



### **Hak cipta dan penggunaan kembali:**

Lisensi ini mengizinkan setiap orang untuk menggubah, memperbaiki, dan membuat ciptaan turunan bukan untuk kepentingan komersial, selama anda mencantumkan nama penulis dan melisensikan ciptaan turunan dengan syarat yang serupa dengan ciptaan asli.

### **Copyright and reuse:**

This license lets you remix, tweak, and build upon work non-commercially, as long as you credit the origin creator and license it on your new creations under the identical terms.

## BAB II

### LANDASAN TEORI

#### 2.1 Sistem Rekomendasi

Sistem rekomendasi merupakan subkelas dari *information filtering system* yang berusaha untuk memprediksi *rating* atau preferensi yang diberikan oleh *user* ke suatu *item*. Sistem rekomendasi terutama ditunjukkan kepada orang yang memiliki kekurangan dalam pengalaman pribadi atau tidak memiliki kompetensi untuk mengevaluasi *item* dalam jumlah besar yang berpotensi untuk ditawarkan oleh situs web (Ricci, dkk, 2011).

Pada tahun (2006) McGinty dan Smyth mengatakan bahwa sistem rekomendasi merupakan model aplikasi dari hasil observasi terhadap keadaan dan keinginan pelanggan. Oleh karena itu sistem rekomendasi memerlukan model rekomendasi yang tepat agar yang direkomendasikan sesuai dengan keinginan pelanggan, serta mempermudah pelanggan mengambil keputusan yang tepat.

Ada dua *basic entities* yang akan muncul di setiap sistem rekomendasi yaitu *user* atau pengguna yang terkadang dapat disebut sebagai *customer* dan *item* yang juga sering disebut sebagai produk. *User* merupakan seseorang yang memanfaatkan sistem rekomendasi dengan memberikan opini dikatakan oleh *user* tentang bermacam-macam *item* dan mendapatkan rekomendasi tentang *item-item* baru dari sistem (Vozalis, Margaritis, 2003).

Menurut Sebastia, dkk, (2009) ada dua teknik yang paling populer digunakan untuk membuat sistem rekomendasi yaitu:

### 1. Collaborative filtering

Pada *Collaborative filtering*, teknik ini merekomendasikan *item* berdasarkan *item* yang dipilih oleh *user* lain yang memiliki model preferensi yang sama dengan *user* saat ini. Teknik ini membutuhkan informasi dari *user* dalam jumlah yang besar untuk mendapatkan hasil yang lebih akurat.

### 2. Content-Based filtering

Pada *Content-based filtering*, setiap *item* didefinisikan oleh fitur dan *item* yang direkomendasikan adalah *item* yang memiliki fitur yang sama dan *user* sudah memberikan tinjauan positif selama riwayat interaksi *user* dengan sistem rekomendasi, kekurangan pada teknik ini yaitu rekomendasi hanya memuat *item* yang mirip dengan yang sudah pernah dipilih oleh *user* lainnya.

## 2.2 Item-based Collaborative Filtering

*Item-based collaborative filtering* merupakan algoritma sistem rekomendasi berdasar pada adanya kemiripan antara pemberian *rating* oleh *user* dengan *item* yang dipilih oleh *user* (Sarwar, dkk, 2001). Dari *rating* yang diberikan pada sebuah *item* dan *item* lainnya, didapatlah nilai kemiripan terhadap kedua *item* tersebut. Nilai kemiripan antar *item* akan dihitung dengan rumus prediksi *rating*, sehingga dapat menghasilkan prediksi *rating* yang akan dijadikan hasil prediksi.

Langkah pertama dalam algoritma ini adalah mencari nilai kemiripan antar *item*. Terdapat dua rumus untuk menghitung nilai kemiripan antar *item*, yaitu:

### 1. Cosine Similarity

Rumus *Cosine Similarity* (Sarwar, dkk, 2001):

$$\text{Similarity} = \cos(\theta) = \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_{i=1}^n A_i \times B_i}{\sqrt{\sum_{i=1}^n (A_i)^2} \times \sqrt{\sum_{i=1}^n (B_i)^2}} \dots(1)$$

Keterangan:

1.  $A_i$  adalah *rating user* terhadap *item A*.
2.  $B_i$  adalah *rating user* terhadap *item B*.

## 2. Adjusted Cosine Similarity

Memiliki kesamaan dengan *Cosine Similarity* akan tetapi setiap *rating user* terhadap suatu *item* harus dikurangi dengan rata-rata *rating user* tersebut. Rumus *Adjusted Cosine Similarity* (Sarwar, dkk, 2001):

$$sim(i, j) = \frac{\sum_{u \in U} (R_{u,i} - \bar{R}_u) (R_{u,j} - \bar{R}_u)}{\sqrt{\sum_{u \in U} (R_{u,i} - \bar{R}_u)^2} \sqrt{\sum_{u \in U} (R_{u,j} - \bar{R}_u)^2}} \quad \dots(2)$$

Keterangan:

1.  $Sim(i, j)$  adalah nilai kemiripan antara *item i* dan *item j*.
2.  $u \in U$  adalah himpunan *user u* yang me-*rating item i* dan *item j*.
3.  $R_{u,i}$  adalah *rating user u* pada *item i*.
4.  $R_{u,j}$  adalah *rating user u* pada *item j*.
5.  $R_u$  adalah *rating user u*.

Setelah mendapatkan nilai kemiripan antar *item*, langkah selanjutnya adalah menghitung prediksi *rating* yang akan diberikan kepada *user*.

## 2.3 Weighted Sum

*Weighted sum* adalah rumus yang digunakan untuk memberikan prediksi *rating* terhadap seorang *user* pada suatu *item* (Sarwar, dkk, 2001). Setiap *rating* yang diberikan oleh *user* pada *item* yang berhubungan akan dikalikan dengan nilai kemiripannya. Kemudian dibagi dengan jumlah nilai pasti dari kemiripan semua *item* yang saling berhubungan. Pada rumus prediksi *weighted Sum*, salah satu

variabel yang digunakan adalah *rating user* secara mentah atau *raw*. Rumus prediksi *weighted sum* (Sarwar, dkk, 2001):

$$P_{u,i} = \frac{\sum_{all\ similar\ items, N} (S_{i,N} * R_{u,N})}{\sum_{all\ similar\ items, N} (|S_{i,N}|)} \quad \dots(3)$$

Keterangan:

1.  $P_{u,i}$  adalah prediksi untuk *user u* pada *item i*.
2.  $S_{i,N}$  adalah nilai kemiripan antara *item i* dan *item N*.
3.  $R_{u,N}$  adalah *rating user u* pada *item N*.

*Rating user* yang digunakan pada rumus *Weighted Sum* harus dinormalisasi menjadi skala -1 sampai 1 seperti yang terpapar pada rumus 4 yang hasilnya dikembalikan ke skala awal dengan rumus denormalisasi seperti yang ada pada rumus 5.

Rumus Normalisasi *Rating* (Sarwar, dkk, 2001)

$$NR_{u,N} = \frac{2(R_{u,N} - Min_R) - (Max_R - Min_R)}{(Max_R - Min_R)} \quad \dots(4)$$

Rumus Denormalisasi *Rating* (Sarwar, dkk, 2001)

$$R_{u,N} = \frac{1}{2} \left( (NR_{u,N} + 1) \times (Max_R - Min_R) \right) + Min_R \quad \dots(5)$$

Keterangan:

1.  $NR_{u,N}$  adalah normalisasi *rating user u* terhadap *item N*.
2.  $R_{u,N}$  adalah *rating user u* *item N*.
3.  $Max_R$  adalah skala *rating* terbesar.
4.  $Min_R$  adalah skala *rating* terkecil.

*Weighted sum* terbagi dua, yaitu *item-item weighted sum* dan *item-regression weighted sum*. Pada *item-item weighted sum*, *rating user* yang digunakan adalah *rating user* secara mentah atau *raw*. Pada *item-regression*, *rating user* yang digunakan adalah *rating user* yang diolah dengan menggunakan *Simple linear regression*. *Simple linear regression* dapat dijelaskan pada rumus berikut.

$$Y_i = a_0 + b_0 X_i \quad \dots(6)$$

Keterangan :

- $Y_i$  adalah variabel *response* atau variabel akibat.
- $X_i$  adalah variabel *predictor* atau variabel faktor penyebab.
- $a_0$  adalah konstanta.
- $b_0$  adalah koefisien regresi.

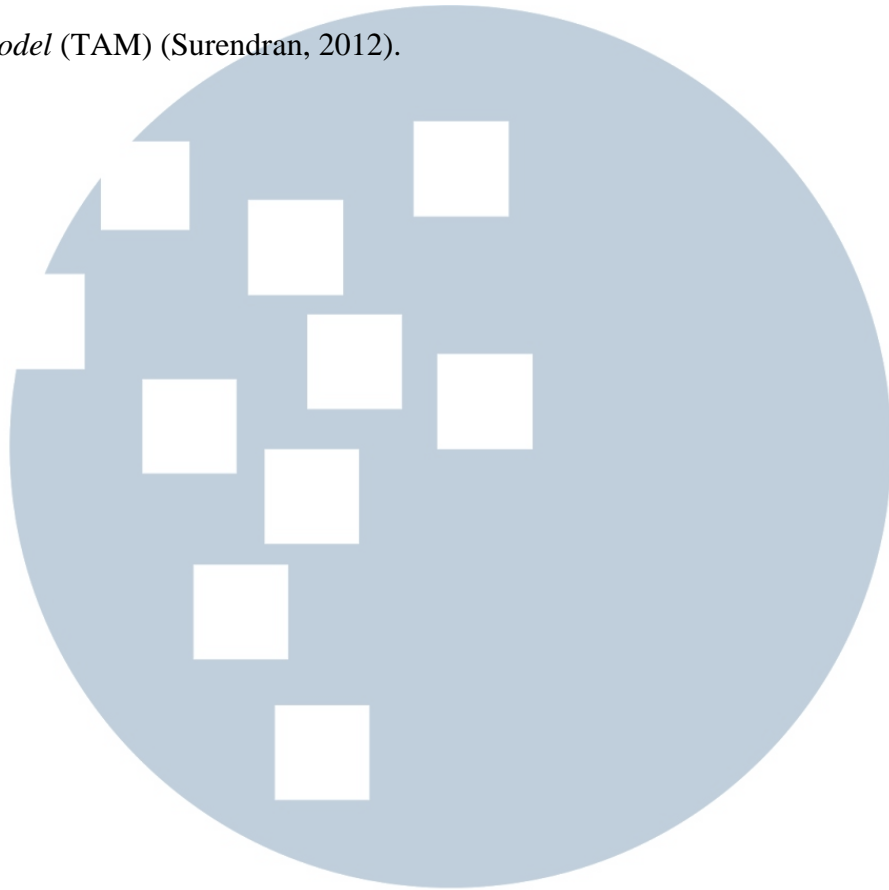
## 2.4 Steam

Steam adalah toko *online*/distributor digital yang dibuat oleh Valve Corporation untuk membeli *video game* dan tempat bermain *video game*. toko *online* Steam menjual sekitar 7672 *game* yang baru dirilis dan dijual di toko *online* Steam pada tahun 2017 (Statista, 2018).

## 2.5 Technology Acceptance Model

*Technology Acceptance Model* (TAM) adalah metode yang dibuat oleh davis pada tahun 1989, *Technology Acceptance Model* (TAM) berbasis dari *theory of reasoned action* (TRA) yang sudah pernah dipakai untuk menjelaskan perilaku penerimaan individual. *Technology Acceptance Model* (TAM) adalah salah satu metode penelitian populer yang digunakan untuk memprediksi nilai penerimaan dan penggunaan sebuah sistem informasi dan teknologi yang digunakan oleh *user*. *Percieved usefulness factor* dan *Percieved ease of use factor* adalah dua faktor besar

dalam perilaku penggunaan komputer yang berbasis dari *Technology Acceptance Model* (TAM) (Surendran, 2012).



# UMMN

UNIVERSITAS  
MULTIMEDIA  
NUSANTARA