

# Pendekatan Metode Grafik Dalam Menggabungkan Pemfilteran Berbasis Konten Dan Kolaboratif Pada Sistem Rekomendasi

Zen Munawar<sup>1\*</sup>, Novianti Indah Putri<sup>2</sup>, Yudi Herdiana<sup>3</sup>

<sup>1</sup>Program Studi Manajemen Informatika, Politeknik LP3I Bandung, Indonesia

<sup>2,3</sup>Program Studi Teknik Informatika, Universitas Bale Bandung (UNIBBA), Indonesia

Email: [1munawarzen@gmail.com](mailto:munawarzen@gmail.com), [2noviantiindahputri2021@gmail.com](mailto:noviantiindahputri2021@gmail.com), [3ydherdn@gmail.com](mailto:ydherdn@gmail.com)

---

## INFORMASI ARTIKEL

### *Histori artikel:*

Naskah masuk, 7 Maret 2021

Direvisi, 15 Juni 2021

Diterima, 16 Juni 2021

### *Kata Kunci:*

*Pemfilteran Kolaboratif,  
Pemfilteran Berbasis Konten,  
Pemberi Rekomendasi hibrid,  
Model Berbasis Grafik*

---

## ABSTRAK

**Abstract-** Since the emergence of research on collaborative screening, recommendation systems have been an important research area. In the last decade there has been a lot of work to develop new approaches to recommendation systems carried out either by academia or in industry. This research was conducted to combine content-based approaches and collaborative filtering to make recommendations in a recommendation system to improve recommendation accuracy. Where the two approaches are to make recommendations. In this study, a graphical method is used which allows the incorporation of content information and ranking information naturally. The method used is user ranking and then describing the content, then it is concluded the content relation of the user, then recommendations are made with new relations, and combined with user item relations. From the experimental results, it was found that the proposed method had better capabilities.

**Abstrak-** Sejak awal kemunculan penelitian tentang penyaringan kolaboratif maka sistem rekomendasi telah menjadi area penelitian penting. Pada dekade terakhir telah banyak pekerjaan untuk mengembangkan pendekatan baru untuk sistem rekomendasi yang dilakukan baik oleh akademisi atau di bidang industri. Penelitian ini dilakukan untuk menggabungkan pendekatan pemfilteran berbasis konten dan pemfilteran kolaboratif untuk membuat rekomendasi dalam sistem pemberi rekomendasi untuk meningkatkan akurasi rekomendasi. Dua pendekatan tersebut untuk membuat rekomendasi. Dalam penelitian ini, digunakan metode berbasis grafik yang memungkinkan penggabungan informasi konten dan informasi peringkat secara alami. Cara yang digunakan yaitu peringkat pengguna lalu mendeskripsikan konten selanjutnya disimpulkan relasi konten dari pengguna, baru setelah itu dilakukan rekomendasi dengan relasi baru, dan dikombinasikan dengan relasi item pengguna. Dari hasil percobaan diperoleh usulan metode mempunyai kemampuan lebih baik.

Copyright © 2019 LPPM - STMIK IKMI Cirebon  
This is an open access article under the CC-BY license

---

## *Penulis Korespondensi:*

### **Zen Munawar**

Program Studi Manajemen Informatika,

Politeknik LP3I Bandung

Jl. Pahlawan No.59, Bandung, Indonesia

Email: [munawarzen@gmail.com](mailto:munawarzen@gmail.com)

---

## 1. Pendahuluan

Sistem rekomendasi bermanfaat bagi pengguna untuk mengurangi kelebihan informasi, adapun metode yang digunakan yaitu dengan memberikan saran yang telah dipersonalisasi untuk berbagai jenis produk seperti musik, film, buku dan lain sebagainya. Di tahun 2000-an bahkan sistem rekomendasi sudah mulai diterapkan di berbagai domain seperti e-commerce, e-learning, e-bisnis dan masih banyak lagi.

Secara komersial, e-commerce dapat disebut sebagai kegiatan yang berusaha menciptakan transaksi yang panjang antara perusahaan dan individu [1]. Sistem ini telah memainkan peran penting dalam E-commerce dan pemfilteran informasi dengan sejumlah sistem komersial yang diterapkan, contohnya termasuk Amazon, Netflix, IMDB. Dunia saat ini tidak lepas dari peran data karena semua dibangun di atas sebuah fondasi data [2].

Pemfilteran kolaboratif dan pemfilteran berbasis konten adalah dua teknik utama yang digunakan dalam sistem pemberi rekomendasi. Sistem pemfilteran kolaboratif bekerja dengan terlebih dahulu mengumpulkan preferensi pengguna untuk item dalam domain tertentu. Sistem kemudian menggunakan data yang dikumpulkan untuk menemukan pengguna dengan profil serupa dan menggunakan peringkat untuk memprediksi item yang mungkin menarik bagi pengguna tertentu [3][4]. Pemfilteran berbasis konten merupakan salah satu teknik alternatif yang berasal dari bidang pencarian informasi. Sistem berbasis konten mengandalkan deskripsi konten item (seperti judul, penulis, deskripsi teks) untuk menemukan item yang mirip dengan item yang menarik bagi pengguna. Secara umum, tujuan penyaringan berbasis konten adalah untuk menentukan rekomendasi berdasarkan kesamaan fitur antara item yang dipertimbangkan dan item yang sebelumnya dinilai menarik oleh pengguna.

Dalam makalah ini mengusulkan untuk menggabungkan informasi konten dengan informasi peringkat dengan menggunakan representasi grafik terpadu untuk dua jenis informasi. Dari model grafik gabungan yang mewakili interaksi item-pengguna dan item-konten, metode ini pertama-tama menentukan fitur konten yang memiliki dampak signifikan pada perilaku setiap pengguna. AI dan *deep learning* dapat meningkatkan prediksi dengan deteksi dan diagnosis [5]. Algoritma propagasi jaringan kemudian digunakan untuk menghitung

asosiasi antara node pengguna dan node item dengan menjelajahi link konten pengguna dan item pengguna dari grafik. Penelitian ini menerapkan metode dalam domain rekomendasi film dan menunjukkan bahwa metode ini memberikan hasil yang menjanjikan.

## 2. Penelitian Terkait

Manfaat potensial dari menggabungkan pemfilteran kolaboratif dan berbasis konten telah dipelajari di sejumlah karya. Pendekatan *hybrid* paling sederhana adalah dengan mengimplementasikan metode berbasis konten dan kolaboratif secara terpisah dan kemudian menggabungkan prediksi [6]. Saat ini, sejumlah besar data yang dikumpulkan dan dihasilkan setiap hari menawarkan berbagai peluang analitis bagi organisasi untuk mengungkap informasi yang bermanfaat untuk operasinya [7].

Rekomendasi bisa juga menimbulkan ketidakpastian yang disebut dengan *certainty factor*. *Certainty factor* adalah metode untuk mengelola ketidakpastian dalam sistem berbasis aturan [8]. Dalam pendekatan lain, informasi konten dan informasi peringkat pertama-tama digabungkan untuk menghasilkan data yang berfungsi sebagai masukan campuran untuk prediktor. Matriks profil pengguna kemudian digunakan sebagai masukan untuk pemfilteran kolaboratif, bukan matriks item pengguna.

Karena intuisi representasi dan ketersediaan algoritma grafik, model berbasis grafik telah digunakan dalam sejumlah metode rekomendasi. Aggarwal dkk. [9] merepresentasikan hubungan antar pengguna sebagai grafik terarah di mana tautan terarah yang menghubungkan dua pengguna menunjukkan bahwa perilaku pengguna sumber sangat prediktif dari perilaku pengguna target. Model berbasis grafik telah diperkenalkan yang meliputi pengguna dan item [10]. Tautan berbobot antara dua node item mewakili kesamaan antara dua item, yang telah dihitung sebelumnya berdasarkan konten item. Model ini memungkinkan pengambilan informasi berbasis konten dan rating dalam kerangka kerja terpadu. Model berbasis grafik dieksploitasi dengan asosiasi transitif untuk mengatasi masalah keterbatasan data [11].

### 2.1 Model Grafik

Notasi ditunjukkan dengan  $X = \{x_1, x_2, \dots, x_n \mid X\}$  satu set item,  $A=X$  dan dengan  $U = \{u_1, u_2, \dots,$

$u \mid U \}$ ,  $B=U$  sekumpulan pengguna. Peringkat pengguna atas item dengan matriks  $R = (r_{ij})$  dengan ukuran  $|B| \times |A|$ , sedemikian rupa sehingga  $r_{ij}$  adalah rating yang diberikan pengguna  $i$  untuk butir  $j$ . Setiap peringkat  $r_{ij}$  dapat mengambil nilai dari serangkaian kemungkinan peringkat yang terbatas. Di asumsikan  $r_{ij}$  bisa berupa  $+1$  (suka) atau  $-1$  (tidak suka). Jika pengguna  $i$  belum memberi nilai  $j$  maka  $r_{ij} = \emptyset$ . Selanjutnya, menggunakan  $C = \{c_1, c_2, \dots, c_n \mid C \}$ ,  $D=C$  untuk menunjukkan sekumpulan fitur yang mencirikan konten item. Asosiasi item-konten dengan  $|A| \times |D|$  matriks  $D = (y_{ij})$ , di mana  $y_{ij} = 1$  jika item  $i$  memiliki ciri  $j$  dan  $y_{ij} = 0$  sebaliknya. Misalnya, untuk  $x_i$  adalah sebuah film,  $c_j$  dapat berupa “genre = action” dan  $y_{ij} = 1$  berarti film tersebut termasuk dalam genre “action”. Tujuan dari sistem pemberi rekomendasi adalah untuk memprediksi peringkat yang akan diberikan pengguna aktif untuk item yang tidak diberi peringkat dan berdasarkan ini memberikan daftar rekomendasi.

Model Grafik. Seperti yang ditunjukkan pada penelitian sebelumnya [9][10], adalah wajar dan nyaman untuk menyelesaikan masalah yang dihadapi dengan menggunakan model rekomendasi berbasis grafik. Ide dasarnya adalah untuk membangun model grafik dari rating dan informasi konten, dan kemudian mengeksplorasi asosiasi antar node untuk membuat prediksi. Gambar 1 menunjukkan grafik contoh. Bagian atas grafik menunjukkan asosiasi item-konten, di mana node berhubungan dengan item atau fitur konten. Tautan ditarik antara item node  $x_i$  dan node fitur  $c_j$  jika ada asosiasi bukan nol antara  $x_i$  dan  $c_j$ , yaitu jika  $y_{ij} = 1$  sesuai dengan notasi di atas. Demikian pula, bagian bawah grafik mewakili preferensi pengguna atas item. Pada bagian ini, link antara node pengguna dan file.

## 2.2 Grafik Semantik

Perhatikan  $G = (C, R)$  sebuah graf semantik tak berarah yang terdiri dari himpunan konsep  $C$  dan himpunan relasi semantik  $R$ . Busur menghubungkan dua konsep  $C_i$  dan  $C_j$  yang memiliki kesamaan semantik yang dibobot menurut skor yang dihitung menggunakan jarak kesamaan gabungan rinci di bawah ini. Secara formal, kami mempertimbangkan: Himpunan  $C = \{C_1, C_2, \dots, C_n\}$  yang elemen-elemennya disebut node, Himpunan  $R = \{R_1, R_2, \dots, R_m\}$  yang elemen-elemennya disebut busur simpul.

$$m_{ij} = \begin{cases} Rel(C_i, C_j) & \text{If } Rel(C_i, C_j) \neq 0 \\ 0 & \text{else} \end{cases}$$


Hubungan antara dua konsep  $C_i$  dan  $C_j$  diklasifikasikan sebagai berikut:

$$Rel(C_i, C_j) = Dist(C_i, C_j)$$

Jarak semantik diklasifikasikan menjadi tiga jenis: Jarak hierarkis [12]: didasarkan pada hierarki sumber daya semantik dan dihitung menggunakan jumlah tepi antara konsep. Jarak kontekstual [13]: bergantung pada isi informasi, dan dihitung dengan menggunakan perbandingan antara definisi kedua konsep tersebut. Jarak *hybrid* : merupakan kombinasi dari jarak hierarkis dan kontekstual.

## 2.3 Representasi Grafik

Mengingat matriks asosiasi konten-item, cara sederhana untuk menghitung kesamaan antara dua item adalah dengan membandingkan fitur kontennya. Misalnya, menghitung kesamaan dua item dengan menghitung informasi timbal balik antara deskripsi item dan kemudian menggambar tautan berbobot antara node item untuk mewakili kesamaan [10]. Namun, metode tersebut tidak memperhitungkan peringkat pengguna saat menghitung kesamaan item-item dan dengan demikian tidak dapat menyesuaikan kesamaan item untuk pengguna tertentu. Untuk mengilustrasikan hal ini, mari kita perhatikan contoh yang diberikan pada gambar 1.



Gambar 1. Contoh representasi grafik untuk rating dan informasi konten [14]

Dalam contoh ini, item  $x_3$  dan  $x_4$  memiliki fitur yang sama  $c_2$ . Dengan melihat hanya pada bagian konten-item dari grafik, penghitungan kemiripan sederhana akan memutuskan bahwa  $x_3$  dan  $x_4$  serupa karena fitur umum ini. Tetapi ini tidak berlaku untuk pengguna  $u_1$ , yang menilai  $x_3$  sebagai disukai dan  $x_4$  sebagai tidak suka. Artinya, dari sudut pandang  $u_1$ ,  $x_3$  dan  $x_4$  tidak serupa dan  $c_2$  tidak berpengaruh pada peringkat  $u_1$ . Pada saat yang sama, semua item yang memiliki rating  $u_1$  dan yang berisi  $c_1$  (yaitu  $x_2$  dan  $x_3$ ) mendapatkan rating positif dari  $u_1$ . Oleh karena

itu, seseorang harus mempertimbangkan  $c_1$  sebagai memiliki peran penting dalam pendapat  $u_1$ .

Contoh ini menunjukkan kebutuhan untuk menggunakan ukuran kemiripan yang dipersonalisasi saat menghitung kesamaan item-item dari informasi konten. Setiap fitur konten harus memiliki tingkat kepentingannya dalam memutuskan kemiripan item, dan tingkat kepentingan ini harus disesuaikan untuk pengguna tertentu. Sekarang akan disajikan pendekatan yang mencirikan pentingnya setiap fitur konten untuk setiap pengguna. Ini adalah langkah pertama untuk menggabungkan rekomendasi berbasis konten dan kolaboratif. Dengan adanya grafik yang diperkenalkan di atas, untuk setiap  $u_i$  pengguna dan setiap fitur konten  $c_k$ , bahwa  $c_k$  penting untuk  $u_i$  jika jumlah bobot dari semua jalur berbeda yang menghubungkan  $c_k$  dan  $u_i$  dibagi dengan jumlah jalur melebihi beberapa ambang  $T$  ( $0 < T < 1$ ). Di sini, hanya jalur dengan panjang 2 dan melewati node item yang dipertimbangkan. Untuk jalur yang menghubungkan  $u_i$  dan  $c_k$  melalui  $x_j$ , bobot dihitung sebagai  $r_{ij} * y_{jk} = r_{ij}$ , karena  $y_{jk} = 1$ .

Misalkan  $s_{ik}$  adalah banyaknya lintasan yang menghubungkan  $u_i$  dan  $c_k$ , dan  $w_{ik}$  adalah jumlah bobot lintasan. Karena bobot jalur dapat berupa +1 atau -1,  $w_{ik}$  sama dengan jumlah jalur dengan bobot positif dikurangi jumlah jalur dengan bobot negatif. Didefinisikan tingkat kepentingan  $v_{ik}$  dari  $c_k$  sehubungan dengan  $u_i$  sebagai:

$$v_{ik} = \begin{cases} \frac{\min(s_{ik}, \gamma) w_{ik}}{\gamma s_{ik}} & \text{if } \frac{w_{ik}}{s_{ik}} > T \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

Dalam rumus ini,  $w_{ik}/s_{ik}$  menunjukkan dominasi peringkat positif atas peringkat negatif yang diberikan  $u_i$  pengguna untuk item dengan fitur  $c_k$ ;  $\min(s_{ik}, \gamma) / \gamma$  adalah yang disebut faktor bobot signifikansi yang mendevaluasi derajat kepentingan berdasarkan beberapa jalur [15]. Mengikuti menggunakan  $\gamma = 50$  dalam eksperimen [15]. Nilai ambang  $T$  ditetapkan ke 0,3, yang berarti jumlah jalur positif harus sekitar dua kali lebih besar dari jumlah jalur negatif agar fitur dianggap penting.

Ilustrasi komputasi  $v_{ij}$  melalui contoh yang ditunjukkan pada gambar 1: untuk pengguna  $u_1$  dan fitur konten  $c_1$ . Untuk pengguna. Untuk setiap pasangan ( $u_i, c_k$ ) yang memiliki  $v_{ik}$  bukan nol, Penggambaran tautan baru dengan  $v_{ik}$  bobot. Gambar 1 menunjukkan grafik yang diperpanjang untuk grafik dari gambar 1. Garis putus-putus adalah tautan baru yang baru saja ditambahkan untuk mewakili korelasi antara  $u_1$  dan  $c_1$ .

## 2.4 Rekomendasi

Sekarang akan dijelaskan proses rekomendasi sebagai masalah pencarian grafik dalam grafik yang diperluas. Dengan menggunakan contoh yang ditunjukkan pada gambar 1 untuk mengilustrasikan pendekatan ini. Sistem rekomendasi diperlukan karena sebelumnya terdapat kelemahan pada sistem berbasis konten [16].

Misalkan sistem perlu merekomendasikan item untuk pengguna aktif. Mengikuti [10][11], pertama-tama menentukan hubungan antara pengguna ini dan setiap item yang belum dinilai oleh pengguna. Item tersebut kemudian diurutkan sesuai dengan asosiasi, dan item  $K$  teratas dipilih untuk rekomendasi.

Dalam model, asosiasi antara dua node ditentukan dengan mempertimbangkan semua jalur yang menghubungkannya. Untuk pasangan node pengguna  $u_i$  dan item node  $x_j$ , kita menghitung asosiasi di antara keduanya sebagai jumlah bobot dari semua jalur berbeda yang menghubungkan  $u_i$  dan  $c_j$ . Dalam perhitungan ini membedakan dua jenis jalur - jalur melalui node konten dan jalur melalui node item. Jalur tipe pertama adalah jalur yang panjangnya sama dengan 2 dan melewati node fitur konten. Contoh jalur tersebut adalah  $u_1-c_1-x_1$  pada gambar 1, yang memiliki interpretasi intuitif -  $u_1$  menyukai item yang berisi fitur  $c_1$  dan karena itu menyukai  $x_1$ . Jalur tersebut sesuai dengan asosiasi melalui informasi konten. Dengan membatasi panjang jalur menjadi 2, tidak diizinkan asosiasi transitif untuk jalur jenis ini. Karena bobot tautan konten-item selalu 1, bobot jalur jenis ini sama dengan bobot tautan konten-pengguna masing-masing. Jenis kedua mencakup jalur yang melewati node item dan node pengguna. Sangat tertarik pada asosiasi antara node pengguna dan node item, panjang jalur jenis ini harus berupa angka ganjil. Selain itu, hanya jalur yang panjangnya tidak melebihi parameter  $M$  yang dipertimbangkan.

## 3. Evaluasi

Dengan menggunakan presisi, penarikan kembali (*recall*), dan pengukuran F untuk mengukur keefektifan metode rekomendasi. Metrik tersebut didefinisikan sebagai berikut:

$$\text{presisi} = \frac{\# \text{ item yang direkomendasikan yang mendapatkan peringkat positif aktual}}{\# \text{ dari semua item yang direkomendasikan}} \quad (3)$$

$$\text{Recall} = \frac{\# \text{ item yang direkomendasikan mendapatkan peringkat positif aktual}}{\# \text{ dari semua item yang mendapatkan peringkat positif actual}} \quad (4)$$

$$F = \frac{2 \times \text{presisi} \times \text{recall}}{\text{Presisi} + \text{recall}} \quad (5)$$

Dibandingkan metode yang diusulkan) dengan metode berikut: Tetangga terdekat k-Berbasis

Pengguna menggunakan korelasi Pearson. Metode ini menggunakan korelasi Pearson sebagai ukuran kemiripan antara dua pengguna, dan membuat rekomendasi berdasarkan peringkat pengguna yang sangat mirip dengan pengguna aktif.

Berbasis Konten menggunakan pencarian grafik. Metode ini menghitung jumlah jalur dengan panjang 3 yang berpindah dari node pengguna aktif melalui node item dan konten ke node item yang tidak dinilai dan merekomendasikan item dengan jumlah jalur terbesar.

Pemfilteran kolaboratif 3-Hop menggunakan pencarian grafik. Metode ini membuat rekomendasi hanya berdasarkan asosiasi melalui node item seperti yang dijelaskan di bagian sebelumnya dengan panjang jalur maksimal  $M = 3$ .

Metode Hybrid Sederhana yang menggabungkan Content-Based dan 3-Hop dengan menggabungkan item rekomendasi teratas yang dikembalikan oleh masing-masing metode.

#### 4. Hasil dan Pembahasan

Tabel 1 menunjukkan bahwa 3-Hop sederhana secara signifikan mengungguli metode Berbasis Pengguna dan Berbasis Konten. Hasil ini mendukung temuan terbaru bahwa pendekatan k-NN berbasis pengguna memberikan hasil yang buruk dalam hal presisi dan penarikan sementara berkinerja baik dalam hal metrik *mean absolute error* (MAE) - didefinisikan sebagai perbedaan absolut rata-rata antara peringkat yang diprediksi dan peringkat aktual [9].

Tabel 1. Penarikan, presisi, dan nilai pengukuran F dari metode percobaan [17]

Algorithm	Metrics	Number of recommended item		
		10	20	50
User-based	Recall	0,007	0,021	0,069
	Precision	0,015	0,025	0,034
	F-measure	0,009	0,023	0,045
Content-Based	Recall	0,009	0,017	0,037
	Precision	0,022	0,020	0,018
	F-measure	0,013	0,018	0,024
3-Hop	Recall	0,155	0,222	0,377
	Precision	0,284	0,225	0,164
	F-measure	0,200	0,223	0,228
Simple Hybrid	Recall	0,117	0,162	0,279
	Precision	0,186	0,148	0,118
	F-measure	0,144	0,155	0,166
CombinedGraph	Recall	0,165	0,234	0,381
	Precision	0,292	0,240	0,175
	F-measure	0,211	0,237	0,240

Salah satu tantangan untuk algoritma pemfilteran kolaboratif adalah akurasi rekomendasi berkurang saat matriks item pengguna jarang. Metode ini dapat mengatasi masalah ini dengan mengeksploitasi pengaitan melalui node fitur konten meskipun sebagian besar jalur melalui node item tidak ada. Jadi, ketersebaran data peringkat memiliki

efek yang lebih kecil pada CombinedGraph daripada pada algoritma kolaboratif murni. Untuk memverifikasi hipotesis ini, dengan melakukan eksperimen berikut. Digunakan 400 pengguna pertama untuk membentuk set pelatihan dan 100 pengguna berikutnya untuk membentuk set pengujian. Untuk setiap pengguna uji, 25% peringkat ditahan untuk prediksi. Secara acak menghapus elemen dari matriks item pengguna untuk meningkatkan ketersebaran dan mengukur akurasi rekomendasi pada tingkat ketersebaran yang berbeda.

Nilai F-measure untuk 50 rekomendasi teratas ditunjukkan pada Tabel 1. Seperti dapat dilihat, CombinedGraph memberikan hasil yang lebih stabil daripada Berbasis Pengguna dan 3-Hop saat ketersebaran meningkat. Ini menegaskan hipotesis bahwa Combine-Graph kurang sensitif terhadap ketersebaran data dibandingkan pemfilteran kolaboratif murni.

#### 5. Kesimpulan

Cara efektif untuk menggabungkan pemfilteran berbasis konten dan kolaboratif untuk mencapai rekomendasi yang lebih akurat. Metode ini menggunakan model berbasis grafik untuk merepresentasikan konten dan informasi peringkat.

Dengan pemanfaatan peringkat pengguna untuk memilih fitur konten penting yang menghubungkan pengguna dengan item yang diminati. Model grafik juga menyediakan cara mudah untuk menghitung asosiasi antara pengguna dan item menggunakan algoritma propagasi jaringan yang tersedia. Diperoleh hasil yang menunjukkan bagaimana metode ini berkinerja lebih baik daripada metode pemfilteran kolaboratif berbasis pengguna, metode berbasis konten, dan metode rekomendasi *hybrid*.

#### Daftar Pustaka

- [1] Z. Munawar, "Keamanan Pada E-Commerce Usaha Kecil dan Menengah," *Temat. - J. Teknol. Inf. dan Komun.*, vol. 5, no. 1, pp. 1–16, Jun. 2018.
- [2] Z. Munawar, B. Siswoyo, and N. S. Herman, "Machine learning approach for analysis of social media," *ADRI Int. Journal. Information. Technol.*, vol. 1, pp. 5–8, 2017.
- [3] P. Resnick and H. R. Varian, "Recommender Systems," *Commun. ACM*, vol. 40, no. 3, pp. 56–58, 1997.
- [4] U. Shardanand and P. Maes, "Social information filtering: Algorithms for automating word of mouth," in *Proceedings of the ACM CHI Conference on Human Factors in Computing Systems*, 1995, pp. 210–217.
- [5] R. Komalasari, "Manfaat Teknologi Informasi

- dan Komunikasi di Masa Pandemi Covid 19,”  
*Temat. Teknol. Inf. Dan Komun.*, vol. 7, no. 1,  
pp. 38–50, 2020.
- [6] M. Claypool, A. Gokhale, T. Miranda, P. Murnikov, D. Netes, and M. Sartin, “Combining content-based and collaborative filters in an online newspaper,” in *Proceedings of the ACM SIGIR '99 Workshop on Recommender Systems: Algorithms and Evaluation*, 1999, p. .
- [7] N. I. Munawar, Zen and Putri, “Keamanan Jaringan Komputer Pada Era Big Data,” *J-SIKA/ J. Sist. Inf. Karya Anak Bangsa*, vol. 02, no. 01, pp. 14–20, 2020.
- [8] N. I. Putri, “Sistem pakar diagnosa tingkat kecanduan gadget pada remaja menggunakan metode Certainty Factor.” UIN Sunan Gunung Djati Bandung, 2018.
- [9] C. C. Aggarwal, J. L. Wolf, K.-L. Wu, and P. S. Yu, “Horting hatches an egg: A New Graph-Theoretic Approach to Collaborative Filtering,” in *Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining - KDD '99*, 1999, pp. 201–212.
- [10] Z. Huang, W. Chung, T.-H. Ong, and H. Chen, “A graph-based recommender system for digital library,” in *The Second ACM/IEEE-CS Joint Conference on Digital Libraries - JCDL '02*, 2002, p. 65.
- [11] Z. Huang, H. Chen, and D. Zeng, “Applying associative retrieval techniques to alleviate the sparsity problem in collaborative filtering,” *ACM Trans. Inf. Syst.*, vol. 22, no. 1, pp. 116–142, 2004.
- [12] R. Rada, H. Mili, E. Bicknell, and M. Blettner, “Development and Application of a Metric on Semantic Nets,” *IEEE Trans. Syst. Man Cybern.*, vol. 19, no. 1, pp. 17–30, 1989.
- [13] J. J. Jiang, “Jiang1997.pdf,” in *International Conference on Research in Computational Linguistics (ROC)*, 1997, pp. 19–33.
- [14] N. D. Phuong, L. Q. Thang, and T. M. Phuong, “A graph-based method for combining collaborative and content-based filtering,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2008, vol. 5351 LNAI, pp. 859–869.
- [15] J. L. Herlocker, “An algorithmic framework for performing collaborative filtering,” *SIGIR '99 Proc. 22nd Annu. Int. ACM SIGIR Conf. Res. Dev. Inf. Retr.*, vol. 7, no. 2, pp. 65–83, 1999.
- [16] Z. Munawar, N. Suryana, Z. B. Sa'aya, and Y. Herdiana, “Framework With An Approach To The User As An Evaluation For The Recommender Systems,” in *2020 Fifth International Conference on Informatics and Computing (ICIC)*, 2020, pp. 1–5.
- [17] J. Herlocker, Jonathan L. ; Konstan, Joseph A.; Borchers, Al ; Riedl, “Evaluating Collaborative filtering recommender systems,” *ACM Trans. Inf. Syst.*, vol. 22, no. 1, pp. 5–53, 2004.