

BAB II

TINJAUAN PUSTAKA

2.1 *Video Game*

Video game merupakan sebuah permainan visual yang dapat diinteraksikan menggunakan alat kontrol khusus. Alat yang digunakan pada *video game* umumnya berupa mesin *arcade*, konsol *game*, alat simulator, ataupun komputer. *Video game* juga memungkinkan pemain mendapatkan pengalaman baru, rasa ingin tahu dan tantangan. Hal ini membuktikan bahwa *video game* dapat menjadi salah satu media edukasi (Griffiths, 2002).

2.2 *Playstation 4*

Playstation adalah konsol *game* yang dikembangkan oleh *Sony Computer Entertainment* yang generasi pertamanya diperkenalkan pada 3 Desember 1994 di Jepang. *Playstation 4* merupakan konsol *game* yang diluncurkan pada 15 November 2013 di Amerika Utara. *Playstation 4* menggunakan *processor AMD Jaguar X86* serta 8GB GDDR5 RAM (playstation.com, 2016). Konsol *game* ini mampu menjalankan *video game* dengan resolusi hingga 1080p. Selain peningkatan spesifikasi pada komponen konsol, Sony juga melakukan pembaharuan besar pada *controller DualShock*. *Controller DualShock 4* memiliki *touchpad*, sensor 6-Axis, *Speaker*, serta 3 *LED-Bar*.

2.3 *Sistem Rekomendasi*

Sistem Rekomendasi adalah alat atau perangkat lunak dan teknik yang digunakan dalam memberikan saran untuk *item* yang akan direkomendasikan ke *user*. Sistem rekomendasi telah digunakan dalam berbagai situs web *e-commerce* untuk memilih produk yang diinginkan pelanggan (Schafer et al, 2001). Sistem rekomendasi memiliki ketergantungan pada sistem pengambilan informasi berdasarkan interaksi penggunaannya. Hasil dari sistem rekomendasi merupakan pilihan yang layak dipertimbangkan, karena dihasilkan dari sistem pencarian

informasi yang sesuai dengan permintaan *user* (Burke, 2007). Terdapat beberapa fungsi dari sistem rekomendasi (Ricci et al, 2011):

1. Meningkatkan penjualan barang.
Penjualan barang dapat ditingkatkan dengan sistem rekomendasi karena *item* yang direkomendasikan cenderung sesuai dengan apa yang dibutuhkan ataupun diinginkan *user*.
2. Menjual *item* yang beragam.
Sistem rekomendasi dapat menghasilkan *item* beragam sehingga memungkinkan *user* untuk memilih *item* yang tidak dapat ditemukan tanpa rekomendasi.
3. Meningkatkan kepuasan *user*.
Dengan sistem rekomendasi, *user* dapat menemukan rekomendasi *item* yang menarik dan relevan.
4. Meningkatkan kesetiaan *user*.
User akan menyukai situs web yang mereka kunjungi jika *user* lama diperlakukan sebagai pengunjung yang berharga. Semakin banyak *user* melakukan interaksi dengan *website*, semakin cocok rekomendasi *item* yang dihasilkan dengan preferensi *user*.
5. Lebih mengerti apa yang diinginkan *user*.
Berdasarkan interaksi *user*, sebuah penyedia layanan dapat mengiklankan *item* atau pesan promosi tertentu kepada pelanggan baru.

Berdasarkan sumber pengetahuannya, Terdapat 4 kelas berbeda pada teknik rekomendasi (Burke, 2002):

1. *Collaborative Filtering*
Rekomendasi dihasilkan dari data yang diolah berdasarkan informasi yang diberikan *user*. *Collaborative filtering* menemukan *user* yang memiliki ketertarikan yang mirip kemudian merekomendasikan *item* berdasarkan kesukaan *user* tersebut.
2. *Content-Based*
Item rekomendasi diperoleh dari fitur terkait *item* tersebut ataupun *rating* yang telah diberikan oleh *user*.

3. *Demographic*

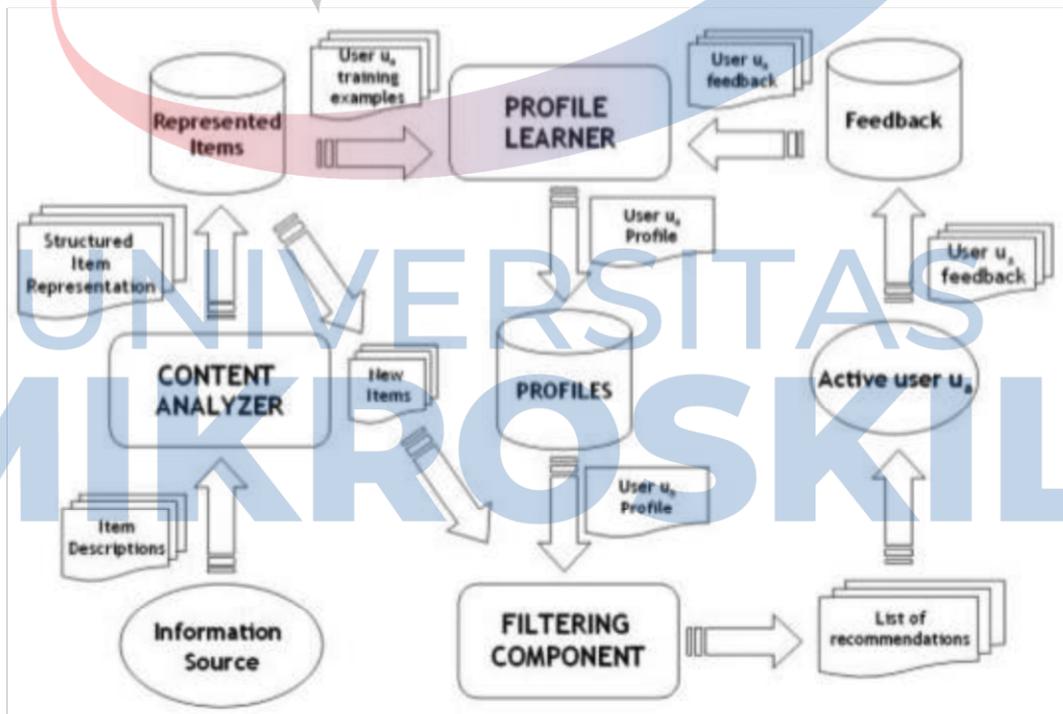
Rekomendasi *item* diperoleh berdasarkan profil demografi *user*.

4. *Knowledge-Based*

Knowledge-Based merekomendasikan *item* berdasarkan inferensi tentang kebutuhan *user* dan preferensi *user*.

2.4 *Content-Based Filtering*

Content-based filtering adalah teknik rekomendasi yang memilih *item* berdasarkan korelasi antara isi *item* dan preferensi *user*. Teknik ini membandingkan profil *user* dengan deskripsi *item* (Meteren dan Someren, 2000). Profil dari *user* direpresentasikan dengan aturan tertentu dan dibangun dengan menganalisis konten dari *item* yang disukai *user*.



Gambar 2.1 *Arsitektur Content-Based Recommender System*

(Sumber: Lops, et al., 2011)

Berdasarkan Gambar 2.1, terdapat tiga proses untuk menghasilkan rekomendasi, yaitu:

1. *Content analyzer*, pada tahap ini setiap konten ataupun fitur pada item dianalisis dan direpresentasikan dalam bentuk yang dapat diolah oleh sistem.
2. *Profile learner*, interaksi yang pernah dilakukan *user* dikumpulkan dengan tujuan untuk membentuk profil *user*.
3. *Filtering component*, memanfaatkan profil *user* untuk menghasilkan rekomendasi yang relevan sesuai dengan kesukaan *user*.

Metode yang dapat digunakan dalam pengumpulan informasi yang dapat digunakan pada sistem rekomendasi *content-based* salah satunya adalah TF-IDF (*Term Frequency-Inverse Document Frequency*). Bobot nilai TF-IDF dapat dihitung dengan persamaan sebagai berikut (Meteren dan Someren, 2000):

$$w_i = tf_i \cdot \log\left(\frac{n}{df_i}\right) \quad (1)$$

Keterangan:

w_i = Bobot TF-IDF

tf_i = Frekuensi kata i

df_i = Jumlah konten yang terdapat kata i

Pada *profile learner*, perhitungan bobot profil *user* dapat dihitung dengan persamaan sebagai berikut (Musto, 2010):

$$\vec{p}_u = \sum_i \vec{d}_i * rate(u, d_i) \quad (2)$$

Keterangan:

\vec{p}_u = Vektor profil *user*

d_i = konten pada *item* i

$rate(u, d_i)$ = *Rating user* u terhadap konten *item* i

2.4.1 Pengujian Content-Based dengan Precision and Recall

Untuk menguji akurasi dari rekomendasi yang dihasilkan, digunakan pengujian *precision and recall*. *Precision* adalah rasio jumlah dokumen yang ditemukan dan dianggap relevan. Semakin tinggi nilai *precision* maka rekomendasi yang dihasilkan semakin akurat. Sedangkan *recall* adalah kemampuan sebuah sistem dalam memanggil kembali dokumen yang dianggap relevan atau sesuai dengan yang diinginkan oleh pengguna dari *database*. Semakin tinggi nilai *recall* maka data relevan yang dikembalikan semakin banyak. Pada pengujian *precision and recall*, konsep hubungan informasi yang relevan dan tidak relevan dapat digambarkan dalam *matrix* sebagai berikut (Ekstrand et al, 2010):

	Relevan	Tidak Relevan
Ditampilkan	<i>True Positive (TP)</i>	<i>False Positive (FP)</i>
Tidak Ditampilkan	<i>False Negative (FN)</i>	<i>True Negative (TN)</i>

Untuk menghitung nilai *precision* digunakan persamaan sebagai berikut:

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

Untuk menghitung nilai *recall* digunakan persamaan sebagai berikut:

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

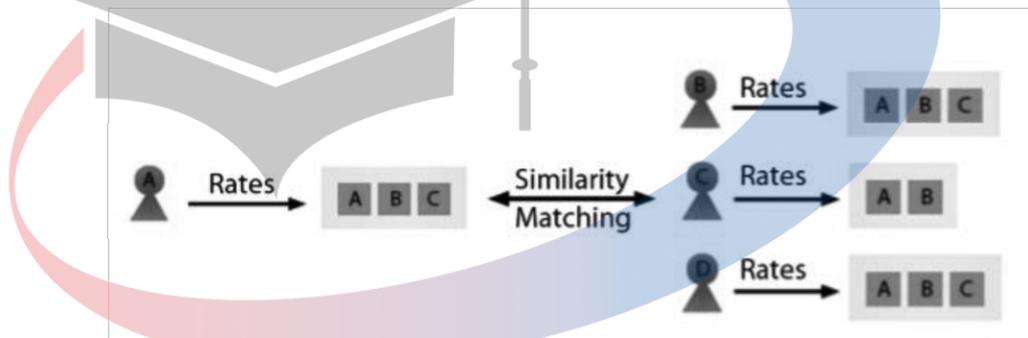
2.5 Collaborative Filtering

Collaborative filtering adalah algoritma rekomendasi yang melakukan prediksi berdasarkan penilaian atau perilaku *user* lain dalam suatu sistem (Ekstrand et al, 2010). Jika diantara beberapa *user* memberikan *rating* yang sama pada suatu *item*, diasumsikan mereka memiliki kesukaan yang sama. *User* yang memiliki kesukaan yang sama membangun korelasi, kemudian, *user* mendapat

rekomendasi *item* yang belum diberikan *rating* tetapi sudah dinilai positif oleh *user* lain (Asanov, 2011). *Collaborative filtering* terbagi dua, yaitu *user-based* dan *item-based*.

2.5.1 User-Based Collaborative Filtering

Sistem mencari *user* lain yang memiliki korelasi tinggi terhadap suatu *user* berdasarkan kemiripan perilaku *rating* terhadap *item* untuk memprediksi kesukannya. Diasumsikan *user A* menyukai *item 1,2,3* dan *user B* menyukai *item 1,2,4* maka rekomendasi yang diberikan kepada *user A* adalah *item 4* dan rekomendasi yang diberikan untuk *user B* adalah *item 3*.



Gambar 2. 2 User-Based Collaborative Filtering)
(Sumber: Asanov, 2011)

Untuk menghitung nilai kemiripan antar *user*, digunakan persamaan *Cosine Similarity* (Ekstrand et al, 2010).

$$sim(u, v) = \frac{r_u \cdot r_v}{||r_u||^2 ||r_v||^2} \quad (5)$$

Keterangan:

$sim(u, v)$ = Nilai Kemiripan antara *user* u dan *user* v

r_u = *Rating user* u

r_v = *Rating user* v

Setelah mendapatkan nilai kemiripan antar *user*, langkah selanjutnya adalah menghitung prediksi *rating user* terhadap *item*. Persamaan *weighted Sum*

dapat digunakan untuk menghasilkan nilai prediksi *rating user* terhadap *item* yang akan direkomendasikan (Ekstrand et al, 2010).

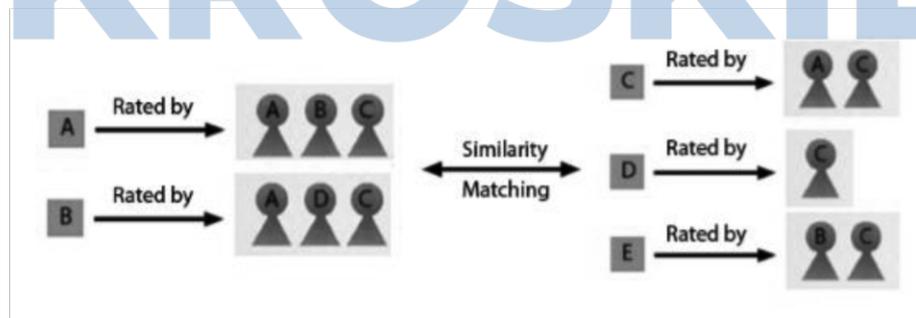
$$P_{(u,i)} = \bar{r}_u + \frac{\sum_{u' \in N} s(u, u') (r_{u',i} - \bar{r}_{u'})}{\sum_{u' \in N} |s(u, u')|} \quad (6)$$

Keterangan:

- $P(u, i)$ = Prediksi *rating user* u terhadap *item* i
- $u' \in N$ = Himpunan *user* lain yang memiliki nilai kemiripan dengan *user* aktif
- $r_{u',i}$ = *Rating user* lain yang memiliki kemiripan dengan *user* aktif terhadap *item* i
- $s(u, u')$ = Nilai *similarity* antara *user* aktif dan *user* lain
- \bar{r}_u = Rata-rata *rating user* aktif
- $\bar{r}_{u'}$ = Rata-rata *rating user* lain yang memiliki nilai kemiripan dengan *user* aktif

2.5.2 Item-Based Collaborative Filtering

Jika dua *item* cenderung disukai beberapa *user* yang sama, maka *item* tersebut diasumsikan mirip dan *user* diharapkan memiliki preferensi yang sama untuk *item* serupa. Pada metode ini, kesamaan *item* ditafsirkan berdasarkan pola preferensi *user* terhadap *item*.



Gambar 2. 3 *Item-Based Collaborative Filtering*
(Sumber: Asanov, 2011)

Untuk menghitung nilai kemiripan antar *item*, digunakan persamaan *Cosine Similarity* (Ekstrand et al, 2010).

$$sim(i, j) = \frac{\mathbf{r}_i \cdot \mathbf{r}_j}{\|\mathbf{r}_i\|^2 \|\mathbf{r}_j\|^2} \quad (7)$$

Keterangan:

$sim(i, j)$ = Nilai Kemiripan antara *item* i dan *item* j

\mathbf{r}_i = Rating *item* i

\mathbf{r}_j = Rating *item* j

Setelah mendapatkan nilai kemiripan antar *item*, langkah selanjutnya adalah menghitung prediksi *rating user* terhadap *item*. Persamaan *weighted Sum* dapat digunakan untuk menghasilkan nilai prediksi *rating user* terhadap *item* yang akan direkomendasikan (Ekstrand et al, 2010).

$$P_{(u,i)} = \frac{\sum_{j \in S} s(i, j) r_{u,j}}{\sum_{j \in S} |s(i, j)|} \quad (8)$$

Keterangan:

$P(u, i)$ = Prediksi *rating user* u terhadap *item* i

$j \in S$ = Himpunan *item* j yang memiliki nilai kemiripan

$r_{u,j}$ = Rating user u pada *item* j

$s(i, j)$ = Nilai *similarity* antara *item* i dan *item* j

2.5.3 Pengujian Collaborative Filtering dengan MAE

Untuk menguji akurasi rekomendasi *collaborative filtering* digunakan metode pengujian MAE. MAE adalah kuantitas yang digunakan untuk mengukur seberapa dekat suatu prediksi dengan hasil akhirnya. Metode MAE mengambil rata-rata mutlak dari perbedaan antara setiap prediksi *rating* untuk semua user

didalam *test-set*. Untuk menghitung *MAE* digunakan persamaan sebagai berikut (Ekstrand et al, 2010):

$$\frac{1}{n} \sum_{u,i} |P_{u,i} - r_{u,i}| \quad (9)$$

Keterangan:

n = Jumlah data

$P_{u,i}$ = Prediksi *rating user* u terhadap *item* i

$r_{u,i}$ = *Rating* yang sebenarnya dari *user* terhadap *item* i

