

# HỆ THỐNG GỢI Ý PHIM KẾT HỢP MÔ HÌNH PHÂN RÃ MA TRẬN SÂU VÀ LỌC THEO NỘI DUNG MOVIE RECOMMENDER SYSTEM COMBINE DEEP MATRIX FACTORIZATION AND CONTENT-BASED FILTERING

NGUYỄN HỒNG PHƯƠNG<sup>1,a</sup>, NGUYỄN THÁI NGHE<sup>2</sup>

<sup>1</sup>Trường Đại học Sư phạm Kỹ thuật Vĩnh Long

<sup>2</sup>Đại học Cần Thơ

<sup>a</sup>Tác giả liên hệ: [phuongnh@vlute.edu.vn](mailto:phuongnh@vlute.edu.vn)

Nhận bài (Received): 16/12/2023; Phân biệt (Reviewed): 14/03/2024; Chấp nhận (Accepted): 25/03/2024

## TÓM TẮT

Ngày nay các nhà cung cấp nội dung đang muốn thu hút số lượng người dùng một cách tối đa bằng cách giới thiệu nội dung mà người dùng mong muốn theo sở thích cá nhân chính vì thế hệ thống gợi ý luôn là đối tượng trọng điểm được quan tâm đến. Trong bài báo này chúng tôi đề xuất một hệ thống kết hợp nhằm tăng cường hiệu suất gợi ý. Đầu tiên, chúng tôi tạo ma trận TF-IDF từ những đánh giá của người dùng và nội dung của bộ phim tạo nên ma trận đầu vào. Sau đó, các vector tiềm ẩn được tạo ra bằng các lớp nhúng. Các vector mang đặc trưng của người dùng và phim này sẽ qua lớp nổi và đi vào hệ thống mạng MLP (Multi Layer Perceptron) với H lớp ẩn. Sau đó chúng tôi sử dụng mô hình học sâu để tìm mối liên hệ giữa người dùng và sản phẩm. Cuối cùng chúng tôi sử dụng độ đo RMSE và MAE để đánh giá mức độ hiệu quả của mô hình. Kết quả thực nghiệm cho thấy mô hình đạt 0.9247 RMSE, 0.7047MAE với tập dữ liệu Netflix Prize và 0.9823 RMSE, 0.7552 MAE với tập dữ liệu Movie Lens.

**Từ khóa:** hệ thống gợi ý phim, lọc theo nội dung, phân rã ma trận sâu.

## ABSTRACT

Nowadays, content providers want to attract the maximum number of users by introducing content that users want according to personal preferences, so recommendation systems are always a key target interested in. In this paper we propose a hybrid system to enhance recommendation performance. First, we create the TF-IDF matrix from the user reviews and the content of the movie that forms the input matrix. Then, the hidden vectors are generated using embedding layers. These vectors carrying the characteristics of the user and the movie will pass through the concatenate layer and enter the MLP (Multi Layer Perceptron) network system with H hidden layers. Then we use a deep learning model to find relationships between users and items. Finally, we use RMSE and MAE measures to evaluate the effectiveness of the model. Experimental results show that the model achieves 0.9247 RMSE, 0.7047MAE with the Netflix Prize data set and 0.9823 RMSE, 0.7552 MAE with the Movie Lens data set.

**Keywords:** movie recommendation system, content-based filtering, deep matrix factorization.

## 1. GIỚI THIỆU

Hệ thống gợi ý thông tin (Recommender System – RS) là một trong những ứng dụng phổ biến nhất của khoa học dữ liệu ngày nay. Chúng được sử dụng để dự đoán sở thích (preferences) hay xếp hạng (rating) mà người dùng có thể dành cho một mục thông tin (item) nào đó mà họ chưa xem xét tới trong quá khứ (item có thể là bài hát, bộ phim, đoạn video clip, sách, bài báo,..) [1]. Hầu hết mọi công ty công nghệ lớn đều đã áp dụng chúng dưới một số hình thức.

- Amazon sử dụng nó để đề xuất sản phẩm cho khách hàng
- Netflix sử dụng gợi ý phim cho người dùng
- YouTube sử dụng nó để đề xuất các video và quyết định video sẽ phát tiếp theo trên chế độ tự động phát
- Facebook sử dụng nó để gợi ý kết bạn, đề xuất các trang để thích và mọi người theo dõi.

Trong bài báo này, chúng tôi đề xuất một phương pháp lai sử dụng cả kỹ thuật phân rã ma trận sâu và lọc theo nội dung cho bài toán gợi ý phim với phần nhúng ID người dùng và ID phim là đầu vào kết hợp với các tính năng tiềm ẩn từ MLP của phân rã ma trận sâu.

Những đóng góp chính của bài báo này như sau:

Chúng tôi sử dụng TF-IDF để chuyển đổi mô tả ngắn của tất cả các bộ phim thành một vector thưa thớt. Mô hình sẽ học cách giảm kích thước của vector này và kết hợp siêu dữ liệu bằng việc nhúng id người dùng và id phim vào vector này trở thành vector đầu vào. Kết hợp với MLP mạng lưới thần kinh ánh xạ người dùng và vật phẩm vào một không gian có chiều thấp phi tuyến tính.

## 2. NỘI DUNG

### 2.1 Các nghiên cứu liên quan:

Có hai phương pháp được sử dụng phổ biến trong các hệ thống gợi ý đó là: lọc dựa trên nội dung (Content-based Filtering) và lọc cộng tác (Collaborative Filtering)

#### Lọc dựa trên nội dung (Content-based Filtering):

Hệ thống gợi ý này đề xuất cho người dùng các mặt hàng tương tự dựa trên một mặt hàng cụ thể. Phương pháp này dựa vào dữ liệu về sản phẩm người người dùng đã cung cấp hay còn gọi là siêu dữ liệu, chẳng hạn như thể loại, đạo diễn, mô tả, diễn viên, v.v. cho phim, để đưa ra các đề xuất này. Ý tưởng chung đằng sau các hệ thống giới thiệu này là nếu một người thích một mặt hàng cụ thể, họ cũng sẽ thích một mặt hàng tương tự với nó [2]. Một ví dụ điển hình có thể là YouTube, nơi dựa trên lịch sử của bạn, nó gợi ý cho bạn những video mới mà bạn có thể xem tiếp dựa trên nền những video bạn đã xem.

#### Lọc cộng tác (Collaborative Filtering):

Các mô hình dựa trên kỹ thuật này dựa vào sức mạnh cộng tác của xếp hạng do người dùng cung cấp. Thách thức chính trong việc xây dựng các mô hình này là ma trận xếp hạng đang thưa thớt. Các phương pháp lọc cộng tác dự đoán xếp hạng không xác định dựa trên xếp hạng được quan sát vì chúng thường có mối tương quan cao giữa những người dùng và mặt hàng khác nhau. Lọc cộng tác phân tích dữ liệu người dùng để tìm ra mối tương quan giữa các đối tượng người dùng và thực hiện gợi ý các sản phẩm dịch vụ, nội dung dựa trên mối quan tâm, sở thích của người dùng tương tự đối với các sản phẩm, dịch vụ hay nội dung đó.

Trong nhóm này các giải thuật chủ

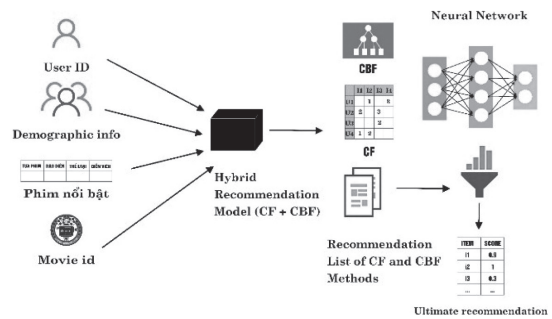
yếu sử dụng là phương pháp láng giềng (memory-based) trong đó hoặc là dựa trên dữ liệu quá khứ của người dùng, trong đó hoặc là dựa trên dữ liệu quá khứ của người dùng “tương tự - similarity” (user-based approach), hoặc là dựa trên dữ liệu quá khứ của những item “tương tự” (item-based approach) hoặc dựa trên mô hình (Model-based): Nhóm này liên quan đến việc xây dựng các mô hình dự đoán dựa trên dữ liệu thu thập được trong quá khứ. Như mô hình Bayesian, các mô hình nhân tố tiềm ẩn (latent factor models): trong đó kỹ thuật phân rã ma trận (Matrix Factorization) [3] là một điển hình. Phương pháp này dựa vào user – item tương tác, tương tác này có thể biểu diễn hoặc mô hình hóa như sản phẩm bên trong của các vector tiềm ẩn.

#### **Lọc cộng tác kết hợp với lọc theo nội dung:**

Các hệ thống đề xuất kết hợp hai hoặc nhiều phương pháp đề xuất để cải thiện hiệu suất đồng thời giảm thiểu nhược điểm của từng phương pháp riêng biệt. Thông thường nhất, lọc cộng tác được sử dụng kết hợp với một kỹ thuật khác nhằm nỗ lực giải quyết vấn đề tăng tốc [4].

Lọc cộng tác kết hợp với lọc trên nội dung là kỹ thuật kết hợp các thuộc tính mục và tùy chọn của người dùng để tạo đề xuất. Lọc dựa trên nội dung tập trung vào tính tương tự của mục, trong khi lọc cộng tác xem xét hành vi của người dùng [5]. Đây là sự kết hợp của cả hai phương pháp nhằm giảm thiểu nhược điểm của từng kỹ thuật và tạo ra các đề xuất tốt hơn cho người dùng.

Bên cạnh đó kết hợp với phân rã ma trận nhằm giải quyết vấn đề “Cold Start” bằng cách tận dụng sự tương tác giữa người dùng và yếu tố tiềm ẩn.



**Hình 1: Mô hình hệ thống gợi ý kết hợp DMF và CBF**

CBF chủ yếu dựa trên sự so sánh giữa thông tin hỗ trợ của người dùng và vật phẩm trong khi phương pháp CF chỉ sử dụng tương tác giữa người dùng và vật phẩm. Văn bản, hình ảnh và video có thể được coi là nhiều loại thông tin bổ sung [6]. Trong vài năm gần đây, nhiều nỗ lực nghiên cứu đã được thực hiện để cải thiện hiệu suất đề xuất bằng cách sử dụng thông tin phụ trợ và kỹ thuật học sâu đã trở nên quan trọng để xử lý một lượng lớn thông tin.

Đã có rất nhiều phương pháp tiếp cận lai được đề xuất bằng cách kết hợp các phương pháp cộng tác và dựa trên nội dung [7]. Cách tiếp cận kết hợp có thể được triển khai theo nhiều cách khác nhau, chẳng hạn như áp dụng các nhiệm vụ dựa trên nội dung và cộng tác riêng biệt cũng như kết hợp các dự đoán của chúng, kết hợp một số thuộc tính dựa trên nội dung thành cách tiếp cận hợp tác hoặc ngược lại và cuối cùng là xây dựng một mô hình hỗn hợp chung kết hợp giữa cộng tác và nội dung.

Gần đây, Deep Learning (DL) đã được những thành công to lớn khi tận dụng mạng lưới thần kinh sâu để tạo ra những kết quả đề xuất tốt hơn. DL đã được sử dụng để lập mô hình người dùng và các mục thuộc tính là đầu vào của mạng lưới thần kinh sâu [8].

Trong bài báo này, chúng tôi kết hợp lọc theo nội dung và phân rã ma trận sâu

để tạo nên một hệ thống hybrid nhằm tạo ra một phương pháp đề xuất tốt hơn cho người dùng.

## 2.2 Phương pháp nghiên cứu:

### TF-IDF

Các thuật toán học máy theo truyền thống sẽ hoạt động tốt hơn với các con số thì thuật toán TF-IDF giúp chúng giải mã các từ bằng cách phân bổ cho chúng một giá trị số hoặc vector. Điều này đã mang tính cách mạng cho học máy, đặc biệt là trong các lĩnh vực liên quan đến phân tích ngôn ngữ tự nhiên (Natural Language Processing - NLP) như phân tích văn bản.

Trong phân tích văn bản bằng máy học, thuật toán TF-IDF giúp sắp xếp dữ liệu thành các danh mục cũng như trích xuất từ khóa. Điều này có nghĩa là các tác vụ đơn giản, đơn điệu như gắn thẻ hỗ trợ hoặc phản hồi và nhập dữ liệu có thể được thực hiện trong vài giây. Vector hóa văn bản biến văn bản trong tài liệu thành số, do đó, thuật toán TF-IDF có thể xếp hạng các bài viết theo thứ tự liên quan.

Trong bài báo này chúng tôi sẽ dùng TF-IDF để chuyển đổi mô tả ngắn của tất cả các bộ phim thành một vector thưa thớt. Mô hình sẽ học cách giảm kích thước của vector này và cách kết hợp siêu dữ liệu với việc nhúng id người dùng và id phim.

$$w_{i,j} = tf_{i,j} * idf_i \quad (1.1)$$

*Phương trình TF-IDF*

### Lớp nhúng Embedding

Embedding là quá trình chuyển đổi đưa một vector có số chiều lớn thường ở dạng thưa về một vector có số chiều nhỏ thường ở dạng dày đặc. Đây là quá trình ánh xạ vector thưa có số chiều lớn vào một không gian vector có số chiều

thấp hơn nhưng dày đặc hơn và bảo toàn các mối quan hệ ngữ nghĩa trong dữ liệu ban đầu.

- Id người dùng (Users) và id phim (Movies) được chuyển đổi thành embedding đầu vào.

- Embedding chuyển đổi các giá trị này thành không gian vector.

- Kích thước lớp nhúng được xác định bởi kích thước của K

- Vector người dùng được embedding và tổ hợp vector phim và ma trận xếp hạng dự đoán được tạo.


- Embedding giúp biểu diễn ma trận ở kích thước nhỏ mà không làm mất đi tính năng của ma trận thực tế

### Lớp nối (Concatenate layer)

Phía sau lớp nhúng là lớp nối làm nhiệm vụ nối các vector ẩn. Các vector ẩn được nối lại với nhau tạo thành vector có đặc tính mới phục vụ cho các thuật toán tiếp theo. Tạo thành vector đầu vào duy nhất cho mạng nơ ron nhiều lớp MLP phía sau.

### Phân rã ma trận sâu:

Mô hình phân rã ma trận sâu sử dụng máy học để tối ưu hóa mục tiêu. MLP (Multi Layer Perceptron) là một loại mạng nơ ron nhân tạo đóng vai trò là trọng số [9]. Các thuộc tính của User và Item được tích hợp bằng lớp nối (Concatenate). Mỗi lớp ẩn sẽ trích xuất các tri thức tiềm ẩn trong mối quan hệ giữa người dùng và phim dùng để dự đoán kết quả đầu ra. Cuối cùng ở lớp đầu ra sẽ dự đoán kết quả xếp hạng của bộ phim tương ứng với người dùng. Và hàm GELU và hàm Swish được sử dụng làm hàm kích hoạt trong mô hình.



Hình 2: Mô hình Multi Layer Perceptron

### 3. MÔ HÌNH ĐỀ XUẤT

#### 3.1. Tập dữ liệu:

Trong bài báo này, chúng tôi sử dụng 2 bộ dữ liệu để thực nghiệm:

Bộ dữ liệu Netflix Prize là bộ dữ liệu đã mang về giải thưởng 1.000.000 USD cho đội Pragmatic Chaos của BellKor [10]. Tập dữ liệu bao gồm hơn 100 triệu xếp hạng (các bộ phim được xếp hạng trên một thang đo từ 1 đến 5 sao) từ hơn 480 nghìn người dùng Netflix được chọn ngẫu nhiên trên 17 nghìn tựa phim. Các dữ liệu được thu thập từ tháng 10 năm 1998 đến tháng 12 năm 2005 phản ánh tất cả các xếp hạng nhận được trong giai đoạn này.

Và bộ dữ liệu Movie Lens 30M chứa 33.832.162 xếp hạng và 2.328.315 ứng dụng thẻ trên 86.537 phim. Những dữ liệu này được tạo bởi 330.975 người dùng trong khoảng thời gian từ ngày 09 tháng 1 năm 1995 đến ngày 20 tháng 7 năm 2023. Tập dữ liệu này được tạo vào ngày 20 tháng 7 năm 2023. Đây là bộ dữ liệu mới nhất của Movie Lens được phát hành.

Tiếp theo, chúng tôi sẽ chia dữ liệu thành các bộ đào tạo và thử nghiệm để chúng tôi có thể đánh giá hiệu suất mô hình một cách hiệu quả. Bài báo chia tập dữ liệu theo phương pháp Train – Validation – Test

với tỷ lệ 80% sử dụng cho huấn luyện và 20% cho kiểm tra thuật toán.

Trong bài báo chúng tôi chỉ tập trung vào các trường userID, itemID và rating để dùng cho hệ thống gợi ý.

#### 3.2. Phương pháp đánh giá:

Có nhiều phương pháp được sử dụng để đánh giá như F-Measure, AUC, ... Mỗi phương pháp sẽ thích hợp cho từng lĩnh vực cụ thể. Trong bài báo này, độ đo RMSE (Root Mean Squared Error) và MAE (Mean Absolute Error) là độ đo được sử dụng.

$$RMSE = \sqrt{\frac{1}{|D^{test}|} \sum_{u,i,r \in D^{test}} (r_{ui} - \hat{r}_{ui})^2} \quad (1.2)$$

$$MAE = \frac{1}{|D^{test}|} \sum_{u,i,r \in D^{test}} |r_{ui} - \hat{r}_{ui}| \quad (1.3)$$

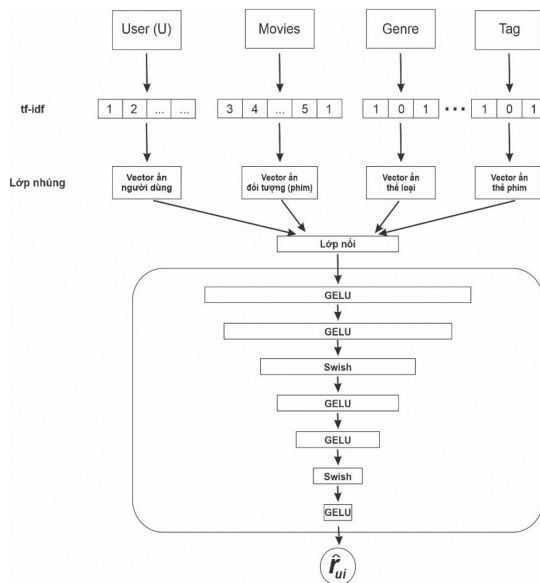
*Công thức các độ đo*

#### 4. Mô hình và kết quả:

Mô hình của chúng tôi được triển khai trên Keras. Chúng tôi đã kết hợp phân rã ma trận sâu với lọc theo nội dung cho hồ sơ của người dùng và phim nhằm giảm tác động của vấn đề người dùng mới (Cold Start Problem) cũng như tận dụng được những mẫu tiềm năng trong nội dung để đạt được những kết quả tốt hơn [11].

Trước tiên chúng tôi sử dụng phương pháp Lọc theo nội dung để tạo ra ma trận TF-IDF bằng cách cho mô hình tạo thành ma trận mang id của người dùng và phim từ dữ liệu đầu vào, sau đó bổ sung vào ma trận này thông tin của siêu dữ liệu (metadata) tạo thành ma trận mang giá trị Id người dùng, Id phim và Rating làm ma trận đầu vào. Sau đó, mô hình sẽ chuyển đổi ma trận này thành vector thưa thớt đầu vào. Lớp nhúng (Embedding) sẽ làm nhiệm vụ tiếp theo là đưa vector ở dạng thưa này về dạng dày đặc và sau đó chúng sẽ được kết hợp lại với nhau thành một vector thông qua lớp ghép (Concatenate).

Sau đó chúng tôi xây dựng lại ma trận thông qua mô hình máy học để tối ưu hóa hàm mục tiêu. Ngoài ra, các tham số mô hình đã được kích hoạt bằng cách sử dụng hàm GELU (Gaussian Error Linear Unit) và Swish là hàm kích hoạt đối với các lớp ẩn của mạng nơ ron nhân tạo. Chúng tôi cũng sử dụng hàm mất mát (loss) ‘mse’ và hàm tối ưu (optimizer) ‘adam’ cho mô hình của mình. Số lượng hệ số tiềm ẩn là 7 lớp gồm: 512 (gelu) – 256 (gelu) – 128 (swish) – 64(gelu) – 32 (gelu) – 16 (swish) – 8 (gelu) để thu được các tính năng tiềm ẩn từ việc nhúng ID. Đối với DNN, kích thước đầu ra của lớp nhúng để nhúng ID đã được chọn là 64 và 128. Đồng thời tốc độ học tập được áp dụng với 0,0001 và 0,001 cho trình tối ưu hóa Adam.

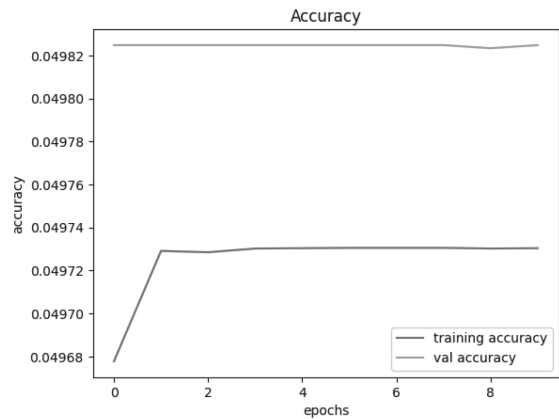


Hình 3: Mô hình hệ thống gợi ý kết hợp CBF và DMF


### 5. Kết quả thực nghiệm

#### Bộ dữ liệu Netflix Prize

Độ đo RMSE đạt: 0.9247 và MAE đạt: 0.7047



Hình 4: Training accuracy và Val accuracy



Hình 5: Training loss và Validation loss

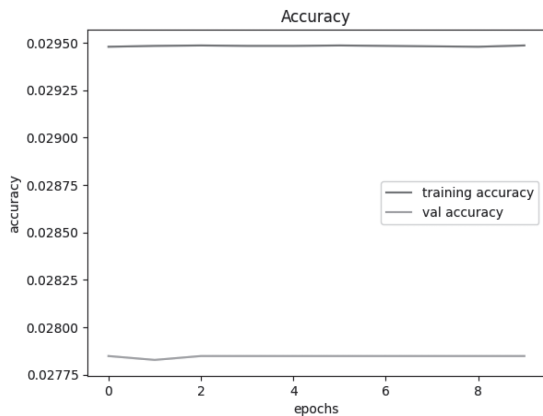
So sánh với một số mô hình khác như: User-kNN, MF và DMF trên độ đo RMSE và MAE được thống kê theo bảng sau:

	Phương pháp				
	Mean Rating	User-kNN	MF	DMF	CBF&DMF
<b>RMSE</b>	0.9926	1.3357	1.1196	1.0098	0.9247
<b>MAE</b>	0.7988	1.0788	0.9410	0.8100	0.7047

Bảng 1: Kết quả thử nghiệm tập dữ liệu Netflix Prize trên độ đo RMSE và MAE

**Bộ dữ liệu Movie Lens:**

Độ đo RMSE đạt: 1.0823 và MAE đạt: 0.8552



**Hình 6: Training accuracy và Val accuracy**



**Hình 7: Training loss và Validation loss**

So sánh với một số mô hình khác như: User-kNN, MF và DMF trên độ đo RMSE và MAE được thống kê theo bảng sau:

	Phương pháp				
	Mean Rating	User-kNN	MF	DMF	CBF&DMF
<b>RMSE</b>	1.0241	1.1646	1.0296	1.0198	0.9823
<b>MAE</b>	0.7825	0.8670	0.8434	0.7823	0.7552

*Bảng 2: Kết quả thử nghiệm tập dữ liệu Movie Lens trên độ đo RMSE và MAE*

Thực nghiệm cho thấy sử dụng phương pháp kết hợp Lọc cộng tác (CBF) và Phân rã ma trận sâu (DMF) cho kết quả tốt hơn so với các phương pháp khác được đem ra so sánh. Bên cạnh đó, thông qua mạng lưới thần kinh sâu trong Phân rã ma trận sâu đã khai thác được tốt các mối quan hệ giữa người dùng và bộ phim trong ma trận người dùng – phim. Kết quả là hệ số RMSE và MAE được cải thiện tuy tốn thêm thời gian tính toán nhưng mô hình lại đạt được kết quả tốt hơn so với các mô hình đã có.

**4. KẾT LUẬN**

Mỗi phương pháp gợi ý đều có ưu và nhược điểm riêng của hệ thống. Tuy vậy chúng ta có thể kết hợp chúng lại với nhau để sử dụng ưu điểm của hệ thống này bù lại nhược điểm của hệ thống kia nhằm tìm ra một hệ thống lai có thể đáp ứng được nhu

cầu gợi ý cho người dùng tốt nhất trong khả năng của hệ thống.

Trong bài báo này chúng tôi đã kết hợp lọc cộng tác và lọc nội dung lại với nhau và chúng đã hoạt động khá tốt, cải thiện được phần nào hiệu suất dự đoán của hệ thống gợi ý cho người dùng so với các kỹ thuật gợi ý thông thường như Mean Rating, hay User kNN hoặc Deep Matrix Factorization...

Tương lai, chúng ta có thể kết hợp thêm vào các thông số khác ngoài những thông số mà bài báo đã đưa ra như userID, Rating, Mô tả phim hoặc sử dụng các bộ dữ liệu khác vào bài toán để tăng thêm khả năng dự đoán và đánh giá mức độ hiệu quả của mô hình nhằm cung cấp cho người dùng những trải nghiệm tốt nhất khi sử dụng hệ thống gợi ý phim.

**TÀI LIỆU THAM KHẢO**

- [1] N. T. Nghe, “Nghiên cứu và ứng dụng công nghệ thông tin ở Đồng bằng sông Cửu Long,” vol. Chương 2, no. Nhà xuất bản Đại học Cần Thơ, pp. 21-47, 2016.
- [2] Mirza Ilhami, Suharjito, “Film Recommendation Systems using Matrix Factorization and Collaborative Filtering,” no. 2014 International Conference on Information Technology, pp. 24-27, 2014.
- [3] X. He, H. Zhang, M. Kan, and T. Chua, “Fast matrix factorization for online recommendation with implicit feedback,” no. SIGIR, p. 549–558, 2016.
- [4] R. Burke, “Hybrid Web Recommender Systems,” no. School of Computer Science, Telecommunications and Information Systems, p. 377 – 408, 2007.
- [5] Xiaoyuan Su, Taghi M. Khoshgoftaar, “A survey of collaborative filtering techniques,” 2009.
- [6] SHUAI ZHANG, LINA YAO, AIXIN SUN, YI TAY, “Deep learning based recommender system: A Survey and New Perspectives,” no. ACM Comput. Surv, 2019.
- [7] Amir Albadvi, Mohammad Shahbazi, “A hybrid recommendation technique based on product category attributes,” no. Expert Systems with Applications 36, pp. 11480-11488, 2009.
- [8] Muhammet C, akır, S, ule G “und”uz O “g”ud”uc”u ”, Resul Tugay, “A Deep Hybrid Model for Recommendation Systems,” *Computer Engineering Department*, no. Istanbul Technical University, 2020.
- [9] Kalyan Kumar Jena 1 , Sourav Kumar Bhoi 1 , Soumya Ranjan Jena , Chittaranjan Mallick , Raghvendra Kumar , Hoang Viet Long , Nguyen Thi Kim Son , “Neural model based collaborative filtering for movie recommendation system,” *International Journal of Information Technology* , no. International Journal of Information Technology , 2022.
- [10] Y. Koren, “The BellKor Solution to the Netflix Grand Prize,” 2009.
- [11] Tulasi K. Paradarami, Nathaniel D. Bastian, Jennifer L. Wightman, “A Hybrid Recommender System Using Artificial Neural Networks,” vol. 83, no. Expert Systems with Applications, pp. 300-313, 2017.