

Deep Sequential Real Estate Recommendation Approach for Solving Item Cold Start
Problem



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering in Computer Engineering

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2020

Copyright of Chulalongkorn University

แนวทางการแนะนำสั่งหาริมทรัพย์ตามลำดับเชิงลึกเพื่อแก้ปัญหาโคลด์สตาร์ทของสินค้า



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมคอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2563
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Thesis Title	Deep Sequential Real Estate Recommendation Approach for Solving Item Cold Start Problem
By	Mr. Jirut Polohakul
Field of Study	Computer Engineering
Thesis Advisor	Associate Professor Dr. PROADPRAN PUNYABUKKANA
Thesis Co Advisor	Dr. EKAPOL CHUANGSUWANICH

Accepted by the FACULTY OF ENGINEERING, Chulalongkorn University in
Partial Fulfillment of the Requirement for the Master of Engineering

..... Dean of the FACULTY OF
ENGINEERING
(Professor Dr. SUPOT TEACHAVORASINSKUN)

THESIS COMMITTEE

..... Chairman
(Associate Professor Dr. CHOTIRAT RATANAMAHATANA)

..... Thesis Advisor
(Associate Professor Dr. PROADPRAN PUNYABUKKANA)

..... Thesis Co-Advisor
(Dr. EKAPOL CHUANGSUWANICH)

..... Examiner
(Associate Professor Dr. ATIWONG SUCHATO)

..... External Examiner
(Dr. Pipop Thienprapasith)

จิรัฏฐ์ โพธิ์โลหะกุล : แนวทางการแนะนำอสังหาริมทรัพย์ตามลำดับเชิงลึกเพื่อแก้ปัญหา
 โคลด์สตาร์ทของสินค้า. (Deep Sequential Real Estate Recommendation
 Approach for Solving Item Cold Start Problem) อ.ที่ปรึกษาหลัก : รศ. ดร.โปรด
 ปราณ บุญยพุกกณะ, อ.ที่ปรึกษาร่วม : อ. ดร.เอกพล ช่วงสุนิช

ปัญหาโคลด์สตาร์ทมักเกิดขึ้นเมื่อระบบแนะนำไม่สามารถแนะนำรายการใหม่เมื่อขาดข้อมูลหรือเมื่อ
 ไม่ได้พิจารณาข้อมูลของรายการใหม่ ๆ สำหรับการค้นหาอสังหาริมทรัพย์นั้น ผู้ใช้สามารถสนใจทั้งที่อยู่อาศัยใหม่
 และเก่าในเวลาพร้อม ๆ กัน ดังนั้นจึงต้องมีระบบแนะนำที่สามารถแนะนำทั้งรายการเก่าและรายการใหม่ไป
 ด้วยกัน นอกจากนี้การที่ผู้ใช้งานไม่จำเป็นต้องเป็นสมาชิกและพฤติกรรมการใช้งานแบบไม่สม่ำเสมอทำให้การ
 แนะนำอสังหาริมทรัพย์มีผู้ใช้ที่มีข้อมูลการใช้งานน้อยและผู้ใช้ใหม่เป็นจำนวนมาก ลักษณะดังกล่าวจึงสอดคล้อง
 กับการใช้แนวทางการแนะนำที่อิงตามเนื้อหาและระบบแนะนำแบบเซสชัน ในงานวิจัยนี้จึงเสนอแนวทางการ
 แนะนำอสังหาริมทรัพย์สำหรับการแก้ปัญหาโคลด์สตาร์ทของสินค้าที่มีประสิทธิภาพของการแนะนำรายการเก่าที่
 สามารถยอมรับได้สำหรับสถานการณ์ที่มีผู้ใช้ที่มีข้อมูลการใช้งานน้อยและผู้ใช้ใหม่เป็นจำนวนมาก เราได้แปลง
 ระบบแนะนำแบบเซสชันและใช้กลไกที่มีอยู่เพื่อจัดการกับข้อมูลลำดับและข้อมูลบริบทอย่างมีประสิทธิภาพ
 สำหรับการคาดการณ์คุณลักษณะที่ถูกเข้ารหัสของอสังหาริมทรัพย์ถัดไปที่ใช้จะสนใจ จากนั้นจึงหาที่อยู่
 อาศัยที่สอดคล้องกับคุณลักษณะดังกล่าวโดยใช้วิธีเพื่อนบ้านที่ใกล้ที่สุดร่วมกับความคล้ายคลึงกันของโคไซน์แบบ
 ถ่วงน้ำหนัก เราประเมินประสิทธิภาพของการแนะนำรายการเก่าและการแนะนำรายการใหม่ทั้งระหว่างการใช้
 กลไกที่แตกต่างกันในแนวทางที่นำเสนอและเปรียบเทียบแนวทางที่นำเสนอกับวิธีบรรทัดฐานต่าง ๆ โดยใช้
 Recall @ K และ Mean Reciprocal Rank @ K (MRR @ K) คู่กับการวัดผลแบบการแนะนำรายการยอดนิยม
 ผลลัพธ์ของการประเมินแสดงให้เห็นถึงประสิทธิภาพของการนำเข้าสู่ข้อมูลลำดับและข้อมูลบริบทอย่างมี
 ประสิทธิภาพและความท้าทายในการแนะนำทั้งรายการเก่าและใหม่ได้ดีในเวลาเดียวกัน แนวทางที่นำเสนอ
 สามารถแนะนำได้เป็นอันดับ 4 และ 2 ในแง่ของการวัดผลด้วย Recall @ 20 เมื่อแนะนำรายการเก่าและ
 รายการใหม่ตามลำดับ ผลลัพธ์นี้แสดงให้เห็นถึงความสามารถในการแก้ปัญหาการโคลด์สตาร์ทของสินค้าแม้ว่าจะ
 ไม่ใช่ผลลัพธ์ที่ดีที่สุดทั้งในการแนะนำรายการเก่าและใหม่ก็ตาม ในท้ายที่สุดนี้แนวทางที่นำเสนอเป็นการแนะนำที่
 เหมาะสมระหว่างการแนะนำรายการเก่าและใหม่และแนวทางนี้จะเป็ประโยชน์ต่องานที่ต้องการแนะนำรายการ
 เก่าและใหม่ในเวลาเดียวกัน

สาขาวิชา วิศวกรรมคอมพิวเตอร์

ปีการศึกษา 2563

ลายมือชื่อนิสิต

ลายมือชื่อ อ.ที่ปรึกษาหลัก

ลายมือชื่อ อ.ที่ปรึกษาร่วม

6170124421 : MAJOR COMPUTER ENGINEERING

KEYWORD: Context awareness, Machine learning, Recommender systems, Recurrent neural networks

Jirut Polohakul : Deep Sequential Real Estate Recommendation Approach for Solving Item Cold Start Problem. Advisor: Assoc. Prof. Dr. PROADPRAN PUNYABUKKANA Co-advisor: Dr. EKAPOL CHUANGSUWANICH

The item cold-start problem occurs when a recommendation system cannot recommend new items owing to record deficiencies and new listing omissions. When searching for real estate, users can register a concurrent interest in recent and prior projects. Thus, an approach to recommend cold-start and warm-start items simultaneously must be determined. Furthermore, unrequired membership and stop-by behavior cause real estate recommendations to have many cold-start and new users. This characteristic encourages the use of a content-based approach and a session-based recommendation system. Herein, we propose a real estate recommendation approach for solving the item cold-start problem with acceptable warm-start item recommendations in the many-cold-start-users scenario. We modify a session-based recommendation system and employ existing mechanisms to efficiently deal with sequential and context information for the next-interacted item's encoded attribute prediction. Subsequently, we use the nearest-neighbors approach using weighted cosine similarity to determine conforming candidates. We use Recall@K and MRR@K with the top-n recommendation to evaluate warm-start and cold-start item recommendations among different applied mechanisms and against the baselines. The results demonstrate the effectiveness of efficiently integrating the information and the difficulty in performing well in warm-start and cold-start item recommendations simultaneously. Our proposed approach illustrates the capability of solving the item cold-start problem while yielding promising results in both recommendations although neither result is the best. We believe that our approach provides a suitable compromise between both recommendations and that it will benefit recommendation tasks focusing on both recommendations.

Field of Study: Computer Engineering

Student's Signature

Academic Year: 2020

Advisor's Signature

Co-advisor's Signature

ACKNOWLEDGEMENTS

I would like to express my deep gratitude to my advisor, Assoc. Prof. Proadpran Punyabukkana, and co-advisor, Dr. Ekapol Chuangsuwanich, for their guidance and feedback throughout this thesis. I also would like to thank Home Dot Tech Co., LTD. for providing and allowing the use of the dataset. I also appreciate all the support and encouragement I received from my friends and family.

Jirut Polohakul



TABLE OF CONTENTS

	Page
.....	iii
ABSTRACT (THAI).....	iii
.....	iv
ABSTRACT (ENGLISH).....	iv
ACKNOWLEDGEMENTS.....	v
TABLE OF CONTENTS.....	vi
LIST OF TABLES.....	viii
LIST OF FIGURES.....	ix
1. Introduction.....	1
2. Related Work.....	4
3. Background.....	8
3.1. Content-based Recommendation System.....	8
3.2. Recurrent Recommendation System without User Identifiers.....	9
3.3. Attention Mechanism in the Recurrent Recommendation System.....	10
3.4. Application of Context Information in Recurrent Recommendation System.....	12
4. Proposed Method.....	13
4.1. Profile Learner.....	13
4.2. Filtering Component.....	15
5. Experimental Setup.....	17
5.1. Dataset and Data Preparation.....	17
5.2. Evaluation Setup.....	21


5.3. Implementation Details.....	22
6. Experimental Result and Discussion	23
6.1. Comparison among Different Mechanisms.....	23
6.2. Comparison against Selected Baselines.....	24
7. Further Study.....	29
Appendix A: Recommendation Examples	30
A.1 Top-1 Recommendation Examples.....	30
A.2 Top-5 Recommendation Examples.....	31
A.3 Top-10 Recommendation Examples.....	32
A.4 Top-15 Recommendation Examples.....	34
A.5 Top-20 Recommendation Examples.....	35
A.6 Missed Recommendation Examples	36
REFERENCES	38
VITA.....	43

LIST OF TABLES

	Page
Table 1. Description, type, and post-processed information of the encoded attributes within the item profiles.	18
Table 2. Statistics of training and testing set.	19
Table 3. Description and participation of context features in pre-fusion and post-fusion 20	20
Table 4. Comparison between the performances of the proposed approach among different applied mechanisms with 728,066 warm-item test cases.	23
Table 5. Comparison between the performances of the proposed approach among different applied mechanisms with 56,013 cold-item test cases.	24
Table 6. Comparison between the performances of the proposed approach and selected baselines with 728,066 warm-item test cases.	26
Table 7. Comparison between the performances of the proposed approach and selected baselines with 56,013 cold-item test cases.	27
Table 8. Examples of the proposed approach's top-1 recommendation 31	31
Table 9. Examples of the proposed approach's top-5 recommendation 32	32
Table 10. Examples of the proposed approach's top-10 recommendation 33	33
Table 11. Examples of the proposed approach's top-15 recommendation 35	35
Table 12. Examples of the proposed approach's top-20 recommendation 36	36
Table 13. Examples of the proposed approach's missed recommendation 37	37

LIST OF FIGURES

	Page
Figure 1. Structure of the session-based recommendation system.	9
Figure 2. An example of splitting the click sequence into training sequences.	10
Figure 3. Structure of YouTube’s recurrent recommendation system when applying the latent cross technique.	12
Figure 4. The structure of the proposed profile learner	14
Figure 5. The structure of the proposed filtering component.....	16



1. Introduction

Among the crucial challenges in e-commerce is maintaining the existing users while attracting new ones. While the abundance of information and choices can be a deterrent, a common approach is to provide recommendations to users to reduce their time and effort searching for information, with the hope of increasing satisfaction. An example of this situation is when users search for real estate on the Internet. Generally, a recommendation system uses historical records as prior knowledge to choose candidates and performs most effectively with adequate records. However, the recommendation task becomes complex for new items, which inevitably leads to the item cold-start problem.

The item cold-start problem occurs when a recommendation system cannot recommend new items due to record deficiencies and new listing omissions. Cold-start items are new items with few or no interactions [1], whereas the rest of the items are warm-start items. As new items are added continuously in practical applications, this problem can cause missed opportunities for recommendations, particularly in real estate recommendations wherein users can register a concurrent interest in recent and prior projects. For instance, users who concern about a location can be interested in many real estate projects at a particular place regardless of the property age. Specific attributes of real estate, such as location, developer brand, and living space, can influence user behavior when searching and buying properties [2-5]. Thus, a recommendation approach using these attributes to recommend cold-start and warm-start items simultaneously must be determined.

Item attributes have been used in previous studies to mitigate the item cold-start problem. Deep learning techniques can be used to learn item attributes and predict the representation of cold-start items for the corresponding factorization machine [1]. Meta-learning can also be applied [6, 7]. However, these approaches utilize the factorization machine, which interprets the engagement or rating prediction to the

recommendation task. This requires user identifiers and sufficient records for efficiency; both types of data are insufficient in the case of real estate recommendation. In such situations, unrequired membership and stop-by behavior cause the system to have many newcomers and a large number of users with few records. In other words, it has many cold-start users and much more new users. We believe that this characteristic is also observed in other real estate search engines and e-commerce systems with unrequired membership, which encourages the use of a content-based approach and a session-based recommendation system. Unlike the factorization machine, a content-based approach [8] can instantly solve the item cold-start problem corresponding to any number of records by relying on item attributes. A session-based recommendation system [9] can use sequential behavior without relying on user identifiers. Therefore, we follow a content-based approach to solve the item cold-start problem. Furthermore, we use a session-based recommendation system for efficient learning of the user profile.

Context information is useful for recommendation tasks [10]. We believe that this information is also significant for real estate recommendation because user interests can vary according to the context. For example, users searching from urban areas may be more interested in condominiums than users searching from rural areas. Thus, we apply context information to our approach to achieve better real estate recommendations.

Herein, we propose a real estate recommendation approach for solving the item cold-start problem with acceptable warm-start item recommendations in the many-cold-start-users scenario. We modify a session-based recommendation system and employ existing mechanisms to efficiently deal with sequential and context information for the next-interacted item's encoded attribute prediction. Subsequently, we use the nearest-neighbors approach using weighted cosine similarity to determine conforming candidates. Thereafter, we compare our proposed approach not only among different applied mechanisms but also against baselines using the top-n recommendation with the dataset from the real estate search engine.

We evaluate recommendation systems with respect to two aspects: warm-start and cold-start item recommendations. This proposed approach, which addresses the item cold-start problem, will be beneficial for any recommendation system belonging to similar domains.



2. Related Work

For real estate recommendations, Yuan et al. [11] employed a user-oriented recommendation system using ensemble techniques from case-based reasoning and ontological structures. Their system required user criteria and preferences as the knowledge from which the relevant items were found; however, this information was unavailable in our dataset. Furthermore, Yu et al. [12] proved that location is a significant feature via the addition of geographical proximity to the weighted-regularized factorization machine [13] using a method ensuring that real estate with geographical proximity has similar latent factors. However, their experiment used a dataset involving real estate from only one city. In this study, we use real estate information from a whole country. This is justified by the fact that users might be interested in various real estates from several distant locations. Badriyah et al. [14] proposed a property recommendation system based on content-based filtering and association rules. Their approach created user and item profiles from the collection of words in advertisements and performed term frequency-inverse document frequency (TF-IDF). Thereafter, it generated association rules using the user profiles as item sets via the apriori algorithm and recommended property products based on these rules. Knoll et al. [15] conducted an experiment on extracted real estate website data for comparing a deep learning approach with the factorization machine. They adapted neural collaborative filtering (NCF) [16] to consider item features together with user and item identifiers. Their results demonstrated that deep learning outperforms the factorization machine in both overall and cold-start results. Nevertheless, these methods omit sequential and context information and suffer from the item cold-start problem.

A deep learning approach has been applied to recommendation tasks for capturing sequential patterns [17]. It benefits from a nonlinear transformation, representation learning, and sequence modeling. Hidasi et al. [9] proposed the session-based recommendation system with the top-n recommendation task. It is a recurrent recommendation system without user identifiers using a recurrent neural

network (RNN) with a gated recurrent unit (GRU) [18]. They designed a model capable of capturing sequential patterns from a click sequence within the session and predicting the next click. They also applied the long short-term memory (LSTM) [19]; however, this yielded discouraging results compared to the GRU. In their consequent work [20], they added another RNN to their recommendation system to incorporate item features into the model and thus proved the features' utility. Li et al. [21] applied the attention mechanism to session-based recommendation systems, thereby capturing the primary purpose of the session. Moreover, their model simultaneously captured global and local attentions, i.e., the final hidden state of RNN and the sum of weighted hidden states at every time step. Likewise, Liu et al. [22] used a multilayer perceptron (MLP) instead of an RNN. They employed the sum of weighted item representations as the global attention and the last item representation as the local attention. Their work demonstrated that MLP achieves computational efficiency and enhanced recommendations, particularly when considering a long sequence. Moreover, they proved that the last click in the user's session is the dominant control on the next click. Beutel et al. [23] found that concatenating context features with the input is an inefficient means to incorporate them. A greater number of dimensions of concatenated input leads to requiring more units from the hidden layer to increase the efficiency of the model. Hence, they proposed a technique, latent cross (LC), performing element-wise products between embedded context features and the hidden states. Context information was incorporated both before and after being consecutively fed to the GRU as pre-fusion and post-fusion, respectively. Although these works showed a capability of dealing with context information, item features, and sequential patterns, they suffered from the item cold-start problem.

To solve the item cold-start problem, Wei et al. [1] proposed a hybrid recommendation model combining a time-aware model, timeSVD++ [24], with a deep learning architecture and a stacked denoising autoencoder (SDAE) [25] for movie rating prediction. They used the descriptions of the cold-start item to predict its latent factor through the SDAE. Consequently, they found the top-n nearest

warm-start items using Pearson's correlation coefficient and used the mean of their predicted ratings as the prediction. Vartak et al. [7] introduced a meta-learning perspective for solving the item cold-start problem in the recommendation system using a cold-start item representation together with user representation from a learned history to predict the engagement between the cold-start item and the user. Furthermore, they proposed a linear and nonlinear classifier with weight and bias adaptations, respectively. These two classifiers were separately used for each user with different weights or biases depending on specific histories. Pan et al. [6] used meta-embedding to assess the item cold-start problem in click-through rate prediction to make the model better at dealing with the cold-start and faster at warming-up. When a new item was detected, they used its features to learn the representation using a meta-embedding generator designed to update the weight with future interactions until it became warm. These works demonstrated that using item attributes enables solving the item cold-start problem. However, sequential information was omitted and the proposed systems were reliant on the factorization machines, which are considered improper for real estate recommendations.

Content-based recommendation systems [8] are another means of solving the item cold-start problem, and benefit from using only the attributes that can work with any number of records. Setiadi et al. [26] recommended scientific articles through content-based filtering using two matching algorithms, i.e., k-means clustering and cosine similarity. They used TF-IDF to represent both user and item profiles, and elucidated the advantage of using k-means clustering over cosine similarity to obtain relevant items. Luostarinen and Kohonen [27] used a form of topic modeling, latent dirichlet allocation (LDA) [28], to represent and recommend news through the naive Bayes classifier, nearest-neighbor regression, and linear regression with cosine similarity. Deldjoo et al. [29] integrated audio and visual descriptors to the hybrid recommendation system for solving the movie cold-start problem. They used metadata and extracted features to help recommend cold-start movies. The aforementioned works illustrated the advantages of content-based

filtering for solving the item cold-start problem; however, they omitted sequential and context information, and their corresponding items do not include real estate.

Herein, we solve the item cold-start problem while using sequential and context information through a content-based approach by modifying a session-based recommendation system to be a profile learner. We also apply an attention mechanism and LC to efficiently deal with sequential and context information, respectively.



3. Background

In this section, we provide knowledge for implementing our proposed approach. The proposed approach leverages a content-based recommendation system, a recurrent recommendation system without user identifiers, an attention mechanism in the recurrent recommendation system, and application of context information in the recurrent recommendation system.

3.1. Content-based Recommendation System

Content refers to the attributes of an item; this can take the form of different data types, such as metadata and text description. The content-based recommendation system comprises a profile learner and a filtering component when working with structured item representations [8]. The profile learner predicts the user profile from interacted item attributes in a similar representation to the item profile, after which the filtering component determines the relevant items using the matching algorithm. As it relies only on item attributes, it can constantly recommend cold-start items. Herein, we follow this approach to solve the item cold-start problem. We use the nearest-neighbors approach with weighted cosine similarity as a filtering component. We select weighted cosine similarity as the similarity function owing to its efficiency and flexibility with our user and item profiles, which are high-dimensional vectors. Weighted cosine similarity is defined as follows:

$$\textit{similarity} = \frac{\sum_i w_i u_i v_i}{\sqrt{\sum_i w_i u_i^2} \sqrt{\sum_i w_i v_i^2}} \quad (1)$$

where u_i and v_i are components of vector u and v respectively, and w_i is the weight corresponding to both components.

3.2. Recurrent Recommendation System without User Identifiers

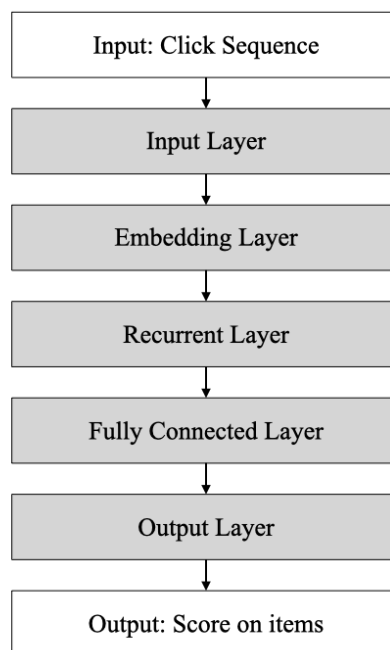


Figure 1. Structure of the session-based recommendation system.

Without a user identifier, the task of recommendation is underappreciated owing to the sparsity of training data [17]. This sparsity leads the recommendation system to learn from sequential interactions without using user identifiers. Many previous works [9, 21, 22, 30] relied only on the sequence of interactions in each session. Such a system is known as a session-based recommendation system and uses RNN as a core layer of the model owing to its capability for capturing sequential patterns. The system operates by receiving the click sequence of the session, $[e_1, e_2, \dots, e_{n-1}, e_n]$ and predicting the next click e_{n+1} where e_i is the i^{th} event of the session. This task is either a multiclass or binary classification treating each item as one class. The output of the system lists the scores for each item, after which the system recommends only the top-n highest-scored items to the user. The structure of the session-based recommendation system proposed in [9], as shown in Fig. 1 is used herein. Our profile learner utilizes this structure to predict the user profile from the sequential patterns.

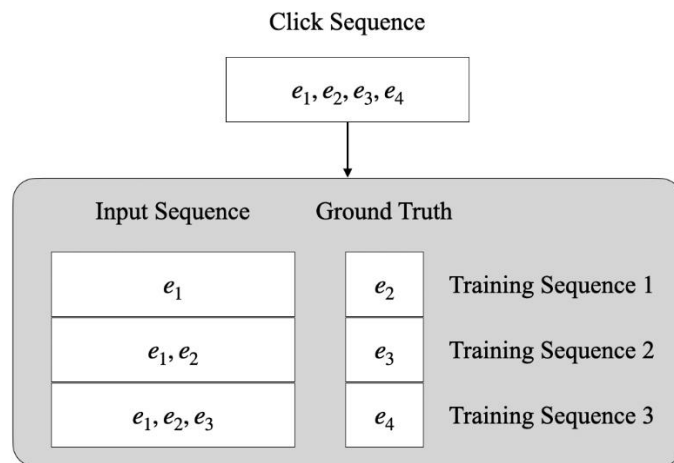


Figure 2. An example of splitting the click sequence into training sequences.

The process splitting the click sequence into training sequences working with the corresponding structure is proposed in [30]. Each training sequence contains the input sequences and ground truths. We obtain the input sequences using every possible prefix within the training sequence with the subsequent clicks as ground truths (Fig. 2). This enables us to generate an adequate number of training sequences for deep learning.

3.3. Attention Mechanism in the Recurrent Recommendation System

A click sequence used in a recurrent recommendation system is implicit feedback. It is an indirect feedback implied from the user behavior and requires careful consideration due to its characteristics of being very noisy and providing no negative feedback [31]. It is impossible to determine whether the users like or dislike the item on which they clicked, nor whether a click is a missclick. Our profile learner uses the attention mechanism to deal with noise and capture the purpose of the sequence, giving precedence to each click differently. Herein, we follow the encoder portion of the neural attentive recommendation machine (NARM) [21].

NARM is an encoder-decoder session-based recommendation system with an attention mechanism. Its encoder portion incorporates two encoders, the global

encoder and the local encoder. The former represents the entirety of user behavior in the click sequence, i.e., the last hidden state of the RNN as follows:

$$c_g = h_t \quad (2)$$

where c_g is the output of the global encoder and h_t is the last hidden state of RNN. The local encoder represents the main purpose of the click sequence, defined as the sum of weighted hidden states from every time step as follows:

$$c_l = \sum_{j=1}^n \alpha_j h_j \quad (3)$$

where c_l is the output of the local encoder, h_j is the hidden state of RNN at time step j and α_j is the weighted factor, which is defined as:

$$\alpha_j = \frac{e^{\text{score}(h_t, h_j)}}{\sum_{j=1}^n e^{\text{score}(h_t, h_j)}} \quad (4)$$

$$\text{score}(h_t, h_j) = A_3 \sigma(A_1 h_t + A_2 h_j) \quad (5)$$

where σ is an activation function, A_3 is a weighting vector, and A_1 and A_2 are the learned weights of h_t and h_j , respectively. As a result, both outputs from the global and local encoders are concatenated and used in the computation of the subsequent layers.

3.4. Application of Context Information in Recurrent Recommendation System

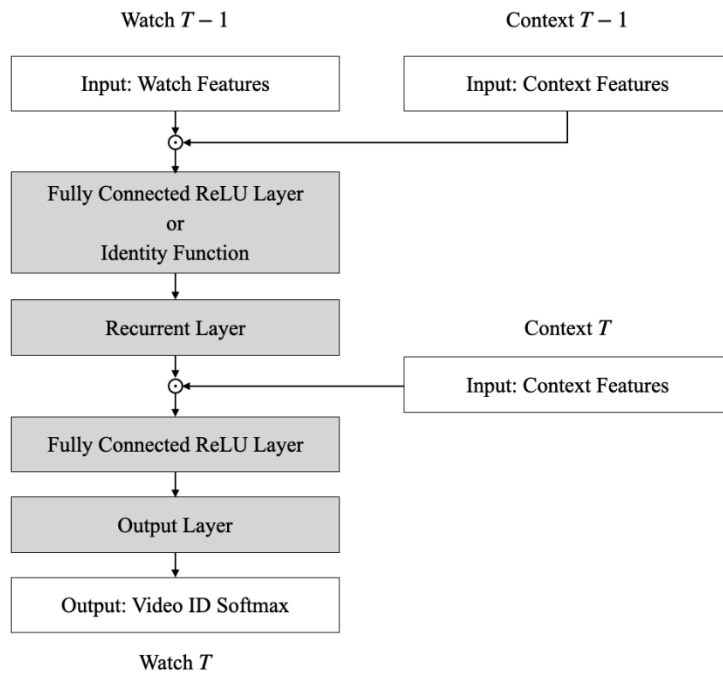


Figure 3. Structure of YouTube's recurrent recommendation system when applying the latent cross technique.

Context information, such as the time and location of the requested service, is useful when applied to the recommendation task [10]. Our profile learner uses the LC technique [23] to efficiently incorporate context features, thereby overcoming difficulties inherent in increasing the dimension of inputs that entail more hidden units in the model. It works by determining the element-wise product of all embedded context features in hidden states as follows:

$$h_j = (1 + \sum w_i) * h_j \quad (6)$$

where h_j is the hidden state of RNN at time step j and w_i is the embedded context feature. The embedding layer of each context feature is initialized by a 0-mean Gaussian distribution to ensure that the multiplicative term has a mean of 1. This initialization causes the multiplicative term to act like an attention mechanism in the hidden state. The element-wise product is performed both before and after passing through the RNN as shown in Fig. 3. These multiplications are considered as prefusion and postfusion, consecutively.

4. Proposed Method

Our method follows the content-based approach having a profile learner and a filtering component to solve the item cold-start problem. Our profile learner is a modified session-based recommendation system with an attention mechanism to predict user profiles using sequential and context information. The filtering component uses the nearest-neighbors approach to determine the most relevant items. The following sections describe the implementation of these two parts.

4.1. Profile Learner

The profile learner predicts a user profile composed of the encoded attributes of the next-interacted item. It utilizes the click sequence and context information. Let $[e_1, e_2, \dots, e_{n-1}, e_n]$ denote a click sequence wherein e_i is the i^{th} event of the sequence and $[c_1, c_2, \dots, c_n, c_{n+1}]$ are context features where c_i corresponds to e_i . The profile learner predicts $[f_1, f_2, \dots, f_{m-1}, f_m]$ where f_i is the i^{th} encoded feature of e_{n+1} determined from the click sequence and context features. The encoded feature is either one-hot or binary encoding depending on the possible number of classes. Each f_i prediction is either a multiclass or binary classification depending on ground truth encoding. For example, real estate projects have the number of bedrooms as a feature. This is reflected by one possible class among three: one, two, or three bedrooms. Therefore, predicting this feature is a multiclass classification problem. Another feature is the unit type; real estate projects can have multiple unit types simultaneously, i.e., both a detached house and a semi-detached house in the same project. The prediction of each class is a binary classification problem. Furthermore, it is a multilabel classification problem when grouping such predictions as a feature prediction. Particularly, we predict the possibilities of all classes for each feature of the next-interacted item and use them as a user profile.




Figure 4. The structure of the proposed profile learner

We leveraged the structure of the session-based recommendation system to modify its task to the objectives of this study. Furthermore, we used the attention mechanism of the encoder portion of NARM and adopted the LC in our profile learner to efficiently deal with sequential and context information, consecutively. Thus, this efficiency should provide better user profile prediction results and both warm-start and cold-start item recommendations. Our profile learner received an embedded item identifier, numerical features, embedded categorical features, and the embedded context features of a click sequence as inputs and then predicted the user profile, as shown in Fig. 4. We used GRU as a core layer because it uses sequential information without suffering a vanishing gradient problem and has advantageous features over LSTM. We performed pre-fusion and post-fusion of the LC before and after passing through the GRU layer to efficiently incorporate context information into the model. In the attention layer, we used global and local encoders similar to the encoder portion of NARM but using post-fusion products

instead of the original hidden states. This replacement includes the effect of context information when calculating the attention score. The output of the attention layer is a concatenated vector from the local and the global encoders, which is used by the fully connected layers to calculate the scores of the classes of all features. Each fully connected layer is responsible for only one encoded feature prediction; thus, its number of units is equal to the number of corresponding classes. Its activation function is either the softmax or sigmoid function for multiclass and binary classification, respectively. As a result, all predicted encoded features are representative of the user profile.

4.2. Filtering Component

The filtering component is responsible for determining the candidates conforming to the predicted user profile through the matching algorithm. Herein, we used the nearest-neighbors approach to gather top-n related items by calculating the scores of all items using weighted cosine similarity, which considers the numerical values of every possibility in the user profile. Moreover, it is suitable for high-dimensional vectors, which are similar to both our user and item profiles. The representation of the item and user profiles must be the same to compute the similarity score. Thus, we use the concatenated vector of all encoded features.

Regarding these profiles, multiclass and multilabel encoded features have different influences on the similarity score calculation owing to the different sum of values within the vector. The former vector is guaranteed to have a sum of 1 whereas the latter's sum can be any value between 0 and the number of classes. To deal with this, we selected weighted cosine similarity over cosine similarity because it is flexible to assign different weights to each component. We reduced only the influence of multilabel feature component using one divided by its number of classes as a weight. In other words, we defined our w_i for (1) as follows:

$$w_i = \begin{cases} 1/n, & \text{if } u_i \text{ and } v_i \text{ are components of multilabel feature} \\ 1, & \text{otherwise} \end{cases} \quad (7)$$

where n is the number of classes of the corresponding multilabel feature.

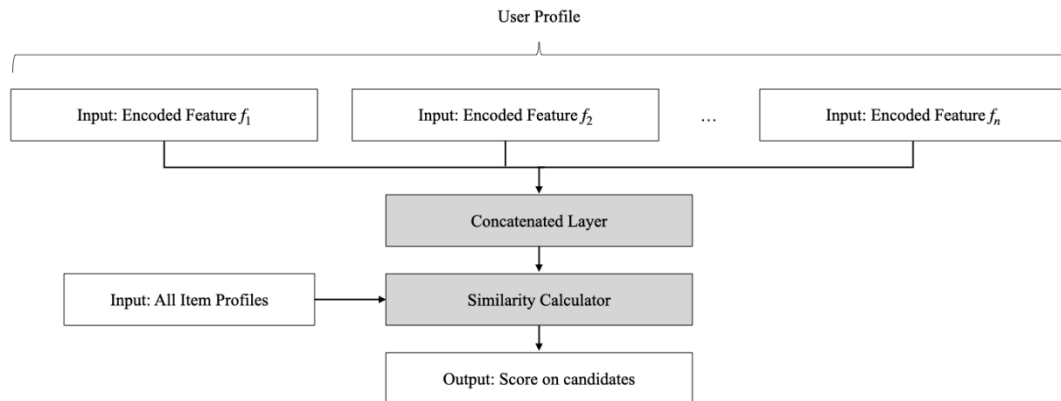


Figure 5. The structure of the proposed filtering component.

The structure of our filtering component is shown in Fig. 5. It was used to calculate the similarity score between all item profiles and the predicted user profile using (1) and (7) together as the similarity function. However, because it is possible to have an equal score, this approach uses the overall number of interactions as the secondary score to break the equality. Particularly, we used popularity to order items with equal similarity scores. Our method thus recommends the top-n items with the highest similarity score to the user.

5. Experimental Setup

In this section, we detail our dataset and data preparation. We also explain how the experiment was conducted and evaluated to compare the performance of our approach not only among different applied mechanisms but also against selected baselines.

5.1. Dataset and Data Preparation

The dataset used herein comprised one year of website records captured in 2018 obtained from www.home.co.th, a popular real estate search engine website based in Thailand, which included 13,425,274 interactions between 3,005,019 users and 6,849 items. It contains 6,917 items with metadata that were used as candidates; these metadata were consequently processed as the item profile for each corresponding item. Meanwhile, each interaction has its context features.

Feature Name	Type	Encoded Type	#Classes	Description
developer_id	categorical	one-hot	2,596	Unique developer ID
province_id	categorical	one-hot	60	Unique province ID
district_id	categorical	one-hot	222	Unique district ID
area_id	categorical	one-hot	36	Unique area ID
subarea_id	categorical	one-hot	285	Unique subarea ID
price_level_id	categorical	one-hot	10	Price level of the project
total_unit	continuous numerical	one-hot	5	Number of total units
functional_space	continuous numerical	one-hot	5	Total size of functional space in sq.m.
n_bedroom	discrete numerical	one-hot	5	Number of bedrooms
n_bathroom	discrete numerical	one-hot	5	Number of bathrooms

Feature Name	Type	Encoded Type	#Classes	Description
n_parking_lot	discrete numerical	one-hot	3	Number of parking lots
created_year	categorical	one-hot	12	Year the project was added to the database
project_status	categorical	binary	1	Status of the project
unit_types	categorical	binary	6	Types of unit within the project
facilities	categorical	binary	6	Facilities within the project

Table 1. Description, type, and post-processed information of the encoded attributes within the item profiles.

First, we prepared the item profile from its metadata to provide the ground truth of the user profile prediction and the participant in the similarity score calculation. These metadata comprised 38 features, some of which have missing and unique values. We removed features with too many unique values because they were difficult to interpret. Likewise, we erased features that have missing values of more than half. Subsequently, we performed data imputation to fill the remaining missing values based on other feature values: the unit type, developer, location, and price level. Thereafter, we differently assigned all values into classes depending on their corresponding feature characteristic. We used each unique value as a class when it was categorical. Likewise, we assigned a value to classes with an upper bound for discrete numerical features. Values greater than or equal to this upper bound were categorized equally. For example, the number of bedrooms is a discrete numerical feature with five classes: one, two, three, four, and five or more bedrooms. This approach entailed the limitation of the number of classes by grouping several sample classes. Continuous numerical features were normalized by taking the logarithm into account and categorizing it according to the percentile. After performing classifications, we encoded the assigned class using either one-hot or binary encoding. We used these processes for cases of one possible class and many

possible classes, respectively. As a result, we generated item profiles composed of 15 encoded features for 6,917 items, the information relating to which is shown in Table 1.

	#Users	#Items	#Interactions	#Sequences
training set	665,501	6,105	3,089,086	2,423,585
testing set	221,837 (192,109 new users)	6,213 (250 new items)	1,005,916	784,079

Table 2. Statistics of training and testing set.

Second, we processed the interaction records for training and testing the model. We maintained only interactions with items having an item profile because our approach relied on their attributes. These interactions were grouped and sorted by user identifiers and timestamps to provide click sequences. However, many continuously repeated-item interactions occurred owing to consequent clicks on the same item. For example, users pressed the project detail button, then the map button, and then the contact button. This led to a sequence of three interactions with the same item. We mitigated this problem by grouping such consequent clicks into one click and using the number of clicks as a new context feature. From the aforementioned example, we retained only one interaction with these three clicks as context information in the sequence. After accounting for this repetition, some users still showed far greater usage than others. These were categorized as bots by plotting the distribution of the number of interactions, using the last two percentiles, and eliminating their records. Afterward, we split the sequences into a training set and a testing set. The first nine-month interactions within provided the training set, whereas the rest formed the testing set. We also removed sequences with one click, since they were unlearnable for the sequential model. Subsequently, we separated the remaining materials into training and testing sequences using the same method as shown in Fig. 2, obtaining input sequences and ground truths for both the training and the testing sets. However, two sets of ground truths are required. The first comprised the next-clicks of the input sequences whereas the second one included their encoded features. To obtain the second set, we replaced the next clicks in the

first set with their item profile. These ground truths were used for the top-n recommendation evaluation and training the profile learner, respectively. Finally, 2,423,585 sequences remained in the training set and 784,079 sequences in the testing set. The statistics of these sets are shown in Table 2. They show that new items and users were added to the testing set during the past three months. Although the number of new items is not high, the item cold-start problem does exist. Moreover, the number of new users and interactions emphasize the characteristic of having many cold-start users.

Feature name	Description	Prefusion	Postfusion
n_click	Number of consecutive clicks with the same item	✓	-
requested_device	Type of the used device (Desktop and Mobile)	✓	✓
requested_province	Province ID where user uses the service	✓	✓
requested_country	Country ID where user uses the service	✓	✓
user_agent	Operation system of used the used device (i.e. Android, Windows, etc.)	✓	✓
page_referrer	Previous page before the current browsing	✓	✓
delta_time	Time between current click and last click in hour	✓	✓

Table 3. Description and participation of context features in prefusion and postfusion

Finally, we prepared two sets of sequences of context features for the training and testing sets. These included context features for the prefusion and postfusion of the LC. Seven context features were used: n_click, requested device, requested province, requested country, user agent, page reference, and delta time. The prefusion considered all such features in its calculation. However, postfusion considered only the last six features because the next-interaction had not yet taken place and the first feature was unobtainable. We describe these features and outline their description and participation in prefusion and postfusion in Table 3.

5.2. Evaluation Setup

We used the top-n recommendation task for evaluation because it is practical for real usage. This task evaluates performance based on the recommendation list provided by the system and the actual click of the user. The appropriate metrics are Recall@K and Mean Reciprocal Rank@K (MRR@K), where K is the number of items in the recommendation list. Recall@K measures the model performance whether the actual click is on the K-items recommendation list. It thus denotes a proportion of the number of cases containing the actual click among all cases as follows:

$$Recall@K = \frac{n_{hit}}{N} \quad (8)$$

where n_{hit} is the number of cases having the actual click and N is the number of all cases. MRR@K measures the ranking performance of the model as an average of reciprocal ranks of the actual click within the recommendation list as follows:

$$MRR@K = \frac{1}{N} \sum_{c \in \mathcal{C}} \frac{1}{rank(c)} \quad (9)$$

where c is the actual click, \mathcal{C} is a set of cases having the actual click, and N is the number of all cases.

Herein, we used Recall@K and MRR@K wherein K in $\{1, 5, 10, 15, 20\}$ was used as the evaluation metric, which recommend K-items simultaneously. We also evaluated the model performance in terms of two aspects: warm-start and cold-start item recommendations. We assigned test cases to each perspective using the type of their actual click item. We defined new items appearing only in the testing set and the top 100 most recently introduced items in the training set as cold-start items, whereas the rest were defined as warm-start items. The earliest timestamp of cold-start items defined in the training set was about one month before the splitting point. The numbers of average interactions were 109.84 and 512.59 for cold-start and warm-start items in the training set, respectively. We ended up with 728,066 warm-start item test cases and 56,013 cold-start item test cases.

5.3. Implementation Details

Our profile learner used the rectifier linear unit (ReLU) as the activation function of the GRU, whereas its local encoder used the hard sigmoid. It also used categorical cross-entropy and binary cross-entropy for the loss function of output layers with multiclass and binary classification, respectively. During the training process, the batch size was fixed at 512 and we used 10% of the training set as the validation set to indicate the best version of the model. We set the number of epochs to 30, used Adam [32] as the optimizer, and applied the model with the lowest loss in the validation set. We adjusted the hyperparameters through grid search. Hyperparameters were as follows: learning rate in $\{0.0001, 0.001\}$, categorical feature embedding size in $\{15, 30, 45\}$, context feature embedding size in $\{110, 200, 290\}$, and number of hidden units in $\{110, 200, 290\}$. We treated the embedded item identifier as the categorical feature; hence, its embedding size varied according to the categorical embedding size. The LC restricted the last two hyperparameters to be affected by the categorical feature embedding size owing to element-wise multiplication. These parameters were required to be equal to the sum of the size of the embedded categorical features and numerical features. As a result, the optimized hyperparameters are as follows: learning rate = 0.0001, categorical feature embedding size = 45, context feature embedding size = 290, and the number of hidden units = 290.

6. Experimental Result and Discussion

In this section, we report and discuss the evaluation of our approach in two parts. The first part is a comparison among different applied mechanisms. The latter is a comparison against selected baselines.

6.1. Comparison among Different Mechanisms

There are three applied mechanisms within our approach: NARM's encoder (NE), LC, and weighted cosine similarity (WCS). NE and LC were applied to the profile learner, whereas WCS was applied to the filtering component. This evaluation compares the performances among with and without each mechanism. We explained the changes when we do not apply each mechanism as follows:

- without NE: Attention layer of the profile learner was removed.
- without LC: Embedded context features were incorporated by concatenating instead of performing element-wise product.
- without WCS: Cosine similarity was used as the similarity function in the filtering component instead of the weighted version.

Mechanism			Recall@1	Recall@5	MRR@5	Recall@10	MRR@10	Recall@15	MRR@15	Recall@20	MRR@20
NE	LC	WCS									
-	-	-	8.80%	20.97%	13.06%	28.89%	14.11%	34.42%	14.55%	38.62%	14.78%
-	-	✓	9.02%	21.78%	13.74%	29.84%	14.81%	35.37%	15.25%	39.60%	15.48%
-	✓	-	10.22%	22.70%	14.62%	30.54%	15.66%	36.00%	16.09%	40.14%	16.32%
-	✓	✓	10.86%	23.52%	15.33%	31.45%	16.38%	36.85%	16.80%	41.01%	17.04%
✓	-	-	9.92%	22.38%	14.30%	30.19%	15.33%	35.65%	15.76%	39.82%	16.00%
✓	-	✓	10.27%	22.94%	14.74%	30.91%	15.79%	36.30%	16.22%	40.49%	16.45%
✓	✓	-	11.50%	23.60%	15.76%	31.24%	16.77%	36.56%	17.19%	40.59%	17.42%
✓	✓	✓	11.97%	24.21%	16.29%	31.90%	17.31%	37.13%	17.72%	41.23%	17.95%

Table 4. Comparison between the performances of the proposed approach among different applied mechanisms with 728,066 warm-item test cases.

Mechanism			Recall@1	Recall@5	MRR@5	Recall@10	MRR@10	Recall@15	MRR@15	Recall@20	MRR@20
NE	LC	WCS									
-	-	-	1.71%	8.14%	3.76%	13.33%	4.43%	17.37%	4.75%	20.69%	4.94%
-	-	✓	2.02%	9.02%	4.23%	15.74%	5.11%	20.62%	5.50%	24.46%	5.71%
-	✓	-	2.20%	8.44%	4.26%	13.50%	4.92%	17.51%	5.23%	20.86%	5.42%
-	✓	✓	2.43%	9.41%	4.67%	16.24%	5.57%	20.92%	5.94%	24.51%	6.14%
✓	-	-	2.45%	9.35%	4.69%	14.80%	5.40%	19.03%	5.73%	22.18%	5.91%
✓	-	✓	2.56%	10.20%	5.01%	17.08%	5.92%	21.80%	6.29%	25.40%	6.49%
✓	✓	-	3.52%	10.30%	5.77%	15.64%	6.47%	19.85%	6.80%	23.10%	6.98%
✓	✓	✓	3.60%	11.49%	6.18%	18.08%	7.05%	22.82%	7.43%	26.33%	7.62%

Table 5. Comparison between the performances of the proposed approach among different applied mechanisms with 56,013 cold-item test cases.

We present evaluation results in Table 4 and Table 5. For the profile learner, the results show that applying either NE or LC provides a better recommendation in both warm-start and cold-start item test cases. Moreover, using them together yields the best performance because the profile learner can efficiently incorporate context information and consider it when computing the attention score. For the filtering component, using WCS helps our approach recommend better in both cases, particularly in the cold-starts. This indicates that reducing the influence of the multilabel feature's value improves the performance of similarity score calculation. As a result, the best performances of our approach with all applied mechanisms are used to compare with selected baselines in the following part.

6.2. Comparison against Selected Baselines

Baselines were categorized by their strengths in terms of two aspects: warm-start and cold-start item recommendations. Warm-start item baselines were as follows:

- Pop: A popularity predictor that recommends items ranked by their overall number of interactions.
- S-Pop: A sequence popularity predictor that recommends items ranked by their number of interactions in the current sequence. The remaining positions of the recommendation list are filled with the nonduplicated items from Pop.

- Item-KNN [33]: A memory-based collaborative filtering recommendation system that recommends items using the item vectors obtained from the rating matrix. It uses the nearest-neighbors approach with cosine similarity between the recent interacted item vector in the current sequence and other item vectors to obtain the most relevant items.
- NARM [21]: An encoder-decoder GRU-based session-based recommendation system with an attention mechanism. It captures the entirety of user behavior and the main purpose of user behavior through global and local encoders, respectively, and then recommends items based on them.
- STAMP [22]: An MLP-based session-based recommendation system with an attention mechanism. It creates a recommendation list based on sequential clicks made by the user and can effectively capture both long-term and short-term user interests from the sequence.

These baselines focus on recommending known items from the training set and not mitigating the item cold-start problem. They are unable to recognize new items and their interactions. Therefore, we removed the new item interactions in the testing set sequences to enable these baselines to perform. Moreover, Recall@K and MRR@K were set to zero when the actual click was the new item. We used only the content-based approach [8] with different profile learners and similar filtering components for the cold-start item baselines. They were as follows:

- CB (Pop): A popularity predictor that predicts the user profile using the item profile of the most interacted item. It uses the nearest-neighbors approach with WCS to obtain the most relevant items.
- CB (S-Pop): A sequence popularity predictor that predicts the user profile using the item profile of the most interacted item in the current sequence. It uses the nearest-neighbors approach with WCS to obtain the most relevant items.
- CB (Mean): A model that predicts the user profile from the mean of the item profiles in the current sequence. It uses the nearest-neighbors approach with WCS to obtain the most relevant items.

Method	Recall@1	Recall@5	MRR@5	Recall@10	MRR@10	Recall@15	MRR@15	Recall@20	MRR@20
Pop	0.35%	1.34%	0.68%	2.16%	0.78%	2.82%	0.84%	3.41%	0.87%
S-Pop	6.49%	18.35%	11.07%	21.02%	11.44%	21.88%	11.51%	22.43%	11.54%
Item-KNN	8.95%	25.64%	14.80%	36.56%	16.25%	43.49%	16.80%	48.49%	17.08%
NARM	13.75%	32.79%	20.52%	43.39%	21.93%	49.91%	22.45%	54.59%	22.71%
STAMP	14.09%	33.14%	20.88%	43.55%	22.27%	49.98%	22.78%	54.62%	23.04%
CB (Pop)	0.35%	0.47%	0.38%	0.56%	0.39%	0.56%	0.39%	0.72%	0.40%
CB (S-Pop)	6.49%	13.96%	9.12%	18.83%	9.76%	22.16%	10.02%	24.77%	10.17%
CB (Mean)	6.03%	19.85%	11.14%	26.81%	12.06%	31.45%	12.43%	35.05%	12.63%
Proposed Approach	11.97%	24.21%	16.29%	31.90%	17.31%	37.13%	17.72%	41.23%	17.95%

Table 6. Comparison between the performances of the proposed approach and selected baselines with 728,066 warm-item test cases.

We present evaluation result of warm-start item recommendation in Table 6. In terms of Recall@K, our approach is mostly fourth following Item-KNN, NARM, and STAMP, respectively. The only exception in terms of Recall@1 is that our approach is at the third place by outperforming Item-KNN. In terms of MRR@K, our approach is at the third place behind NARM and STAMP, consecutively. Meanwhile, our approach yields better performance in both terms compared to cold-start item baselines. Although these results do not match our expectation of outperforming Item-KNN, they are better in terms of ranking and one-item recommendation. Our approach cannot beat Item-KNN, NARM, and STAMP in overall warm-start item recommendation owing to two causes. The first is having more candidates. There are 6,917 considered items when calculating the similarity score, out of which not all participate in the interaction logs. Conversely, these three baselines consider only 6,105 items found in the training set. The second is the disadvantage of using the only item attributes to determine the candidates. This results in retrieving only the items similar to the predicted user profile while users can register their interests in items with different attributes.

Method	Recall@1	Recall@5	MRR@5	Recall@10	MRR@10	Recall@15	MRR@15	Recall@20	MRR@20
Pop	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
S-Pop	2.20%	14.96%	7.02%	18.63%	7.53%	19.61%	7.61%	19.78%	7.62%
Item-KNN	0.73%	2.93%	1.48%	4.50%	1.67%	6.15%	1.80%	7.64%	1.88%
NARM	3.81%	7.32%	5.09%	9.37%	5.36%	10.82%	5.47%	12.00%	5.54%
STAMP	3.59%	6.89%	4.79%	8.80%	5.04%	10.09%	5.15%	11.13%	5.20%
CB (Pop)	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
CB (S-Pop)	2.23%	8.02%	4.31%	12.24%	4.86%	14.76%	5.06%	17.10%	5.19%
CB (Mean)	4.96%	18.67%	10.19%	24.72%	10.99%	28.42%	11.28%	31.39%	11.45%
Proposed Approach	3.60%	11.49%	6.18%	18.08%	7.05%	22.82%	7.43%	26.33%	7.62%

Table 7. Comparison between the performances of the proposed approach and selected baselines with 56,013 cold-item test cases.

We present the evaluation results of cold-start item recommendation in Table 7. In terms of Recall@K, our approach is mostly in second following CB (Mean). The exceptions in terms of Recall@5 and Recall@10 are that our approach is at the third place following S-Pop. In terms of MRR@K, our approach is placed third following S-Pop and CB (Mean). Meanwhile, it performs considerably in both terms compared to Item-KNN, NARM, and STAMP. This evaluation result shows that our approach is not the best method to recommend cold-start items. Using the mean of attributes provides a better user profile than predicting from sequential and context information when recommending these items. Moreover, recommending items based on the popularity of the current sequence performs better than our approach in terms of ranking and 5-item and 10-item recommendations. However, this result does indicate that our approach can solve the item cold-start problem.

When integrating these results, it is difficult for a method to perform well in both recommendations simultaneously. The methods suitable with warm-start items showed meager performance with cold-start items. Likewise, the methods suitable for cold-start items yielded dissatisfactory performance when recommending warm-start items. In detail, according to Recall@20, the first, second, and third places in warm-start item recommendation are occupied by STAMP, NARM, and Item-KNN, respectively. Despite decent performances with warm-start items, they are placed

sixth, fifth, and seventh in the cold-start item recommendation, consecutively. Similarly, CB (Mean), the first place in cold-start item recommendation, is in fifth place when recommending warm-start items. Nevertheless, our approach is in fourth place and second place in warm-start and cold-start item recommendations, respectively. It yields promising results in both recommendations at the same time although neither result is the best. It is particularly important for real estate recommendations to be able to perform well in both recommendations because each real estate listing is unique and users can register concurrent interest in prior and recent projects. Thus, we believe that our method provides a suitable compromise between both recommendations and that it will benefit recommendation tasks focusing on both recommendations.



7. Further Study

Herein, we weighted every feature equally when computing the similarity score; however, this might not match with user's attributes priority. There could be user specific requirements when searching for real estate. For example, users with a car may pay more attention to car parking than users without a car. Hence, making this approach more personalized by incorporating different weights for each feature should improve the recommendation performance.



Appendix A: Recommendation Examples

We provide some random recommendation examples of the proposed approach in this part. The examples are shown as top-1, top-5, top-10, top-15, top-20, and missed recommendations. We represent each real estate project in the provided examples using its name and use the red and blue colors to tell whether it warm or cold, respectively.

A.1 Top-1 Recommendation Examples

Input Sequence	Ground Truth	20-item Recommendation List
เนเทอร์รำ พาร์ค บ้านใหม่-โคกกรวด, บ้านดินโหด, นนทวิวิล 5, ดี เอ็กซ์เทนโซ 2, ศุภาลัย วิลล วังแหวน-พระราม 2	ศุภาลัย วิลล วังแหวน-บางใหญ่	ศุภาลัย วิลล วังแหวน-บางใหญ่, ศุภาลัย วิลล วังแหวน-ลำลูกกา คลอง 5, ศุภาลัย วิลล กรุงเทพฯ-ปทุมธานี, ศุภาลัย เบลล่า วังแหวน-ลำลูกกา คลอง 4, ศุภาลัย วิลล วังแหวน - ลำลูกกา คลอง 3, เบลล่า วังแหวน-ลำลูกกา คลอง 3, ภัสสรไพร์ด ปิ่นเกล้า-วังแหวน, คณาสิริ วังแหวน - ลำลูกกา, เพอร์เฟค พาร์ค รังสิต 2, เดอะ แพลนท์ รังสิต-คลอง 3, เดอะ แพลนท์ กรุงเทพฯ-ปทุมธานี, ศุภาลัย การ์เด็นวิลล วังแหวน-ลำลูกกา คลอง 3, บ้านฟ้าปิยมรณีนีวา ทางด่วนวังแหวน ลำลูกกาคลอง 6, เดอะ วิลเลจ รังสิต-วังแหวนฯ, เดอะ แพลนท์ ชัยพฤกษ์-วังแหวน, ศุภาลัย วิลล ศรีสมาน-ปทุมธานี, เดอะทริสต์ กาญจนภิเษก-หทัยราษฎร์, ศุภาลัย เบลล่า กรุงเทพฯ-ปทุมธานี, โนว วิลล กรุงเทพฯ - ปทุมธานี, ศุภาลัย การ์เด็นวิลล กรุงเทพฯ-ปทุมธานี
บ้านกลางเมือง คลาสเซ่ เอกมัย-รามอินทรา	อาร์เทล เกษตร-นวมินทร์	อาร์เทล เกษตร-นวมินทร์, นาราสิริ โทเพียรี นวมินทร์, เดอะ ซิตี นวมินทร์, เซนโทร รามอินทรา-จตุโชติ, เศรษฐสิริ พัฒนาการ, คาซ่า เลเจนด์ เกษตร-นวมินทร์, เดอะ ซิตี พัฒนาการ, โซล ลาดพร้าว - เสนา, เนอวานา บียอนด์ เกษตร-นวมินทร์, บ้านบุรีปรี สตรีวิทยา 2, แลนด์มาร์ค เอกมัย-รามอินทรา, เดอะ ซิตี พหลโยธิน, เศรษฐสิริ พหล-วัชรพล, อารียา เมทโทร เกษตร-นวมินทร์, โกลเด็นนีโอ ลาดพร้าว-เกษตรนวมินทร์, ภัสสร สรวงประภา, เดอะ ซิตี สาทร-ราชพฤกษ์, บ้านกลางเมือง คลาสเซ่ เอกมัย-รามอินทรา, บุราสิริ วัชรพล, เมอคูน ปิ่นเกล้า-ราชพฤกษ์
คาซ่า วอเตอร์ไซด์ พระราม 5, มาย อีสระ ราชพฤกษ์-รัตนธิเบศร์, เดอะ แกลเลอรี รัตนธิเบศร์-ราชพฤกษ์, รติรมย์ ฟิฟท์ ราชพฤกษ์-ตลิ่งชัน, บ้านกลางเมือง ราชพฤกษ์, เมอคูน ปิ่นเกล้า-ราชพฤกษ์	บ้านกลางเมือง ราชพฤกษ์	บ้านกลางเมือง ราชพฤกษ์, ริชชา พระราม 5, ธนาสิริ ราชพฤกษ์-ทำนันทน์, ไลฟ์ บางกอก บูเลอวาร์ด ราชพฤกษ์-ปิ่นเกล้า, พงกษาวิลเลจ 22 (ปิ่นเกล้า-สิรินธร), บ้านกลางเมือง ดี เอรา ปิ่นเกล้า-จรัญฯ, เดอะ แกลเลอรี รัตนธิเบศร์-ราชพฤกษ์, พาทีโอ พระราม 5 - สิรินธร, นนทรี รีเจนท์ ราชพฤกษ์, รติรมย์ พาร์ค, เดอะ คลัสเตอร์วิลล 4 ราชพฤกษ์-สิรินธร, ธนาอาบิเนต ราชพฤกษ์-สิรินธร, วิลล่า พาร์ค รัตนธิเบศร์, ริชชา นครอินทร์, เซนโทร ราชพฤกษ์, มัณฑนา ปิ่นเกล้า-พระราม 5, วิสต้า ปาร์ค สาทร-ปิ่นเกล้า, ปัญธิญา พระราม 5 (โครงการ 3), รติรมย์ ฟิฟท์ ราชพฤกษ์-ตลิ่งชัน, คาซ่าวิลล ราชพฤกษ์ พระราม 5

Input Sequence	Ground Truth	20-item Recommendation List
เดอะริช บีชโฮม สุขุมวิท 105, ยูนิโอทาวน์ สวนหลวง-พัฒนาการ, เดอะ แพลนท์ เอสทีค พัฒนาการ	ยูนิโอทาวน์ สวนหลวง-พัฒนาการ	ยูนิโอทาวน์ สวนหลวง-พัฒนาการ, ภัตสร เพรสทิจ ลุคซ์ พัฒนาการ, พรีเมียม ไทมโฮม วงแหวน-อ่อนนุช, เอสทารา ฮาเว่น พัฒนาการ 20, พกษาวิลด์ 73 พัฒนาการ, โนเบิล คิวบ์ พัฒนาการ, ดี เอ็กซ์คลูซีฟ พัฒนาการ - เอกมัย - ทองหล่อ, วิลเลต โลท์ พัฒนาการ, พกษาวิลด์ พัฒนาการ 38-อ่อนนุช, โกลเด้น ทาวน์ ๒ บ้านนา-สวนหลวง, ดีวัน อ่อนนุช - ศรีนครินทร์, พาทีโอ พัฒนาการ 38, บ้านเปี่ยมสุข ทิศคานี พัฒนาการ 44, ทาวน์โฮม เดอะ บัลโคนี โฮม, นิรันดร์วิลด์ 8, ชวนชื่น พาร์ค อ่อนนุช-วงแหวน, วิลเลต ซิตี พัฒนาการ 38, บ้านกลางเมือง สวนหลวง, พาทีโอ พระราม 9-พัฒนาการ, อาร์เด็น พัฒนาการ
เจนโทร ราชพฤกษ์-แจ้งวัฒนะ, เดอะทรีสต์ ราชพฤกษ์-รัตนานิเบศร์, เซนโทร ราชพฤกษ์-แจ้งวัฒนะ, เซนโทร บางใหญ่, สัมมากร ชัยพฤกษ์-วงแหวน 2, เซนโทร บางใหญ่, เดอะทรีสต์ ราชพฤกษ์-รัตนานิเบศร์, เซนโทร ราชพฤกษ์-แจ้งวัฒนะ	เซนโทร ชัยพฤกษ์-แจ้งวัฒนะ 2	เจนโทร ชัยพฤกษ์-แจ้งวัฒนะ 2, เซนโทร ราชพฤกษ์-แจ้งวัฒนะ, เพอร์เฟคเพลส แจ้งวัฒนะ 2, เซนโทร บางใหญ่, สราญสิริ ราชพฤกษ์-แจ้งวัฒนะ, เอสเกต พรีเมียม แจ้งวัฒนะ-ชัยพฤกษ์, สัมมากร ชัยพฤกษ์-วงแหวน 2, S88 ราชพฤกษ์-รัตนานิเบศร์, เจ วิลล่า วงแหวน-บางใหญ่, เวนิว เวสต์เกต, สัมมากร ชัยพฤกษ์-แจ้งวัฒนะ, บ้านฟ้ากรีนเนอร์ ปากเกร็ด-ราชพฤกษ์, โลฟี่ บางกอก บูเลอวาร์ด ราชพฤกษ์-รัตนานิเบศร์, บ้านลภาวัน 21, เซนโทร ชัยพฤกษ์-แจ้งวัฒนะ, คาซ่า พรีเมียม ราชพฤกษ์-แจ้งวัฒนะ, ดีซีโอ ราชพฤกษ์-รัตนานิเบศร์, เฮาส์ โคลเวอร์ แจ้งวัฒนะ-ราชพฤกษ์, เศรษฐสิริ ชัยพฤกษ์-แจ้งวัฒนะ, เซนโทร เวสต์เกต
เดอะริช พระราม 9-ศรีนครินทร์ ทริปปี้ล สเตชั่น, โครงการฯ ลาดกระบัง 3/1, เอ สเปซ เมกา 2, นอดดีง ฮิลล์ สุขุมวิท 105	เอ สเปซ เมกา 2	เอ สเปซ เมกา 2, เอ สเปซ สุขุมวิท 77, เลเวล คอนโดมิเนียม, เอ สเปซ มี บางนา, ไอ คอนโด กรีนสเปซ สุขุมวิท 77 เฟส 1, ลุมพินี วิลด์ พัฒนาการ-ศรีนครินทร์, เดอะ สปริต คอนโดมิเนียม, ไอคอนโด สุขุมวิท 77, เอสเพน คอนโด เฟส บี, เอ สเปซ มี สุขุมวิท 77, เดอะ นิซ โมโน บางนา เฟส 2, ลุมพินี เทลส บางนา กม.3, แอชเชอร์ ริชตา-ห้วยขวาง, ไอ คอนโด กรีนสเปซ สุขุมวิท 77 เฟส 2, เอ สเปซ เมกา, เดอะ แอปบีเนส, ดี เอ็กเซล ลาดพร้าว 17, ไฮ ลาดพร้าว 130, ไฮ สุขุมวิท 93, เดอะวันพลัส แกรนด์ รามคำแหง

Table 8. Examples of the proposed approach's top-1 recommendation

A.2 Top-5 Recommendation Examples

Input Sequence	Ground Truth	20-item Recommendation List
บ้านพฤกษา รังสิต-คลองหลวง 2, เดอะ แพลนท์ รังสิต คลอง 4-วงแหวน, เดอะ แพลนท์ รังสิต คลอง 5, เดอะ แพลนท์ รังสิต คลอง 4-วงแหวน, บ้านพฤกษา รังสิต-คลองหลวง 2, เดอะ แพลนท์ รังสิต คลอง 4-วงแหวน	เดอะ แพลนท์ รังสิต คลอง 5	เดอะ แพลนท์ รังสิต คลอง 4-วงแหวน, เดอะ แพลนท์ รังสิต-คลอง 3, เดอะ แพลนท์ รังสิต-คลองหลวง, เดอะ คอนเนค @รังสิต, เดอะ แพลนท์ รังสิต คลอง 5, เดอะ แพลนท์ วงแหวน-รังสิต, ศุภาลย์ เบลล่า รังสิต คลอง 2, บ้านพฤกษา พหลโยธิน-คลองหลวง, พลินี รังสิตคลอง 4-วงแหวน, บ้านพฤกษา 119 รังสิต-คลอง 2, เดอะ แพลนท์ รังสิต-คลอง 2, โมดิ วิลล่า รังสิต คลอง 7, บ้านธรรมชาติ รังสิต-นครนายก คลอง 7, วิลลาจจีโอ รังสิต คลอง 2, ไอลิฟ พาร์ค วงแหวน-รังสิตคลอง 4, เซนโทร รังสิต คลอง 4-วงแหวน, เดอะซีซั่น รังสิต-คลอง 3, เอกกวิน 3 ลำลูกกา-รังสิต คลอง 2, ศุภาลย์ วิลด์ รังสิต คลอง 2, เดอะทรีสต์ ทาวน์โฮม รังสิต-คลอง 1
เวิร์ฟ พระราม 9	พฤกษาวิลด์ รามคำแหง-วงแหวน (มิสทิน)	เวิร์ฟ พระราม 9, พฤกษาวิลด์ รามคำแหง-วงแหวน (มิสทิน), เดอะ เมโทร พระราม 9-กรุงเทพกรีฑา, ศุภาลย์ เบลล่า วงแหวน-รามอินทรา, พลินี พระราม 9-กรุงเทพกรีฑา, เดอะ คอนเนค วงแหวน-พระราม 9, แกรนด์ พลินี สุขสวัสดิ์-พระราม 3, ภัตสร รามคำแหง-ราษฎร์พัฒนา, พลินี พหลโยธิน-วัชรพล, เออร์บาโน่ รามคำแหง, พลินี สุขสวัสดิ์ 30, บ้านกลางเมือง เดอะ ปารีส พระราม 9-รามคำแหง, บ้านกลางเมือง พระราม 9-กรุงเทพกรีฑา, พาทีโอ รามคำแหง-วงแหวน, โมโน เอกชัย-พระราม 2, เดอะ นิซ รามอินทรา-พระยาสุเรนทร์, พลินี รามอินทรา-วงแหวน, เดอะ คัลเลอร์ส วงแหวน-รามอินทรา 2, บ้านพร้อมพัฒนา พระราม 9-วงแหวน, เนอวานา ดีฟายน์ ศรีนครินทร์-พระราม 9

Input Sequence	Ground Truth	20-item Recommendation List
วิเศษสิริ 2 สมุทรสาคร, เดอะมันนี่ มี พันธวงษ์, เดอะ มิวราเคิล พลัส เศรษฐกิจ-คลองครุ	โลโอ บลิสซ์ เศรษฐกิจ-พุทธสาคร	เดอะมันนี่ มี พันธวงษ์, โลโอ บลิสซ์ เศรษฐกิจ-พุทธสาคร, บ้านพัก เศรษฐกิจ-พระราม 2, บ้านศิริทรัพย์ โครงการ4-ถนนเศรษฐกิจ, ลินสิริ บางโพธิ์, บ้านแลนซีโอ คริป เศรษฐกิจ-พุทธสาคร, พุทธาวิลล์ พุทธสาคร, บ้านพัก พระราม 2-เอกชัย, บ้านสวนท่าทราย สวนส้ม-พระราม 2, บ้านพัก พระราม 2 (พันท้ายนรสิงห์) , เดอะ มิวราเคิล พลัส เศรษฐกิจ-คลองครุ, นิราวิลล์, สวนส้ม 3 พระราม 2-สวนส้ม, ฌัญญา พุทธสาคร (สาย 4-ตัดใหม่), บ้าน ดี บางโพธิ์, เอ ริกาวิลล์, ซีเค วิลล์ 5 พระราม 2-สวนส้ม, วิลลาจีโอ เพชรเกษม-สาย 4, เดอะ แพลนท์ ถ.เศรษฐกิจ-มหาชัย, บ้านวันดี มหาชัย-คลองครุ
บ้านอิสสระ บางนา, บ้านกลางเมือง The Edition พระราม 9-พัฒนาการ	ภัตสร บางนา-วง แหวน	บ้านอิสสระ บางนา, เพอร์เฟค พาร์ค บางนา, ภัตสร บางนา-วงแหวน , บูราสิริ อ่อนนุช - บางนา, มั่นหนา อ่อนนุช-วงแหวน 5, เรสท์ วิลเลจ, อีโค สเปซ บาง นา-วงแหวน, พุทธาวิลล์ บางนา-วงแหวน, เลคไซด์ วิลล่า 2, วารีโอ สุวรรณภูมิ, บ้านกลางเมือง THE EDITION พระราม 9-อ่อนนุช, บลูลาگون 2 บางนา-วงแหวน , บ้านพูนสุข สุวรรณภูมิ (บางนา-สุวรรณภูมิ), ภัตสร เพรสติจ บางนา-สุวรรณ ภูมิ, เพอร์เฟค เพลส สุขุมวิท 77-สุวรรณภูมิ, โกลเด้น วิลเลจ บางนา-กิ่งแก้ว, พาทีโอ บางนา-วงแหวน, เอโกล มัลดีพีส์ ป่าลม, เดอะ แพลนท์ อ่อนนุช-มอเตอร์ เวย์, คาซ่า ซิตี กิ่งแก้ว-สุวรรณภูมิ
บ้านใหม่ พระราม2-พุทธบูชา 2, เซนโทร สุขสวัสดิ์-พระราม 3, อะซี ประชาอุทิศ 54, แกรนด์ ฟลิโน สุขสวัสดิ์, โกลเด้น ทาวน์ ๓ สุขสวัสดิ์-พุทธบูชา, บ้านลุมพินี ทาวน์วิลล์ สุขสวัสดิ์-พระราม 2, บ้านลุมพินี ทาวน์พาร์ค ท่าข้าม-พระราม 2, ริดดา วงแหวน-ประชาอุทิศ 76 , ลีรินทาวน์ 3, โลโอ บลิสซ์ ประชาอุทิศ-สุขสวัสดิ์	แกรนด์ ฟลิโน สุข สวัสดิ์-พระราม 3	แลนซีโอ คริป ประชาอุทิศ-สุขสวัสดิ์, บ้านขนากานต์ พระสมุทรเจดีย์, บ้าน พัก 128 สุขสวัสดิ์-ประชาอุทิศ, แกรนด์ ฟลิโน สุขสวัสดิ์-พระราม 3 , ฟลิโน สุขสวัสดิ์ 66, บ้านธารินทร์ ประชาอุทิศ-วัดคู่สร้าง, บ้านพัก สุขสวัสดิ์- กาญจนาภิเษก 2, เอเวอร์ ซิตี สุขสวัสดิ์ 30-พุทธบูชา, ซิวาโฮม สุขสวัสดิ์-ประชา อุทิศ, ฟลิโน สุขสวัสดิ์ 30, บ้านพัก 77/2 สุขสวัสดิ์-กาญจนาภิเษก, บ้าน พัก ประชาอุทิศ-พระราม 2, โอลิฟ ทาวน์ 2 ประชาอุทิศ 90, เนเชอรัล เท รันต์ ประชาอุทิศ 90, คาซ่า ซิตี ประชาอุทิศ 90, ศุภาลัย ไพร์ด ประชาอุทิศ, ซิตี เจนส์ พระราม 2-ท่าข้าม, กัลได้ ทาวน์โฮม สุขสวัสดิ์ 26-2, บ้านพัก 82 ประชาอุทิศ-พระราม 2, เนเชอรัล พระราม 2-วงแหวน ประชาอุทิศ
แกรนด์ บางกอก บูเลอวาร์ด ศรีนครินทร์	เดอะ พาลาซโซ่ ศรี นครินทร์	แกรนด์ บางกอก บูเลอวาร์ด ศรีนครินทร์, เดอะ พาลาซโซ่ ศรีนครินทร์, เดอะ แกรนด์ ลักซ์ บางนา-สวนหลวง, เนอวานา บียอนด์ ศรีนครินทร์, อาร์เทล พัฒนาการ-ทองหล่อ, บูราสิริ พัฒนาการ, แกรนด์ บางกอก บูเลอวาร์ด พระราม 9, เดอะ ซิตี พัฒนาการ, แกรนด์ บางกอก บูเลอวาร์ด รามอินทรา-เสรีไทย, เศรษฐสิริ พัฒนาการ, ดี เอวา เรสซิเดนซ์ สุขุมวิท, พาร์ค อเวนิว ไพรเวท, วนา เรสซิเดนซ์, ทุ แกรนด์ โมนาโค บางนา-วงแหวน, เดอะ เจนทริ สุขุมวิท, เดอะ สตาร์ เอสเตท @พัฒนาการ, เดอะ เจนทริ พระราม 9, เดอะ แกรนด์ อุดมสุข, ซิ พัฒนาการ 32, เดอะ แกรนด์ บางนา-วงแหวน

Table 9. Examples of the proposed approach's top-5 recommendation

A.3 Top-10 Recommendation Examples

Input Sequence	Ground Truth	20-item Recommendation List
เมืองเชลล์ อเวนิว ติวานนท์-แจ้งวัฒนะ, อยู่รวย คอนโด	พลัมคอนโด โขกชัย 4	โอ คอนโด กรีนสเปซ เสรีไทย, โอ คอนโด สุขาภิบาล 2, เดอะ ดิพท์ พลัส นวมิ นทร์, ยูนิโอ รามคำแหง-เสรีไทย, แอทโมซ ลาดพร้าว 71, เอลลิโอ เดล มอส์ ทลโยธิน 34, พลัมคอนโด นวมินทร์, พลัมคอนโด โขกชัย 4 , สราญวิลล์ @ แสบีแลนด์, คอนโด ยู เกษตร-นวมินทร์, ศุภาลัย คิวท์ รัชโยธิน-พหลโยธิน 34, นว ลิฟวิ่ง นวมินทร์ 75, โอดีโอ ลาดพร้าว 5, วี คอนโด เอกมัย-รามอินทรา, เอ สเปซ เกษตร, พรีเมโอ ไพร้ม, ยูทรี คอนโด แอท แยกเกษตร, พรีเมโอ ไพร้ม เกษตร-นวมินทร์, เดอะไพร์เวซี ลาดพร้าว-เสนา, พาร์ค เอ็กซ์โซ พลัส เกษตร-น วมินทร์

Input Sequence	Ground Truth	20-item Recommendation List
โคขุน พระราม 9, โซมิส เอ็กซ์คลูซีฟ รัชดา, เมโทร ลักซ์ โรสโกลด์ พหลฯ-สุทธิสาร, ลุมพินี สวีท ดินแดง-ราชปรารภ, เดอะ ทีก สาท-ลุมพินี, มาเอสโตร 07 อนุสาวรีย์ชัยฯ, ศุภาลัย ไท่ รัชดา-นราธิวาส-สาทร, รัสอร์ทต้า เย็นอากาศ, มาเอสโตร 14 สยาม-ราชเทวี, โนเบล ริโว สีลม, โนท์บริดจ์ โพรม สาทร, ลุมพินี สวีท เพชรบุรี-มักกะสัน, โนเบล ริโว สีลม	ศุภาลัย ไท่ รัชดา-นราธิวาส-สาทร	Rhythm Sathorn, เดอะ รุม สาทร-เซนต์หลุยส์, เดอะคีย์ สาทร-เจริญราษฎร์, เซอร์เคิล ลิฟวิง โปรโตไทป์ 2, พิวส์ จันทน์-สาทร, ศุภาลัย ไท่ รัชดา-นราธิวาส-สาทร , ศุภาลัย เอสที สี่พระยา, ศุภาลัย ริวา แกรนด์, คิว อโศก, ไฮด์ สุขุมวิท 11, เดอะ แบงค็อก สาทร, ศุภาลัย คาชา ริวา, เดอะ รุม พญาไท, โนเบล บี โนนท์ สุขุมวิท, โนเบล เฟลนิจิต, เซอร์เคิล เพชรบุรี, เดอะ เทรนต์ คอนโดมิเนียม, ศุภาลัย พรีเมียร์ รัชดา-นราธิวาส-สาทร, พาร์ค ออริจิน พญาไท, เซอร์เคิล 1 เพชรบุรี 36
ดอยคำฮิลล์ไซด์ 5 (แม่โจ้), กรีนวิวโฮม เฟส 2, บ้านธกฤษณ์, กาญจน์กนกวิลล์ 10 สันผักหวาน, เดอะ พลินารี สันทราย, กาญจน์กนกวิลล์ 13 น้ำโสม, พราว บาย ขวัญเวียง, รินดา สันทราย, อรสิริน 14, ดอยคำฮิลล์ไซด์ 5 (แม่โจ้), บ้านเชียงใหม่ พฤษชาโฮม, ปริญญาตา เชียงใหม่-สันกำแพง, ดี เอ เทอร์นี่ดี โฮม, ภัสสร ไพร์ด มหิดล เจริญเมือง (เชียงใหม่), กาญจน์กนกวิลล์ 12 สันโป่ง, กาญจน์กนกวิลล์ 11 สันนาเมือง, บ้าน ณ ซีน, ปียอนด์ สันกำแพง, บ้านนนนิภา (แม่โจ้), เดอะ ปาล์มการ์เด้น โครงการ 7, กาญจน์กนกทาวน์ 4 ทองจ้อม	กรีนวิวโฮม เฟส 2	เดอะ ปาล์ม การ์เด้น 6 สันนาเมือง-สันทราย, เดอะ ปาล์มการ์เด้น โครงการ 7, บ้านชลพร, อรสิริน 14, บ้านกาญจน์ 4, บ้านแสนสบาย 3, บ้านธารน้ำโสม เฟส 7, กรีนวิวโฮม เฟส 2 , เดอะพลินารี สันทราย, อรสิริน 11 Mountain & Lake, บ้านนนนิภา (แม่โจ้) , บ้านกานต์วี, ตัญญา วาเลย์ สันทราย 2, บ้านร่มรื่น, วิลลาจ ลีโอ สันทราย-เชียงใหม่, แกรนด์ โคมอนด์ ลานนา สันพระนคร, กาญจน์กนกวิลล์ 16 ทองจ้อม, บ้านพิภพดี โครงการ 4, บ้านกานต์วี 2, เดอะ ปาล์มการ์เด้น โครงการ 5
แอสปายอุดรธานี, เมืองงามแสนสิริ, โครงการเคหะชุมชนและบริการชุมชน อุดรธานี (สามพร้าว), บ้าน ณ สามพร้าว 2, ศุภาลัย เบลล่า อุดรธานี	บ้านชนากานต์ อุดรธานี	โนโว วิลล์ อุดรธานี, บ้าน ณ สามพร้าว 2, บ้านชนรดา 2 มิตรภาพ-บ้านจั่น, โครงการเคหะชุมชนและบริการชุมชน อุดรธานี (สามพร้าว), เดอะ ไนน์ แอท ประชาสันติ, ศุภาลัย วิลล์ มิตรภาพ-บ้านจั่น, เดอะพรีเมียม วิลล์ อุดรธานี, อินทาวน, พลินวิลล์, บ้านชนากานต์ อุดรธานี , ไอ วิลเลจ, ศรีธานี, ซินเนอร์รี่ วิว (หนองสำโรง), ศุภาลัย เบลล่า อุดรธานี, บ้านรุ่งเรือง 4, คริสตัลโฮม อุดรธานี 1, ลีวีวิลเลจ อุดรธานี - แอร์พอร์ต, ลินธารา เลควิว อุดรธานี, รุ่งเรือง 8 บ้านข้างบ้านแฝด, รุ่งเรือง 6 คชช.บ้านเดี่ยวชั้นเดียว
เศรษฐสิริ พหล-วัชรพล, เซนโทร รามอินทรา-จตุโชติ, จามจรี พาร์ค รามอินทรา 39, อาร์เค พาร์ค รามอินทรา-ชาฟารี, พลินี รามอินทรา, ดี เอ็กซ์คลูซีฟ วงแหวน-รามอินทรา, เดอะ คัลเลอร์ส วงแหวน-รามอินทรา 2, พาร์ควิลล์ 3	ศุภาลัย เบลล่า วงแหวน-รามอินทรา	แลนด์ฮิลล์ นอฟ รามอินทรา-คูบอน 38, เดอะ นีซ รามอินทรา-พระยาสุเรนทร์, เดอะ คัลเลอร์ส วงแหวน-รามอินทรา 2, บ้านประภาพรพิทย รามอินทรา-หทัยราษฎร์, เค.ริช ทาวน์ รามคำแหง-นิมิตใหม่ 15, ศุภาลัย เบลล่า วงแหวน-รามอินทรา , เบสส์วิลล์ รามอินทรา 117, กรีนนิช โพรม ทางด่วนรามอินทรา-หทัยราษฎร์, เดอะเบสท์ หทัยราษฎร์-ไทยรามัญ, เบสส์ วิลล์ รามอินทรา-พระยาสุเรนทร์ 25, รื่นฤดี 7 (รามอินทรา-หทัยราษฎร์), กรูฟวิลล์ รามอินทรา, เดอะรักซ์ รามอินทรา-หทัยราษฎร์, ชิกเนเจอร์ รามอินทรา, เดอะ แพลแซง รามอินทรา-คูบอน, อาร์เค พาร์ค รามอินทรา-ชาฟารี, พาทาโกเนีย 3 ชาฟารี - เลียบคลองสอง, เค.ซี.การ์เด้นโฮม, ชัยพฤกษ์ รามอินทรา-พระยาสุเรนทร์, ฮาบีเทีย ออร์บิต หทัยราษฎร์
นิช โมโน รามคำแหง, พาร์ค เอ็กซ์โซ พลัส เกษตร-นวมินทร์, เดอะริช พระราม 9-ศรีนครินทร์ ทริปเปิ้ล สดชื่น, ริชพาร์ค @ทริปเปิ้ลสดชื่น, ไพรเวทเนอวาน่า โลฟ เอ็กซ์คลูซีฟ, ดีลักซ์ทาวน์ เลียบทางด่วน-รามอินทรา, เพอร์เฟค เพลส พระราม 9-กรุงเทพกรีฑา	บ้านกลางเมือง พระราม 9-กรุงเทพกรีฑา	ทาวน์พลัส เกษตร-นวมินทร์, บ้านกลางเมือง นวมินทร์ 42, ดีลักซ์ทาวน์ เลียบทางด่วน-รามอินทรา, บ้านกลางเมือง เกษตร-นวมินทร์, เพอร์เฟค เพลส รามคำแหง-สุวรรณภูมิ 3, พฤษชาโลฟ พระราม9-ศรีนครินทร์, เศรษฐสิริ ศรีนครินทร์-พระราม 9, บ้านกลางเมือง ลาดพร้าว 87, บ้านกลางเมือง พระราม 9-กรุงเทพกรีฑา , นีโอ สเปซ สุขุมวิท 3, เพอร์เฟค เพลส รามคำแหง-สุวรรณภูมิ 2, พรีเมเว เอกมัย-รามอินทรา, อารียา เดลี่ เกษตร-นวมินทร์, อารียา ทูปี เกษตร-นวมินทร์, บ้านกลางเมือง ลาดพร้าว-เสรีไทย, เพอร์เฟค เพลส วงแหวน-รามคำแหง, เฟล็กซ์ เรสซิเดนซ์ เกษตร-นวมินทร์, อารียา ทูปี เกษตร-นวมินทร์, พาทิโอ รามคำแหง-วงแหวน, โคซี่ นาคนิवास 37

Table 10. Examples of the proposed approach's top-10 recommendation

A.4 Top-15 Recommendation Examples

Input Sequence	Ground Truth	20-item Recommendation List
เพ-ลา, เดอะ เทมโป แกรนด์ สาทร-วุฒากาศ, เดอะริช สาทร-ตากสิน, ยู ดีไลท์ @ตลาดพลู สเตชั่น, เดอะ เพรสซิเด็นท์ สาทร-ราชพฤกษ์ 2, ซี วาท์ย เพชรเกษม 27, แบงค์ค็อก ออโรซอน โลท์ @สถานีเพชรเกษม 48	เดอะ เลค กัลปพฤกษ์-วุฒากาศ	เดอะ เพรสซิเด็นท์ สาทร-ราชพฤกษ์ 2, แอสปาย สาทร-ราชพฤกษ์, แบงค์ค็อก ออโรซอน โลท์ @สถานีเพชรเกษม 48, โพรดิจี เอ็มอาร์ที บางแค, แบงค์ค็อก ออโรซอน เพชรเกษม, บีที บางหว้า อินเทอร์เน็ต, แอสปาย สาทร-ตากสิน (Timber Zone), ซีวาทัย เพชรเกษม 27, แอสปาย สาทร-ตากสิน (คอปเปอร์ โซน), อดีโอ ท่าพระ-อินเทอร์เน็ต, ศุภาลัย ลอฟท์ สถานีตลาดพลู, รีเจนท์ ออร์คิด ตลาดพลู, เดอะ เลค กัลปพฤกษ์-วุฒากาศ, ศุภาลัย ปาร์ค ราชพฤกษ์-เพชรเกษม, เมโทร สกาย วุฒากาศ, วิสซ์คอม สเตชั่น รัชดา-ท่าพระ, อดีโอ สาทร-ท่าพระ, นิช อดี เพชรเกษม-บางแค, ธนา แอสโทเรีย ปิ่นเกล้า, แอสปาย สาทร-ราชพฤกษ์
อดีโอ สาทร-วงเวียนใหญ่, โคซี่ โชคชัย 4 ซอย 84 แยก2-2, โคซี่ สตรีวิทยา ซอย 32, นาราสิริ โทเพียร์ นวมินทร์	คิมันตรา ลาดพร้าว 71	บ้านบุรีศรี สตรีวิทยา 2, โคซี่ นาคนิวาส 37, อาร์เทล เกษตร-นวมินทร์, โคซี่ โชคชัย 4 ซอย 72, เดอะ ฟรืดอม, โคซี่ โชคชัย 4 ซอย 84 แยก2-2, โคซี่ สตรีวิทยา ซอย 32, นีโอ สเปซ ลุคนธสวัสดิ์ 3, โคซี่ โชคชัย 4 ซอย 28, เดอะ คาสเทลโล ลาดพร้าว 71, โคซี่ โชคชัย 4 ซอย 18 แยก 2, พราโต้, คิมันตรา ลาดพร้าว 71, คลัสเตอร์เฮาส์ ลาดปลาเค้า 53, ลมหายใจ นาคนิวาส 48, เดอะ ลีฟท์ บาย ไอ-เจน, นาราสิริ โทเพียร์ นวมินทร์, โชล ลาดพร้าว - เสนา, คาซ่า แกรนด์ เกษตร-นวมินทร์, บ้านกลางเมือง ลาดพร้าว 71
บ้านธนภูมิ, เดอะ แพลนท์ ปิ่นเกล้า-สาย 5, บ้านขริดา (ดอนตูม-นครปฐม), เดอะทาวน์ บางแฉม-หลังสิรินธร, หมู่บ้านจงเจริญโชคชัย 3	บ้านอยู่สบาย 8	เดอะเค็ดด์ ลำพญา, พฤษชาพรรณ ลำพญา 2, บ้านอยู่ดี นครปฐม, บ้านอยู่สบาย สนามกีฬา, แกรนด์ธรา ไพร์สตาร์วิลเลจ, ธราศิริ, มัดชานา นครปฐม, เดอะทาวน์ บางแฉม-หลังสิรินธร, พฤษชาพรรณ กระติ๊ดเดียว2, พฤษชาพรรณ แกรนด์ลำพญา 3, พฤษชาพรรณ ราชภัฏ, ร้อยพฤษชา กำแพงแสน, บ้านอยู่สบาย 8, บ้านอยู่สบาย หนองขาหย่าง, บ้านเจียรไน 6, พฤษชาพรรณ กระติ๊ดเดียว 3, บ้านเจียรไน 7, เดอะ ชาริน่า, บ้านเจียรไน 8, ร้อยพฤษชา เลควิลล์
เดอะ พอยต์ คอนโด แผลมฉบัง, บ้านแสนสรายุ, ธาราวานา, สระบุรีบ้านสวย 5	สระบุรีบ้านสวย 7	ธาราวานา, บ้านแสนสรายุ, เดอะวิลเลจ, พันดารา 2, ฮิว ฮัท สระบุรี, ธราฟ้าใส 3, เดอะ ริช ทาวน์, สระบุรีบ้านสวย 5, เดอะเบสท์ ทาวน์โฮม, พาลิธี ธรา 5, บ้านพรเทพวิลล่า, สระบุรีบ้านสวย 7, สระบุรีบ้านสวย 6, ธนดารา การ์เด็นท์โฮม มวกเหล็ก-สระบุรี, เดอะกรีน 2, จรุงรัตน์ วัน (เกษมราษฎร์), สีวลี ออยุธยา 2, เดอะพิค @ เขาค้อ, ทุ่งวิลล์ ออยุธยา1, แกรนด์วิลล์ 5 สมาร์ทโฮม
เดอะ คัลเลอร์ส วงแหวน-รามอินทรา 2	ศุภาลัย เบลล่า วงแหวน-รามอินทรา	พฤษชาทาวน์ ไร่เว้ รามอินทรา 117, พฤษชาทาวน์ เบ็ญจ รามอินทรา-วงแหวนฯ, พฤษชาวิลล์ รามอินทรา-พระยาสุเรนทร์, เดอะ คัลเลอร์ส วงแหวน-รามอินทรา 2, พฤษชาวิลล์ 55/2 วงแหวน-รามอินทรา, เบ็ญจ วิลล์ รามอินทรา 117-เจริญพัฒนา 8, เดอะ นิช รามอินทรา-พระยาสุเรนทร์, พนาสนธิ์ วิลล่า (นิมิตใหม่), นลิน เรสซิเดนซ์ (หทัยราษฎร์), เบ็ญจวิลล์ รามอินทรา 117, บ้านรื่นฤดี 6 รามอินทรา-ชาฟารี, ซิตีเซนส์ รามอินทรา, ศุภาลัย เบลล่า วงแหวน-รามอินทรา, บ้านประภาพรทรัพย์ รามอินทรา-หทัยราษฎร์, เบ็ญจ วิลล์ รามอินทรา-พระยาสุเรนทร์ 25, ซัยพฤษ รามอินทรา-พระยาสุเรนทร์, แลนซีโอ วงแหวนฯ-รามอินทรา, เค.ซี.รามอินทรา 5 (พระยาสุเรนทร์), พลินี รามอินทรา-วงแหวน, เต็มสิริ แกรนด์ มินบุรี-สามวา
สิริ เพลส กัลปพฤกษ์-สาทร, เดอะ ซิตี สาทร-ราชพฤกษ์, สิริ เพลส จรัญ-ปิ่นเกล้า, บ้านกลางเมือง ราชพฤกษ์, ฮาบีเทีย ชายน ทำข้าม-พระราม 2	สิริ เพลส จรัญ-ปิ่นเกล้า	บ้านกลางเมือง ราชพฤกษ์, บ้านกลางเมือง ดิ เอโร่ ปิ่นเกล้า-จรัญฯ, พาทีโอ พระราม 5 - สิรินธร, บ้านกลางเมือง ราชพฤกษ์-พระราม 5, เซนโทร ราชพฤกษ์, เดอะ แกลเลอรี รัตนวิเบศร์-ราชพฤกษ์, คณาสิริ ปิ่นเกล้า-กาญจนา, คาซ่า วอเดอไรซ์ พระราม 5, บ้านกลางเมือง ปิ่นเกล้า-จรัญฯ, บ้านลุมพินี ทาวน์วิลล์ ราชพฤกษ์-ปิ่นเกล้า, สิริ เพลส จรัญ-ปิ่นเกล้า, เดอะ ซิตี ราชพฤกษ์, โกลเด้น ซิตี ปิ่นเกล้า-จรัญสนิทวงศ์, โลฟท์ บางกอก บูเลอวาร์ด ราชพฤกษ์-ปิ่นเกล้า, ดริมดีลักซ์ ราชพฤกษ์-ปิ่นเกล้า, คาซ่า เลเจนด์ พระราม 5-ราชพฤกษ์, บ้านกลางเมือง ราชพฤกษ์-รัตนวิเบศร์, มายด์ ปิ่นเกล้า-จรัญ, ธนาสิริ ราชพฤกษ์-ทำนมนนท์, วิลล่า พาร์ค รัตนวิเบศร์

Table 11. Examples of the proposed approach's top-15 recommendation

A.5 Top-20 Recommendation Examples

Input Sequence	Ground Truth	20-item Recommendation List
เดอะ พณา เพชรเกษม-พุทธมณฑล สาย 3, คณาสิริ ศาลายา, คาซ่า เพรสโต้ วงแหวน ปิ่นเกล้า, ดีไลท์ พุทธมณฑล-ศาลายา, วิลลาจีโอ ปิ่นเกล้า-ศาลายา, มณีนพรัตน์ 3, เดอะบาลานซ์ ศาลายา, แลนซีโอ เพชรเกษม 77, วิสคอม กรีนทาวน์ 2 (เพชรเกษม 69), บ้านฟ้ากรีนเนอร์รี่ ปิ่นเกล้า-สาย 5, เดอะไพรเวทเฮ้าส์ พุทธมณฑล สาย 3	ซีรีน เพชรเกษม	เสนาวิลล์ บรมราชชนนี-สาย 5, บ้านฟ้ากรีนเนอร์รี่ ปิ่นเกล้า-สาย 5, เดอะบาลานซ์ ศาลายา, อิมเมจ เฟส, เดอะบาลานซ์ ปิ่นเกล้า-สาย 5, บ้านฟ้าทาวน์นี่ ปิ่นเกล้า-สาย 5, โลที บางกอก บูเลอวาร์ด ปิ่นเกล้า-เพชรเกษม, ธนทอง ธารารร เฟส 2 วงแหวนปิ่นเกล้า - ถนนอักษะ (เลียบบคลองทวิวัฒนา), บางกอก บูเลอวาร์ด ปิ่นเกล้า-เพชรเกษม, ธนทอง ธารารร เฟส 1 วงแหวนปิ่นเกล้า - ถนนอักษะ (เลียบบคลองทวิวัฒนา), โมดิ วิลล่า ปิ่นเกล้า-สาย 5, อิคอนเนเจอร์ ศาลายา, เดอะ พณา เพชรเกษม-พุทธมณฑล สาย 3, พฤกษ์ลดา ปิ่นเกล้า สาย 5, บ้านทิพธนา เพชรเกษม 53, ซีรีน เพชรเกษม, เดอะ แกลเลอร์รี่ ปิ่นเกล้า-สาย 4, ดี ไอคอลล 1, เดอะ กรีนเนอร์รี่ 8 ปิ่นเกล้า-สาย 4, เดอะ แพลนท์ บางแค
บ้านลุมพินี สวนหลวง ร.9	นีโอ เดอ สยาม สวนหลวง ร.๙	คาซ่า พรีเมียม อ่อนนุช-วงแหวน, บ้านกลางเมือง สวนหลวง, เดอะ ซิตี้ พัฒนาการ, บ้านกลางเมือง ศรีนครินทร์ 2, เพอร์เฟค เฟส พัฒนาการ-ศรีนครินทร์, นารา โฮม วงแหวน-บางนา, เดอะ บัลโคนี่ โฮม อุดมสุข-เฉลิมพระเกียรติ, ขวนซัน พาร์ค อ่อนนุช-วงแหวน, ลลิล กรีนวิลล์ พระราม9-อ่อนนุช-สุวรรณภูมิ, ศุภาลัย วิลล์ อ่อนนุช-สวนหลวง, เศรษฐสิริ พัฒนาการ, พาทีโอ พัฒนาการ 38, เดอะ แพลนท์ เอสทีค พัฒนาการ, วิทู อ่อนนุช-พระราม 9, เศรษฐสิริ อ่อนนุช - ศรีนครินทร์, นีโอ เดอ สยาม สวนหลวง ร.๙, บ้านกลางเมือง THE EDITION พระราม 9-อ่อนนุช, ศุภาลัย สวนหลวง, ไอฟิล บางนา, ภัสตร เพรสทีจ ลุคซ์ พัฒนาการ
วาริโอ สุวรรณภูมิ, ศุภาลัย พรีเม่า วิลล่า พระราม 2-บางขุนเทียน, ศุภาลัย พรีเม่า วิลล่า พุทธมณฑล สาย 3, ศุภาลัย ไพรด์ บางนา-ลาดกระบัง, ศุภาลัย การ์เด็นวิลล์ ชลบุรี	ศุภาลัย การ์เด็นวิลล์ รังสิต คลอง 2	ศุภาลัย วิลล์ เพชรเกษม 69, ศุภาลัย ไพรด์ ประชาอุทิศ, ศุภาลัย การ์เด็นวิลล์ กรุงเทพมหานคร-ตึกใหม่-มอเดิร์นเวย์, ศุภาลัย พรีเม่า บางแสน, ศุภาลัย วิลล์ ชลบุรี, ศุภาลัย ไพรด์ บางนา-ลาดกระบัง, ศุภาลัย พาร์ควิลล์ ศรีราชา, ศุภาลัย การ์เด็นวิลล์ ประชาอุทิศ-สุขสวัสดิ์, ศุภาลัย ไพรด์ บางนา-วงแหวน, ศุภาลัย วิลล์ เทพารักษ์, ศุภาลัย วิลล์ อ่อนนุช-สวนหลวง, ศุภาลัย วิลล์ รามอินทรา 117, ศุภาลัย การ์เด็น วิลล์ บางแสน, ศุภาลัย พาร์ควิลล์ ประชาอุทิศ 86, เพอร์เฟค เฟส วงแหวน-รามคำแหง, ศุภาลัย การ์เด็นวิลล์ รังสิต คลอง 2, ศุภาลัย พาร์ควิลล์ 2 (พหลโยธิน-รามอินทรา กม.1), เพอร์เฟค เฟส รามคำแหง-สุวรรณภูมิ 3, อิคอนเนเจอร์ พระราม 2-เทียนทะเล, ศุภาลัย พาร์ควิลล์ แม่กรณ์-เชียงรายได้
คุณาลัย ปีกินส์, เดอะ วิลเลจ กาญจนานิกะ-ราชพฤกษ์, บ้านเต็มรัก 4 (ชัยพฤกษ์-วงแหวน), เดอะ ไพร่ม ชัยพฤกษ์-วงแหวนรอบนอก, ขวนชมพาร์ค 3, บ้านชิดลม	คุณาลัย จอย	ขวนชมพาร์ค 3, บ้านเต็มรัก 4 (ชัยพฤกษ์-วงแหวน), บ้านชิดลม, เดอะ วิลเลจ กาญจนานิกะ-ราชพฤกษ์, บ้านหงส์ประยูร 3, ไอริส พาร์ค ชัยพฤกษ์-วงแหวน, เดอะ แพลนท์ ชัยพฤกษ์-วงแหวน, อิมพีเรียล ลาгуนา, เดอะ วิลเลจ คอทเทจ กาญจนานิกะ-ราชพฤกษ์, คุณาลัย คอร์ทยาร์ด, เดอะ ริช เกต, แลนซีโอ ไพรด์ กาญจนานิกะ - คลองถนน, เดอะคัลเลอร์ส กาญจนานิกะ-ราชพฤกษ์, บ้านเต็มรัก 5 บ้านกล้วย-บางบัวทอง, บ้านพราวฟ้า รัตนาธิเบศร์-บางบัวทอง, สัมมากรอเวนิว ชัยพฤกษ์-วงแหวน, คุณาลัย พอลเลน, สัมมากร ชัยพฤกษ์-วงแหวน ราชพฤกษ์ 345, คุณาลัย จอย, เรสท์ บางใหญ่

Input Sequence	Ground Truth	20-item Recommendation List
เดอะ เพรสตัน ทาวน์โฮม พระราม 9-กรุงเทพกรีฑา, เนอวานา ดีฟายน์ ศรีนครินทร์-พระราม 9	บ้านกลางเมือง The Edition พระราม 9-กรุงเทพกรีฑา	เดอะ เพรสตัน ทาวน์โฮม พระราม 9-กรุงเทพกรีฑา, พาทีโอ ศรีนครินทร์-พระราม 9, เนอวานา ดีฟายน์ ศรีนครินทร์-พระราม 9, พฤษภาลัย พระราม 9-ศรีนครินทร์, เศรษฐสิริ ศรีนครินทร์-พระราม 9, บ้านกลางเมือง พระราม 9, เพอร์เฟค เพลส พระราม 9-กรุงเทพกรีฑา, เดอะ เมโทร รามคำแหง-วงแหวน, ทาวน์ พลัส หัวหมาก, ทาวน์ อเวนิว พระราม 9, นลิน แกรนด์ อเวนิว, ซิตีลิงก์ พระราม 9-ศรีนครินทร์, บ้านใหม่ พระราม 9 - ศรีนครินทร์, เดอะ เมโทร พระราม 9-กรุงเทพกรีฑา, เพอร์เฟค เรสซิเดนซ์ พระราม 9-กรุงเทพกรีฑา, บ้านกลางเมือง พระราม 9-กรุงเทพกรีฑา, เศรษฐสิริ กรุงเทพกรีฑา, พาทีโอ รามคำแหง-วงแหวน, แมกซิม กรีน วิลเลจ ร่มเกล้า สุวรรณภูมิ, บ้านกลางเมือง The Edition พระราม 9-กรุงเทพกรีฑา
เดอะ มิราเคิล พลัส เศรษฐกิจ-คลองครุ, บ้านพฤษภา เศรษฐกิจ-พระราม 2, เดอะมันนี่ มี ถ. เศรษฐกิจ-พุทธสาคร	เดอะมันนี่ มี บางหญ้าแพรก-พระราม 2	โลโอ บิลด์ เศรษฐกิจ-พุทธสาคร, บ้านพฤษภา เศรษฐกิจ-พระราม 2, บ้านพฤษภา พระราม 2-เอกชัย, เดอะมันนี่ มี พันธวงษ์, บ้านศิริทรัพย์ โครงการ 4-ถนนเศรษฐกิจ, บ้านพฤษภา พระราม 2 (พันท้ายนรสิงห์), เดอะ มิราเคิล พลัส เศรษฐกิจ-คลองครุ, สันสิริ บางโหนด, พฤษภาวิลลัส พุทธสาคร, บ้านสวนท่าพรายสวนส้ม-พระราม 2, ซีเค วิลลัส 5 พระราม 2-สวนส้ม, นิราวิลลัส, ณีญา พุทธสาคร (สาย 4-ตัดใหม่), บ้าน ดี บางโหนด, บ้านวันดี กม.12 พุทธสาคร สาย 4 ตัดใหม่ โครงการ 2, เดอะมันนี่ มี บางหญ้าแพรก-พระราม 2 , โนโว วิลลัส พุทธสาคร, สวนส้ม 3 พระราม 2-สวนส้ม, บ้านแลนด์ซีโอ คริป เศรษฐกิจ-พุทธสาคร, นิราวิลลัส ไอริช

Table 12. Examples of the proposed approach's top-20 recommendation

A.6 Missed Recommendation Examples

Input Sequence	Ground Truth	20-item Recommendation List
สกาย ดอนเมือง-สรงประภา, เดอะริคค์ ทาวน์ วัชรพล, แอปป์ วิลลัส ดอนเมือง, มิลตัน เรสซิเดนซ์ รามอินทรา, คิว ดิสทริค เวสต์เกต, รีเจนท์ โฮม 15 แจ้งวัฒนะ	ลุมพินี พาร์ค วิวาวดี-จตุจักร	กัสโต้ ดอนเมือง-สรงประภา, แอปป์ วิลลัส ดอนเมือง, พาทีโอ วิวาวดี-สรงประภา, เดอะ คอนเนคท์ หลีกสี-ดอนเมือง, คาซ่าซีตี้ ดอนเมือง-ศรีสมาน, คาซ่า เพรสโต้ ดอนเมือง-สรงประภา, คาซ่า ซีตี้ ดอนเมือง, เดอะ แพลนท์ เอ็กซ์คลูซีฟ สรงประภา-แจ้งวัฒนะ, เศรษฐินทาวน์ วิวาวดี, สกาย ดอนเมือง-สรงประภา, คาซ่า วิลลัส ดอนเมือง-สรงประภา, ซินเนอร์รี่ แจ้งวัฒนะ-สรงประภา, แอปป์ วิลลัส ดอนเมือง เฟส 2 , ดี เอ็กซ์คลูซีฟ วงแหวน-รามอินทรา, ดี เอ็กซ์คลูซีฟ แจ้งวัฒนะ-ติวานนท์, โชคประชา ทาวน์โฮม, ศุภาลัย เบลล่า วงแหวน-รามอินทรา , พลัสโน้ พหลโยธิน-วัชรพล, พฤษภาวิลลัส 64 สายใหม่, ลีรี เพลส ติวานนท์
ลิลิตทาวน์ โลโอ ลำลูกกาคลอง 4-5	ไอลิฟ พาร์ค วงแหวน-รังสิตคลอง 4	เดอะ แพลนท์ รังสิต คลอง 4-วงแหวน, เดอะ วิลเลจ รังสิต-วงแหวนฯ, คณาสิริ วงแหวน - ลำลูกกา, ศุภาลัย เบลล่า วงแหวน-ลำลูกกา คลอง 4, บ้านฟ้าปี่ยมย์ เทนโดร ทางด่วนวงแหวน-ลำลูกกา คลอง 6, ศุภาลัย วิลลัส วงแหวน - ลำลูกกา คลอง 3, เนซอรั่า เทรนด์ วงแหวน-ลำลูกกา คลอง 5, ลิลิต ทาวน์ แลนด์ซีโอ คริป วงแหวนฯ-ลำลูกกา คลอง 6 , ศุภาลัย วิลลัส วงแหวน-ลำลูกกา คลอง 5, เดอะ แพลนท์ รังสิต-คลอง 3, เดอะ แพลนท์ วงแหวน-รังสิต, เดอะ คอนเนคท์ @รังสิต, บ้านพฤษภา ลำลูกกา-วงแหวนฯ, ศุภาลัย เบลล่า วงแหวน-ลำลูกกา คลอง 6, เดอะคิวิบ์ ทาวน์ ลำลูกกา, บ้านพฤษภา ไพร่ม วงแหวน-ลำลูกกา 5, โมดี วิลล่า รังสิต คลอง 7, แพรมาพร รังสิต คลอง 7 ลำลูกกา, ลิลิตทาวน์ โลโอ ลำลูกกา คลอง 4-5, บ้านมณฑาทันต์ รังสิต ลำลูกกา คลอง 4

Input Sequence	Ground Truth	20-item Recommendation List
เบลีสทาวน์ ศรีนครินทร์-หนามแดง, ศุภาลย์ เบล ล่า เทพารักษ์	ธัญดา พลัส วงแหวน า-เทพารักษ์	เบลีสทาวน์ ศรีนครินทร์-หนามแดง, ศุภาลย์ วิลล์ เทพารักษ์, เดอะ แพลนท์ ศรี นครินทร์-หนามแดง, เดอะ แพลนท์ เทพารักษ์-บางนา, บริทาเนีย ศรีนครินทร์, ภัสสร ไพร์ด ศรีนครินทร์-หนามแดง, คาซ่าวิลล์ บางนา-เทพารักษ์, ภัสสร เทพารักษ์-บางนา, สุรียา เพอร์เฟค, บ้านบุรีรัมย์ The Innovation เทพารักษ์ - สุวรรณภูมิ, เดอะ แพลนท์ เทพารักษ์, ดีไลฟ์ บางนา-ศรีนครินทร์, บ้านริมสวน ซี นเนอร์, บริทาเนีย เมกะทาวน์ บางนา, ภัสสร ไพร์ด ศรีนครินทร์-เทพารักษ์, เดอะทรัสต์ สุวรรณภูมิ เทพารักษ์, บ้านลิลลี่ อินเดอะพาร์ค วงแหวนฯ-เทพารักษ์ (ชอมังกร), เอโกล มัลดีพี บีช ศรีนครินทร์-วงแหวน, ชัยพฤกษ์ ศรีนครินทร์, ศุ ภาลย์ การ์เด็นวิลล์ ศรีนครินทร์-บางนา
ลุมพินี วิลล์ สุขสวัสดิ์-พระราม 2	โมเดิร์น คอนโด เดอะ ฟอเรสต์	ลุมพินี วิลล์ สุขสวัสดิ์-พระราม 2, โพลิส คอนโด สุขสวัสดิ์ 64, นิช ไอดี พระราม 2-ดาวคะนอง, ยูนิโอ พระราม 2-ท่าข้าม, พรีเมียม คอนโดมิเนียม เอกชัย 32, อิช ซี คอนโด สุขสวัสดิ์, พลัมคอนโด เอ็กซ์ตรา พระราม 2, ลุมพินี วิลล์ ราษฎร์ บูรณะ-ริเวอร์วิว 2, นิช ไอดี พระราม 2, เซอราโน คอนโดมิเนียม, เดอะ เบลล่า คอนโด พระราม 2, แอสปาย สาทร-ตากสิน (คอปเปอร์ โซน), เมโทร สกาย ฎุภา ภาค, ลุมพินี วิลล์ พัฒนาการ-ศรีนครินทร์, ลุมพินี พาร์ค บรมราชชนนี-สิรินธร, รี เจนท์ ออร์คิด ตลาดพลู, วิสซ์คอม สเตชั่น รัชดา-ท่าพระ, อีส 2 พระราม 2, เดอะไพร์เวจี้ ประชาอุทิศ-สุขสวัสดิ์, นิช ไอดี เพชรเกษม-บางแค
บ้านพฤกษา กาญจนฯ-กันตนา, ดีไลฟ์ พุท มณฑล-ศาลายา, โมติ วิลล่า ปิ่นเกล้า-วงแหวน, บ้านพฤกษา กาญจนฯ-กันตนา, แลนซีโอ ครีป ปิ่นเกล้า - วงแหวน, มณีนีพรัตน์ 3, บ้านพฤกษา ปิ่นเกล้า-วงแหวนฯ, บ้านพฤกษา กาญจนฯ-กันต นา	ศิวาลัย 3 บางไผ่	เดอะ คอนเนค กาญจนฯ-กันตนา, บ้านพฤกษา ไพรม์ ช.กันตนา-วงแหวนฯ, บ้าน โลโอ นอฟ วงแหวนฯ-ปิ่นเกล้า (ช.พระนอน), พฤกษาไลฟ์ ลีอกซ์ ปิ่นเกล้า- วงแหวน, บ้านพฤกษา กาญจนฯ-กันตนา, เดอะ แพลนท์ ทางด่วนศรีรัช-วัดพระ เงิน, พฤกษาไลฟ์ รัตนาธิเบศร์, นนทบุรี บางใหญ่ 2, เดอะ แพลนท์ ริสอร์ท พระราม 5-กาญจนฯ-เกษก, พฤกษาวิลล์ 33 ปิ่นเกล้า-วงแหวน-2, บ้านมณฑล 5 กันตนา - พระราม 5, บ้านพฤกษา วงแหวน-ปิ่นเกล้า, ภัสสร ไพร์ด ปิ่นเกล้า-วง แหวน, คณาสิริ วงแหวน พระราม 5, พฤกษาวิลล์ 72 นครินทร์-พระเงิน, โมติ วิลล่า ปิ่นเกล้า-วงแหวน, วิลเลต ไลฟ์ รัตนาธิเบศร์, บ้านพฤกษา 98 ช.แก้ว อินทร์-บางใหญ่, แลนซีโอ ครีป รัตนาธิเบศร์-บางใหญ่ (แก้วอินทร์), แลนซีโอ ครีป ปิ่นเกล้า - วงแหวน
เดอะ ซิตี ปิ่นเกล้า-บรมฯ, 23 องศา วิลล่า, แมกโน เลียส เฟรนซ์ คันทรี่ เขาใหญ่	นิยาม บรมราชชนนี	เดอะ ซิตี ปิ่นเกล้า-บรมฯ, นาราสิริ โทเพียร์ นวมินทร์, เศรษฐสิริ พัฒนาการ, ภัสสร สรประภา, เดอะ ซิตี พัฒนาการ, เดอะ ซิตี นวมินทร์, อาร์เทล เกษตร- นวมินทร์, เดอะ ซิตี สาทร-ราชพฤกษ์, เศรษฐสิริ ปิ่นเกล้า-กาญจนฯ-เกษก, บางกอก บูเลอวาร์ด ซิกเนเจอร์ สาทร-ราชพฤกษ์, เศรษฐสิริ พหล-วัชรพล, เดอะ พลาซ่า รัชฎ์สนิหวงค์-ราชพฤกษ์, บุราสิริ วัชรพล, เดอะ ซิตี รามอินทรา, บุรา สิริ พัฒนาการ, เซนโพร รามอินทรา-จตุโชติ, มิลตัน เรสซิเดนซ์ รามอินทรา, เศรษฐสิริ กรุงเทพมหานคร, บ้านกลางเมือง คลาสเซ่ เอกมัย-รามอินทรา, เดอะ ซิตี ปิ่นเกล้า-สาย 4

Table 13. Examples of the proposed approach's missed recommendation

REFERENCES

- [1] J. Wei, J. He, K. Chen, Y. Zhou, and Z. Tang, "Collaborative filtering and deep learning based recommendation system for cold start items," *Expert Systems with Applications*, vol. 69, pp. 29-39, 2017.
- [2] R. Ariyawansa, "An empirical study of consumer behavior in housing market in Colombo," *Built-Environment Sri Lanka*, vol. 8, no. 1, 2010.
- [3] J. Chia, A. Harun, A. W. M. Kassim, D. Martin, and N. Kepal, "Understanding factors that influence house purchase intention among consumers in Kota Kinabalu: an application of buyer behavior model theory," *Journal of Technology Management and Business*, vol. 3, no. 2, 2016.
- [4] J. S. Mang, R. Zainal, and I. S. M. Radzuan, "Influence of location on home buyers' purchase decision," in *AIP Conference Proceedings*, 2018, vol. 2016, no. 1: AIP Publishing LLC, p. 020078.
- [5] M. Silva and N. Fraser, "Analysis of impact of Property Attributes on Buyer Behaviour in Luxury Condominium Apartments Market in Colombo, Sri Lanka," *B. Sc.(Special) Estate Management and Valuation Degree Programme*, p. 152, 2016.
- [6] F. Pan, S. Li, X. Ao, P. Tang, and Q. He, "Warm up cold-start advertisements: Improving ctr predictions via learning to learn id embeddings," in *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2019, pp. 695-704.
- [7] M. Vartak, A. Thiagarajan, C. Miranda, J. Bratman, and H. Larochelle, "A meta-learning perspective on cold-start recommendations for items," 2017.
- [8] P. Lops, M. De Gemmis, and G. Semeraro, "Content-based recommender systems: State of the art and trends," *Recommender systems handbook*, pp. 73-105, 2011.
- [9] B. Hidasi, A. Karatzoglou, L. Baltrunas, and D. Tikk, "Session-based recommendations with recurrent neural networks," *arXiv preprint arXiv:1511.06939*, 2015.

- [10] G. Adomavicius and A. Tuzhilin, "Context-aware recommender systems," in *Recommender systems handbook*: Springer, 2011, pp. 217-253.
- [11] X. Yuan, J.-H. Lee, S.-J. Kim, and Y.-H. Kim, "Toward a user-oriented recommendation system for real estate websites," *Information Systems*, vol. 38, no. 2, pp. 231-243, 2013.
- [12] Y. Yu, C. Wang, L. Zhang, R. Gao, and H. Wang, "Geographical proximity boosted recommendation algorithms for real estate," in *International Conference on Web Information Systems Engineering*, 2018: Springer, pp. 51-66.
- [13] R. Pan *et al.*, "One-class collaborative filtering," in *2008 Eighth IEEE International Conference on Data Mining*, 2008: IEEE, pp. 502-511.
- [14] T. Badriyah, S. Azvy, W. Yuwono, and I. Syarif, "Recommendation system for property search using content based filtering method," in *2018 International conference on information and communications technology (ICOIACT)*, 2018: IEEE, pp. 25-29.
- [15] J. Knoll, R. Groß, A. Schwanke, B. Rinn, and M. Schreyer, "Applying recommender approaches to the real estate e-commerce market," in *International Conference on Innovations for Community Services*, 2018: Springer, pp. 111-126.
- [16] X. He, L. Liao, H. Zhang, L. Nie, X. Hu, and T.-S. Chua, "Neural collaborative filtering," in *Proceedings of the 26th international conference on world wide web*, 2017, pp. 173-182.
- [17] S. Zhang, L. Yao, A. Sun, and Y. Tay, "Deep learning based recommender system: A survey and new perspectives," *ACM Computing Surveys (CSUR)*, vol. 52, no. 1, pp. 1-38, 2019.
- [18] K. Cho, B. Van Merriënboer, D. Bahdanau, and Y. Bengio, "On the properties of neural machine translation: Encoder-decoder approaches," *arXiv preprint arXiv:1409.1259*, 2014.
- [19] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [20] B. Hidasi, M. Quadrana, A. Karatzoglou, and D. Tikk, "Parallel recurrent neural network architectures for feature-rich session-based recommendations," in

- Proceedings of the 10th ACM conference on recommender systems*, 2016, pp. 241-248.
- [21] J. Li, P. Ren, Z. Chen, Z. Ren, T. Lian, and J. Ma, "Neural attentive session-based recommendation," in *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, 2017, pp. 1419-1428.
- [22] Q. Liu, Y. Zeng, R. Mokhosi, and H. Zhang, "STAMP: short-term attention/memory priority model for session-based recommendation," in *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2018, pp. 1831-1839.
- [23] A. Beutel *et al.*, "Latent cross: Making use of context in recurrent recommender systems," in *Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining*, 2018, pp. 46-54.
- [24] C. Bakir, "Collaborative filtering with temporal dynamics with using singular value decomposition," *Tehnički vjesnik*, vol. 25, no. 1, pp. 130-135, 2018.
- [25] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, P.-A. Manzagol, and L. Bottou, "Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion," *Journal of machine learning research*, vol. 11, no. 12, 2010.
- [26] H. Setiadi, R. Saptono, R. Anggrainingsih, and R. Andriani, "Recommendation Feature of Scientific Articles on Open Journal System Using Content-based Filtering," in *2019 IEEE 6th International Conference on Engineering Technologies and Applied Sciences (ICETAS)*, 2019: IEEE, pp. 1-6.
- [27] T. Luostarinen and O. Kohonen, "Using topic models in content-based news recommender systems," in *Proceedings of the 19th Nordic conference of computational linguistics (NODALIDA 2013)*, 2013, pp. 239-251.
- [28] D. M. Blei, A. Y. Ng, and M. I. Jordan, "Latent dirichlet allocation," *the Journal of machine Learning research*, vol. 3, pp. 993-1022, 2003.
- [29] Y. Deldjoo *et al.*, "Movie genome: alleviating new item cold start in movie recommendation," *User Modeling and User-Adapted Interaction*, vol. 29, no. 2, pp. 291-343, 2019.
- [30] Y. K. Tan, X. Xu, and Y. Liu, "Improved recurrent neural networks for session-

based recommendations," in *Proceedings of the 1st workshop on deep learning for recommender systems*, 2016, pp. 17-22.

- [31] Y. Hu, Y. Koren, and C. Volinsky, "Collaborative filtering for implicit feedback datasets," in *2008 Eighth IEEE International Conference on Data Mining, 2008: IEEE*, pp. 263-272.
- [32] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [33] B. Sarwar, G. Karypis, J. Konstan, and J. Riedl, "Item-based collaborative filtering recommendation algorithms," in *Proceedings of the 10th international conference on World Wide Web*, 2001, pp. 285-295.





จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

VITA

NAME Jirut Polohakul

DATE OF BIRTH 3 March 1996

PLACE OF BIRTH Bangkok

INSTITUTIONS ATTENDED Computer Engineering, Chulalongkorn University

HOME ADDRESS 18/252 Q.house condo sathorn, Krung thonburi rd., Khlong ton sai, Khlong san, Bangkok 10600

PUBLICATION J. Polohakul, E. Chuangsuwanich, A. Suchato and P. Punyabukkana, "Real Estate Recommendation Approach for Solving the Item Cold-Start Problem," in IEEE Access, vol. 9, pp. 68139-68150, 2021, doi: 10.1109/ACCESS.2021.3077564.