u,i}^{\text{patt}} = \sum_{R \in T} N_R^{u,i} \cdot \log \left[\frac{P(R|y=1)}{P(R|y=0)} \right]$$

其中 $y=1$ 表示用戶-項目對存在目標行為 (購買)， $y=0$ 表示不存在目標行為。 $P(R|y=1)$ 和 $P(R|y=0)$ 分別代表在有購買和無購買的情況下，觀察到模式 R 的條件概率。路徑計數 $N_R^{u,i}$ 表示用戶 u 和項目 i 之間存在多少條類型為 R 的路徑。對於長度為 3 的路徑，計數通過交互矩陣乘積 $[\mathbf{E}^{b_1} \cdot (\mathbf{E}^{b_2})^T \cdot \mathbf{E}^{b_3}]_{u,i}$ 獲得，其中 \mathbf{E}^b 是行為 b 的用戶-項目交互矩陣。

4.3 融合預測

本模組在預測分數 (Logits) 層級整合來自序列模組和模式模組的訊號。對於給定的用戶 u 和候選項目 i ，兩個模組分別產生預測分數：

- 序列行爲模型 $\hat{y}_{u,i}^{\text{seq}}$ ：由序列行爲建模的最終表徵 $\mathbf{H}^{(L)}$ 經過行爲感知預測模組 (BA-Pred) 計算得出。
- 跨用戶協同資訊模型 $s_{u,i}^{\text{patt}}$ ：將預先計算的模式總分取對數。

我們將 $\hat{y}_{u,i}^{\text{seq}}$ 和 $s_{u,i}^{\text{patt}}$ 拼接成一個二維向量，並將其輸入到一個前饋神經網路 (Feed-Forward Neural Network, FFNN) 中，以非線性的方式學習兩者間的關係，並產生最終的預測分數：

$$\hat{y}_{u,i}^{\text{final}} = \text{FFNN} \left(\text{Concat} \left(\hat{y}_{u,i}^{\text{seq}}, s_{u,i}^{\text{patt}} \right) \right)$$

4.4 模型訓練

對於序列模型 MB-STR，我們使用遮蔽語言模型 (Mask Language Model, MLM) 為訓練目標，也就是通過最小化負對數概率損失來優化序列模型參數 θ_{seq} ：

$$\mathcal{L}(\theta_{\text{seq}}) = - \sum_{u \in \mathcal{U}} \sum_{k=1}^n m_{u,k} \log p_{\theta_{\text{seq}}}(i_k | S_u^{\text{m}})$$

其中 $m_{u,k}$ 是遮罩標記，當位置 k 被遮蔽時為 1，否則為 0。 S_u^{m} 表示遮蔽後的序列。

在 MB-STR 訓練完成後，我們再針對融合預測模組的 FFNN 參數進行訓練，此時 BPMR 分數也已預先計算完成，因此訓練目標為最小化融合後的預測損失：

$$\mathcal{L}(\theta_{\text{FFN}}) = - \sum_{u \in \mathcal{U}} \sum_{k=1}^n m_{u,k} \log p_{\theta_{\text{FFN}}}(i_k | S_u^{\text{m}}, P_u)$$

其中 P_u 包含預計算的 BPMR 模式分數， θ_{FFN} 代表 FFNN 層的模型參數。

5 實驗

5.1 實驗設定

5.1.1 資料集

我們在兩個真實世界的電子商務資料集上進行實驗：

- **Taobao**¹：數據來自中國最大電商平台淘寶，時間跨度為 2017 年 11 月 25 日至 12 月 3 日。包含瀏覽 (view)、加入購物車 (cart) 和購買 (buy) 三種行爲類型。
- **RetailRocket**²：數據來自俄羅斯電商平台的公開資料集，收集於約 4 個月期間。包含瀏覽 (view)、加入購物車 (cart) 和購買 (buy) 三種行爲類型。

¹<https://tianchi.aliyun.com/dataset/649>

²<https://www.kaggle.com/retailrocket/ecommerce-dataset>

資料集的詳細統計訊息如表 1 所示。兩個資料集都以購買 (buy) 作為目標行爲，其餘為輔助行爲。

5.1.2 評估協議與參數設置

採用 leave-one-out 策略，將每個用戶的最後一個目標行爲作為測試集，倒數第二個作為驗證集，其餘作為訓練集。

我們使用兩個廣泛應用於推薦系統的評估指標：

- **Hit Ratio@K (HR@K)**：衡量前 K 個推薦項目中是否包含真實項目的比例。HR@K 反映了推薦系統的召回能力，計算公式為：

$$\text{HR}@K = \frac{1}{|\mathcal{U}|} \sum_{u \in \mathcal{U}} \mathbb{I}(\text{rank}_u \leq K)$$

其中 $\mathbb{I}(\cdot)$ 是指示函數， rank_u 是真實項目在推薦列表中的排名。

- **Normalized Discounted Cumulative Gain@K (NDCG@K)**：考慮排名位置的評估指標，對排名靠前的正確推薦給予更高權重：

$$\text{NDCG}@K = \frac{1}{|\mathcal{U}|} \sum_{u \in \mathcal{U}} \frac{\mathbb{I}(\text{rank}_u \leq K)}{\log_2(\text{rank}_u + 1)}$$

我們的模型是基於 PyTorch 進行實現，參數設置如下：序列長度 $n = 50$ ，嵌入維度 $d = 16$ ，MB-STR 層數 $L = 2$ ，注意力頭數 $h = 2$ 。學習率設為 0.001，批次大小為 128，dropout 率為 0.2。BPMR 考慮長度為 1 和 3 的行爲路徑。使用 Adam 優化器進行最佳化。

5.1.3 Baselines

我們與以下三類基準方法進行比較：

1. 單行爲序列模型 (Single-behavior Sequential Models)：

- GRU4Rec (Hidasi et al., 2015)：基於 GRU 的序列推薦。
- SASRec (Kang and McAuley, 2018)：基於自註意力的序列推薦。
- BERT4Rec (Sun et al., 2019)：基於雙向 Transformer 的序列推薦。

2. 基於圖的方法 (Graph-based Methods)：

- LightGCN (He et al., 2020)：輕量級圖卷積網路。

Datasets	#User	#Item	#Interactions	Interaction Behavior	Type
Taobao	48,749	39,493	1,952,931	{View, Cart, Buy}	
RetailRocket	147,894	99,037	2,756,101	{View, Cart, Buy}	

表 1: 資料集統計訊息。

Algorithm	Taobao		RetailRocket	
	HR@10	NDCG@10	HR@10	NDCG@10
單行爲序列模型 (Single-behavior Sequential Models)				
GRU4Rec	0.368	0.215	0.355	0.228
SASRec	0.390	0.249	0.178	0.108
BERT4Rec	0.254	0.171	0.350	0.229
基於圖的方法 (Graph-based Methods)				
LightGCN	0.039	0.021	0.041	0.024
MBGCN	0.309	0.143	0.369	0.222
MB-GMN	0.319	0.154	0.491	0.300
BPMR	0.403	0.223	0.363	0.201
多行爲序列模型 (Multi-behavior Sequential Models)				
MBHT	0.745	0.559	0.361	0.239
MB-STR	<u>0.775</u>	<u>0.635</u>	<u>0.777</u>	<u>0.653</u>
Ours	0.790*	0.689*	0.792*	0.702*
<i>Improv.</i>	1.02%	1.08%	1.02%	1.07%

表 2: 不同方法在兩個資料集上的性能比較

- MBGCN (Jin et al., 2020)：多行爲圖卷積網路。
- MB-GMN (Xia et al., 2021)：基於圖元網路的多行爲推薦。
- BPMR (Li et al., 2024)：基於行爲模式挖掘的推薦（我們的基礎模型之一）。

3. 多行爲序列模型 (Multi-behavior Sequential Models) :

- MBHT (Yang et al., 2022)：多行爲超圖 Transformer。
- MB-STR (Yuan et al., 2022)：多行爲序列 Transformer（我們的基礎模型之一）。

5.2 整體性能比較

表2展示了所有方法在兩個資料集上的實驗結果。從結果可以觀察到我們提出的整合方法在兩個資料集上均取得最佳性能。在 Taobao 資料集上，HR@10 達到 0.790，NDCG@10 達到 0.689，相比最強基準 MB-STR 分別提升 1.02% 和 1.08%。在 RetailRocket 資料集

上，HR@10 和 NDCG@10 分別達到 0.792 和 0.702，提升幅度為 1.02% 和 1.07%。

單行爲序列模型 (GRU4Rec、SASRec、BERT4Rec) 表現中等，未能充分利用多行爲訊息。基於圖的方法中，LightGCN 因僅考慮單一行爲而表現較差，而多行爲圖方法 (MBGCN、MB-GMN) 雖有所改善但仍不及序列方法。多行爲序列模型展現明顯優勢，特別是 MB-STR 和 MBHT，證實了同時考慮多行爲和序列訊息的重要性。

在所有基礎模型中，MB-STR 表現最佳，在 Taobao 上 HR@10 達 0.775，在 RetailRocket 上達 0.777。這驗證了序列建模在捕捉用戶動態偏好上的有效性。我們的方法通過引入 BPMR 的跨用戶模式，因此相較於 MB-STR，我們可以有更進一步的提升。

6 結論

本研究探討了多行爲推薦中個人序列建模與跨用戶協同模式的整合問題。我們提出了一個簡單的融合框架，結合 MB-STR 的序列建模能力與 BPMR 的跨用戶模式挖掘。實驗結果顯示，在 Taobao 和 RetailRocket 兩個電商資

料集上，整合方法相比最強基準 MB-STR 在 HR@10 和 NDCC@10 上均取得約 1% 的穩定提升。證明了跨用戶協同訊息對序列模型的補充價值。值得注意的是，即使 MB-STR 已經是表現優異的強基準，引入 BPMR 的統計模式仍能帶來改善，這驗證了我們的核心假設：個人時序動態與群體行為模式是互補的訊息源。

未來，我們將在這份研究的基礎上，持續朝向結合序列資訊與跨用戶協同資訊，提出更完善的模型方法，並以端到端（End-to-end）的方式進行訓練，讓模型不僅在訓練上更有效率，也能夠更進一步地提升推薦系統的任務成效。

7 Acknowledgment

This work was supported by the National Science and Technology Council (NSTC) of Taiwan under Grants NSTC 112-2636-E-011-002, NSTC 112-2628-E-011-008-MY3, and NSTC 113-2640-B-002-005. Additional support was provided by the "Empower Vocational Education Research Center" at the National Taiwan University of Science and Technology (NTUST) through the Featured Areas Research Center Program, as part of the Higher Education Sprout Project funded by the Ministry of Education (MOE), Taiwan. The authors also thank the National Center for High-Performance Computing, National Applied Research Laboratories (NARLabs), Taiwan, for providing essential computational and storage resources.

References

Chong Chen, Weizhi Ma, Min Zhang, Zhaowei Wang, Xiuqiang He, Chenyang Wang, Yiqun Liu, and Shaoping Ma. 2021. *Graph heterogeneous multi-relational recommendation*. In *Proceedings of the AAAI conference on artificial intelligence*, volume 35, pages 3958–3966.

Zhiyong Cheng, Sai Han, Fan Liu, Lei Zhu, Zan Gao, and Yuxin Peng. 2023. *Multi-behavior recommendation with cascading graph convolution networks*. In *Proceedings of the ACM Web Conference 2023*, pages 1181–1189.

Yulong Gu, Zhuoye Ding, Shuaiqiang Wang, Lixin Zou, Yiding Liu, and Dawei Yin. 2020. *Deep multifaceted transformers for multi-objective ranking in large-scale e-commerce recommender systems*. In *Proceedings of the 29th ACM international conference on information & knowledge management*, pages 2493–2500.

Long Guo, Lifeng Hua, Rongfei Jia, Binqiang Zhao, Xiaobo Wang, and Bin Cui. 2019. *Buying or browsing?: Predicting real-time purchasing intent using attention-based deep network with multiple behavior*. In *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*, pages 1984–1992.

Xiangnan He, Kuan Deng, Xiang Wang, Yan Li, Yongdong Zhang, and Meng Wang. 2020. *Lightgcn: Simplifying and powering graph convolution network for recommendation*. In *Proceedings of the 43rd International ACM SIGIR conference on research and development in Information Retrieval*, pages 639–648.

Balázs Hidasi, Alexandros Karatzoglou, Linas Baltrunas, and Domonkos Tikk. 2015. *Session-based recommendations with recurrent neural networks*. *arXiv preprint arXiv:1511.06939*.

Bowen Jin, Chen Gao, Xiangnan He, Depeng Jin, and Yong Li. 2020. *Multi-behavior recommendation with graph convolutional networks*. In *Proceedings of the 43rd international ACM SIGIR conference on research and development in information retrieval*, pages 659–668.

Wang-Cheng Kang and Julian McAuley. 2018. *Self-attentive sequential recommendation*. In *2018 IEEE international conference on data mining (ICDM)*, pages 197–206. IEEE.

Haojie Li, Zhiyong Cheng, Xu Yu, Jinhuan Liu, Guanfeng Liu, and Junwei Du. 2024. *Behavior pattern mining-based multi-behavior recommendation*. In *Proceedings of the 47th international ACM SIGIR conference on research and development in information retrieval*, pages 2291–2295.

Jiacheng Li, Yujie Wang, and Julian McAuley. 2020. *Time interval aware self-attention for sequential recommendation*. In *Proceedings of the 13th international conference on web search and data mining*, pages 322–330.

Steffen Rendle, Christoph Freudenthaler, and Lars Schmidt-Thieme. 2010. *Factorizing personalized markov chains for next-basket recommendation*. In *Proceedings of the 19th international conference on World wide web*, pages 811–820.

Ajit P Singh and Geoffrey J Gordon. 2008. *Relational learning via collective matrix factorization*. In *Proceedings of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 650–658.

Fei Sun, Jun Liu, Jian Wu, Changhua Pei, Xiao Lin, Wenwu Ou, and Peng Jiang. 2019. *Bert4rec: Sequential recommendation with bidirectional encoder representations from transformer*. In *Proceedings of the 28th ACM international conference on information and knowledge management*, pages 1441–1450.

Jiaxi Tang and Ke Wang. 2018. Personalized top-n sequential recommendation via convolutional sequence embedding. In *Proceedings of the eleventh ACM international conference on web search and data mining*, pages 565–573.

Lianghao Xia, Yong Xu, Chao Huang, Peng Dai, and Liefeng Bo. 2021. Graph meta network for multi-behavior recommendation. In *Proceedings of the 44th international ACM SIGIR conference on research and development in information retrieval*, pages 757–766.

Yuhao Yang, Chao Huang, Lianghao Xia, Yuxuan Liang, Yanwei Yu, and Chenliang Li. 2022. Multi-behavior hypergraph-enhanced transformer for sequential recommendation. In *Proceedings of the 28th ACM SIGKDD conference on knowledge discovery and data mining*, pages 2263–2274.

Enming Yuan, Wei Guo, Zhicheng He, Huifeng Guo, Chengkai Liu, and Ruiming Tang. 2022. Multi-behavior sequential transformer recommender. In *Proceedings of the 45th international ACM SIGIR conference on research and development in information retrieval*, pages 1642–1652.

Weifeng Zhang, Jingwen Mao, Yi Cao, and Congfu Xu. 2020. Multiplex graph neural networks for multi-behavior recommendation. In *Proceedings of the 29th ACM international conference on information & knowledge management*, pages 2313–2316.