

# TopC-CAMF: Sistem Rekomendasi *Matrix Factorization* Berbasis *Top Context*

Rosni Lumbantoruan<sup>1</sup>, Paulus Simanjuntak<sup>2</sup>, Ingrid Aritionang<sup>3</sup>, Erika Simaremare<sup>4</sup>

**Intisari**—Aktivitas daring menjadi makin vital seiring dengan berkembangnya bisnis digital. Pengguna dapat melakukan sebagian besar aktivitas daring seperti belanja, pemesanan hotel, atau pendidikan dan kursus daring. Sejumlah besar pengguna media sosial tertarik pada banyaknya barang yang tersedia di internet. Banyaknya informasi membuat pengguna sosial tidak mungkin memilih informasi tersebut dengan benar dan efisien. Banyak perusahaan menawarkan personalisasi untuk mengatasi masalah ini. Terbukti bahwa sistem rekomendasi yang dipersonalisasi mampu menyarankan barang kepada pengguna berdasarkan minat dan kebutuhan yang paling sesuai kepada setiap pengguna dengan menggunakan informasi kontekstual pengguna. Namun, sebagian besar riset menangkap informasi kontekstual ini dari konteks yang telah ditentukan, seperti lokasi dan waktu. Dalam riset ini, diperoleh konteks pengguna yang dipersonalisasi dari ulasan teks pengguna yang dituliskan pengguna memberi peringkat pada suatu barang. Untuk tujuan ini, diusulkan pendekatan baru berdasarkan rekomendasi *matrix factorization* (MF), TopC-CAMF, yang menyelidiki dan menemukan konteks atau kebutuhan paling penting untuk setiap pengguna dengan memanfaatkan model pembelajaran mendalam. Pertama, semua konteks penting dari ulasan teks pengguna diekstrak. Kemudian, preferensi pengguna direpresentasikan dengan variasi konteks yang paling penting, yaitu konteks *top 5*, *top 10*, *top 15*, *top 20*, dan *top 25*. Kemudian, variasi *top* konteks terbaik dievaluasi dan *top* konteks yang teroptimal digunakan sebagai masukan untuk metode MF dalam memberikan rekomendasi yang lebih baik. Eksperimen ekstensif menggunakan tiga kumpulan data nyata dilakukan untuk membuktikan efektivitas TopC-CAMF dengan metrik *root mean square error* (RMSE), *mean absolute error* (MAE), *mean squared error* (MSE), *normalized discounted cumulative gain* (NDCG), dan *recall*.

**Kata Kunci**—Context-Aware, Matrix Factorization, Personalisasi, Ekstraksi Konteks.

## I. PENDAHULUAN

Pesatnya perkembangan layanan dan aplikasi internet menghasilkan sejumlah besar informasi setiap hari [1]–[3]. Berdasarkan *datareportal.com*, *website* yang menyediakan laporan global terkait data statistik dan pertumbuhan industri, pada awal tahun 2022 pengguna internet meningkat menjadi 4,95 juta, yaitu meningkat 4% dibandingkan tahun sebelumnya, serta telah dihasilkan sebanyak 79 zetabita data pada tahun

2022. Jumlah data ini sangat banyak, sehingga membuat pengguna membutuhkan waktu yang lama untuk menemukan informasi yang sesuai dengan kebutuhannya [1]. Hal ini membuat kebutuhan akan sistem rekomendasi menjadi makin penting.

Sistem rekomendasi adalah sistem yang berfungsi sebagai mekanisme penyaringan informasi yang mampu mengatasi masalah kelebihan informasi [4], [5] dan membantu pengguna menemukan produk atau jasa yang paling sesuai dengan kebutuhan masing-masing, yang disebut dengan personalisasi [1]. Personalisasi adalah kemampuan untuk menyesuaikan produk atau layanan berdasarkan pengetahuan tentang perilaku dan preferensi setiap pengguna. Hal ini menjadi salah satu tujuan dari penelitian ini, yaitu memberikan rekomendasi sesuai preferensi pengguna menggunakan sistem rekomendasi tradisional.

Secara umum, berdasarkan pendekatannya, sistem rekomendasi tradisional dapat diklasifikasikan menjadi empat kategori, yaitu model berbasis konten (*content-based*), *collaborative filtering* (CF), *knowledge-based*, dan *hybrid-based*. Model berbasis konten memberikan rekomendasi berdasarkan preferensi pengguna sebelumnya. Model CF memberikan rekomendasi berdasarkan hasil analisis terhadap perilaku pengguna yang serupa untuk mengidentifikasi kandidat produk yang akan direkomendasikan. *Knowledge-based* menghasilkan rekomendasi dengan menanamkan pengetahuan khusus terkait domain, sedangkan *hybrid-based* menggabungkan metode sebelumnya dalam berbagai cara [6]. Salah satu asumsi pada sistem rekomendasi tradisional adalah asumsi bahwa keinginan pengguna tidak berubah dan mengesampingkan hubungan antara keinginan dengan aspek-aspek lain yang memengaruhi kebutuhan tersebut, sehingga sistem rekomendasi tradisional memberikan informasi yang sama untuk semua pengguna dengan tidak melakukan personalisasi sesuai dengan aspek-aspek tersebut [7].

Untuk mengatasi tantangan ini, sistem rekomendasi telah dikembangkan untuk menyediakan layanan rekomendasi yang dipersonalisasi dan telah mendapatkan perhatian yang meningkat, baik dalam penelitian akademis maupun industri [7]. Salah satu teknik yang paling terkenal adalah CF. Konsep utama CF adalah mendapatkan rekomendasi berdasarkan kesamaan minat pengguna dengan menganalisis preferensi setiap pengguna berdasarkan riwayat transaksi dan kemudian membuat rekomendasi berdasarkan preferensi orang lain yang memiliki minat yang sama [7]. *Matrix factorization* (MF) adalah pendekatan umum yang digunakan untuk CF. MF merepresentasikan hubungan antara pengguna dan *item* dengan vektor faktor. Data direpresentasikan sebagai perkalian dari pengguna dan matriks *item*. MF akan menguraikan matriks besar menjadi matriks yang lebih kecil [8]. Teknik ini

<sup>1,2,3,4</sup> Fakultas Teknik Informatika dan Elektro. Pogram Studi Sarjana Sistem Informasi, Institut Teknologi Del, Jl. Sisingamangaraja, Sitoluama, Kecamatan Balige, Toba, Sumatera Utara 22381, INDONESIA (email: <sup>1</sup>rosni@del.ac.id, <sup>2</sup>iss18068@students.del.ac.id; <sup>3</sup>iss18034@students.del.ac.id; <sup>4</sup>iss18054@students.del.ac.id)

[Diterima: 22 Agustus 2022, Revisi: 28 September 2022]

digunakan untuk mengurangi dimensi data, sehingga perhitungan dapat lebih cepat dilakukan tanpa kehilangan makna dari informasi [8].

Metode lain yang digunakan pada penelitian ini adalah *bidirectional encoder representations from transformers* (BERT). Referensi [9] mengusulkan BERT4Rec dengan cara menerapkan BERT pada sistem rekomendasi produk, sedangkan sebuah penelitian lain mengusulkan VCGN-BERT untuk menangkap konteks paling penting dari sebuah kalimat pada sistem pengklasifikasi teks [10]. Namun, pendekatan di atas mengesampingkan pengaruh konteks pada keinginan pengguna. Pada penelitian ini, digunakan BERT sebagai metode *deep learning* untuk mengekstrak konteks atau preferensi untuk setiap pengguna dari informasi kontekstual pengguna dan menggunakannya sebagai masukan ke model MF untuk menghasilkan rekomendasi yang dipersonalisasi. Digunakannya BERT secara khusus terinspirasi oleh keberhasilan BERT dalam pemahaman teks. Kemampuan *deep learning* untuk memproses sumber data yang heterogen membawa lebih banyak peluang untuk merekomendasikan *item* yang beragam dengan data yang tidak terstruktur, seperti data ulasan [11].

*Context-aware recommender systems* (CARS) yang menggabungkan informasi kontekstual telah terbukti meningkatkan kualitas rekomendasi dalam mengembalikan *item* yang paling relevan ke preferensi pengguna [12]–[14]. Pendekatan sebelumnya terutama menggunakan pemodelan topik dalam mengambil konteks yang paling penting untuk setiap pengguna. Kontribusi dalam penelitian ini adalah mengusulkan pendekatan baru pada model rekomendasi MF dengan memanfaatkan *deep learning* yaitu BERT. BERT menggunakan data tinjauan informasi kontekstual sebagai masukan utama model untuk memberikan pemahaman yang mendalam tentang preferensi pengguna, sehingga sistem mampu memberikan saran yang paling relevan kepada pengguna.

## II. TREN PENELITIAN PADA SISTEM PEREKOMENDASI

Telah dilakukan ulasan terhadap tiga jenis sistem rekomendasi, yaitu CF, CARS, MF, dan *deep learning*.

### A. Collaborative Filtering (CF)

Dalam metode CF, pengumpulan dan pemeriksaan informasi didasarkan pada perilaku, aktivitas, atau preferensi pengguna. Metode ini mengantisipasi selera pengguna tertentu dengan menggunakan kesamaan pengguna tertentu dengan pengguna lain [15]. Referensi [16] menggunakan pendekatan berbasis CF dan teknik *clustering* berbasis *bio-inspired clustering* tiga segmen, yaitu untuk pengelompokan pengguna, prediksi, dan hasil rekomendasi, untuk meningkatkan proses pembuatan rekomendasi dan pengelompokan pengguna di Yelp dan TripAdvisor. Hasil prediksi yang konsisten membuktikan bahwa pendekatan ini mengungguli pendekatan sistem rekomendasi lainnya. Referensi [17] mengusulkan metode CF dengan menerapkan *deep learning*, yaitu *restricted Boltzmann machine* (RBM)-*convolutional neural network* (CNN), untuk menyediakan pengetahuan yang baru. Referensi [18] mengusulkan modifikasi CF berbasis pengguna dengan

menghitung kesamaan antara pengguna menggunakan ulasan teks yang disediakan pengguna untuk satu *item* yang ditinjau bersama. Kemudian, skor kesamaan ini digunakan sebagai bobot dalam prediksi peringkat. Dalam studi ini, dihasilkan prediksi peringkat selain CF dengan mempelajari preferensi pengguna dari teks ulasan pengguna atau dari metadata pengguna/*item* jika tidak ada teks ulasan pengguna.

### B. Context-Aware Recommender System (CARS)

*Context-aware* adalah evolusi dari sistem rekomendasi tradisional yang menerapkan informasi konteks untuk meningkatkan kualitas rekomendasi. CARS telah terbukti meningkatkan akurasi rekomendasi dengan menyesuaikan preferensi pengguna untuk situasi kontekstual yang berbeda. Dengan bantuan informasi kontekstual yang tersedia, CARS mengambil alih pemodelan dan memprediksi selera serta preferensi pengguna. Informasi ini biasanya berupa peringkat dan dimodelkan sebagai fungsi, tidak hanya *item* dan pengguna, tetapi juga konteks. Fungsi peringkat dapat didefinisikan sebagai berikut.

$$R : user \times item \times context \rightarrow rating$$

dengan *user* dan *item* adalah domain dari pengguna dan *item*, *rating* adalah domain dari peringkat yang diberikan pengguna terhadap *item*, sedangkan *context* merupakan konteks atau aspek-aspek yang memengaruhi pemberian peringkat tersebut.

Referensi [19] mengusulkan sistem rekomendasi berbasis *context-aware* untuk mempromosikan pembelajaran secara daring kepada setiap pengguna. Dengan menggunakan informasi keterkaitan antara pelajar dan tujuan pembelajaran dari masing-masing pelajar, metode ini menggunakan *K-nearest neighbor* dan *decision tree methods* untuk mengelompokkan pelajar dan menyediakan pembelajaran yang dipersonalisasi. Konteks dinamis telah dibahas untuk pengguna seluler seperti lokasi, waktu, dan kondisi cuaca [4]. Secara spesifik, penelitian ini berbasis kecerdasan buatan *mobile*, sehingga saran dan informasi yang ditawarkan sistem sesuai dan relevan dengan preferensi pengguna. Sementara itu, telah disajikan pula sistem rekomendasi kontekstual menggunakan pendekatan MF untuk meningkatkan kinerja sistem pada kumpulan data yang besar dan melihat pengaruh penggabungan informasi kontekstual dengan sistem rekomendasi tradisional terhadap akurasi hasil rekomendasi [5]. Konteks pengguna yang dipersonalisasi juga telah diusulkan [12], [13]. Secara khusus, [12] mengusulkan *declarative context-aware recommender system* (D-CARS) untuk mengekstrak konteks pengguna yang dipersonalisasi menggunakan pemodelan topik, yaitu *user window non-negative matrix factorization* (UWNMF) dan algoritme *declarative context-aware recommendation* baru berdasarkan *subspace ensemble tree model* (SETM) untuk membangun profil pengguna yang dipersonalisasi dan mengidentifikasi *item* kandidat. Sementara itu, pada [13], diusulkan konteks yang dipersonalisasi secara interaktif dengan mengambil umpan balik dari pengguna selama interaksi dan mempelajari preferensi pengguna berdasarkan umpan balik ini. Berbeda dengan pendekatan-pendekatan sebelumnya, pada penelitian ini diusulkan untuk menemukan konteks yang paling penting bagi pengguna serta jumlah konteks yang paling

optimal untuk merepresentasikan kebutuhan pengguna tanpa mengurangi kemampuan algoritme untuk mengembalikan *item* yang paling relevan sesuai profil target pengguna.

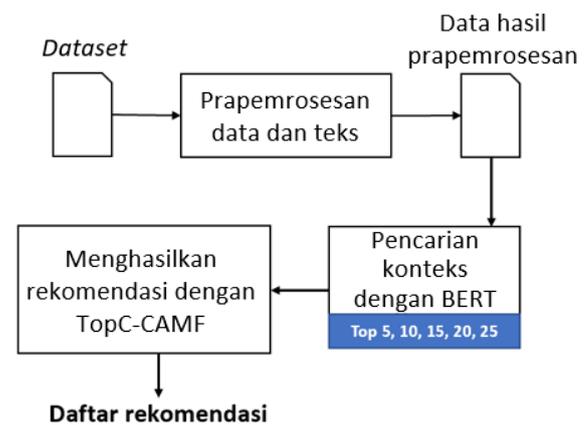
### C. Matrix Factorization (MF)

Dalam situasi ketika sistem rekomendasi terhubung ke matriks peringkat *item*, MF diusulkan untuk memecah matriks besar menjadi yang lebih kecil. Kenyataannya adalah ada banyak pengguna dan *item* dalam pendekatan ini dan banyak di antaranya belum dinilai atau dibeli oleh pengguna. Secara tidak langsung, matriks ini akan makin membesar dan menjadi *sparse*, sehingga solusi untuk menangani *sparsity* pada teknik ini perlu diusulkan agar dimensi data menjadi lebih kecil [8]. Beberapa penelitian telah menjawab permasalahan ini dengan menggunakan informasi jaringan sosial pengguna sebagai konteks [20] dan perbaikan pada preferensi pengguna [21]. Secara khusus, sebuah penelitian mengusulkan metode rekomendasi berdasarkan jaringan sosial menggunakan teknik MF [20]. Penelitian tersebut mempertimbangkan faktor preferensi dan hubungan sosial antara pengguna dan mengklasifikasikan pengguna yang mencapai hasil kinerja yang unggul. Selain itu, berdasarkan penelitian ini, MF mampu menjadi solusi dalam mengatasi *sparsity* data dan memiliki dampak yang signifikan dalam penggunaannya dengan informasi pengguna yang multidimensi. Pada [21], sebuah pendekatan MF berbasis *clustering*, yaitu *cluster refinement on preference embedded MF* (CREPE MF), telah diperkenalkan. Algoritme ini didasarkan pada *clustering* dua tahap, yaitu integrasi jaringan preferensi dan jaringan kesamaan antar *item* yang menggunakan subgraf jaringan sosial pada *dataset* Yelp. Disebutkan bahwa jaringan preferensi dapat menangkap preferensi pengguna lebih baik dalam matriks fitur laten pengguna dibandingkan dengan jejaring sosial.

Pada penelitian ini, digunakan juga metadata pengguna dan metadata *item* sebagai tambahan peringkat pengguna terhadap *item*. Selain itu, konteks yang spesifik kepada pengguna juga dipilih dari ulasan pengguna terhadap *item*.

### D. Deep Learning

Sistem rekomendasi berbasis *deep learning* diusulkan untuk melatih jaringan saraf tiruan dengan mempelajari representasi data secara otomatis, seperti teks, video, dan gambar. Bentuk representasi yang digunakan dalam penelitian ini adalah teks berupa ulasan pengguna terhadap suatu *item*. Model berbasis *deep learning* telah digunakan untuk mempelajari properti *item* dan perilaku pengguna berdasarkan teks ulasan yang disebut model *deep cooperative neural networks* (DeepCoNN) [22]. Model ini mampu mengekstrak informasi semantik dari ulasan dengan menggunakan teknik penyisipan kata yang telah dilatih untuk mempelajari faktor laten antara pengguna dan *item*. Hal ini mirip dengan MF, tetapi menambahkan penggunaan jaringan saraf sehingga akurasi prediksi dan kinerja sistem secara keseluruhan dimaksimalkan. Pada [23], diusulkan sebuah pendekatan dengan *graph convolutional matrix completion* (GC-MC) yang menggunakan kerangka kerja *encoder* otomatis berbasis grafik untuk penyelesaian matriks dan dapat digeneralisasi untuk menyertakan informasi sekunder dari pengguna dan *item*. Sementara itu, diusulkan pendekatan



Gbr. 1 Kerangka kerja TopC-CAMF.

model bahasa prapelatihan besar seperti BERT, yang telah diterapkan pada masalah peringkat teks dan menunjukkan kinerja yang unggul pada beberapa kumpulan data, yaitu *dataset* MS MAR-CO dan TREC-COVID [24]. Di sisi lain, dalam penelitian ini, pendekatan *deep learning* yaitu BERT digunakan untuk menyaring konteks kata menjadi peringkat ulasan yang dapat menggambarkan ulasan pengguna dengan mempelajari konteks kata berdasarkan kata yang berada pada sekitar kata tersebut (*context words*).

## III. METODOLOGI

Pada bagian ini, dijelaskan kerangka pendekatan yang diusulkan, yaitu *TopC-Context-aware Matrix Factorization* (CAMF), seperti yang digambarkan pada Gbr. 1. Ada tiga komponen utama TopC-CAMF: 1) data dan prapemrosesan teks; 2) ekstraksi konteks dengan BERT; dan 3) pembuatan rekomendasi menggunakan TopC-CAMF.

### A. Prapemrosesan Teks dan Data

Sebelum menghasilkan daftar rekomendasi, terlebih dahulu disiapkan data dengan prapemrosesan teks dan data. Kemudian, fitur yang diberikan pada data yang telah diproses sebelumnya diekstrak, khususnya teks ulasan pengguna untuk suatu *item*. Teks ulasan ini berisi informasi atau konteks paling penting bagi pengguna ketika memilih *item* secara daring. Selanjutnya, preferensi pengguna dalam berbagai konteks yang signifikan disimulasikan menggunakan konteks diekstrak dari teks tersebut. Memilih konteks yang relevan sangat penting ketika memodelkan preferensi pengguna karena keadaan yang tidak relevan dapat mengurangi efektivitas dan kemanjuran rekomendasi [12], [25]. Detail masing-masing komponen dari TopC-CAMF dijelaskan pada subbagian berikut.

### B. Matrix Factorization (MF)

Pengumpulan informasi dari pengguna lain untuk membuat rekomendasi prediksi di CF membuat hubungan pengguna dan *item* membentuk matriks peringkat. Matriks peringkat ini biasanya tidak lengkap karena umumnya pengguna hanya memberikan peringkat pada produk tertentu, sehingga ada entri data yang hilang dalam matriks. Nilai yang hilang dicari sehingga rekomendasi dapat dipersonalisasi dengan tepat menggunakan model variabel laten. Metode yang

direkomendasikan untuk menemukan variabel tersembunyi ini adalah MF karena memberikan solusi untuk skalabilitas dan akurasi prediksi yang lebih baik dalam menemukan struktur tersembunyi dalam data besar. Prediksi dengan MF pada nilai ulasan pengguna ( $r_{ui}$ ) diformulasikan pada (1).

$$\hat{r}_{ui} = \mu + b_u + b_i + q_i^T p_u \quad (1)$$

dengan  $\mu$  merupakan peringkat rata-rata dari semua produk serta parameter  $b_u$  dan  $b_i$  merupakan nilai deviasi teramati dari pengguna  $u$  dan item  $i$ . Untuk item  $i$ ,  $q_i$  mengukur besarnya sebuah item memiliki faktor tersebut, positif atau negatif. Untuk pengguna  $u$ , elemen  $p_u$  mengukur kadar ketertarikan pengguna terhadap faktor tertentu, bisa positif atau negatif. Hasil perkalian dari  $q_i^T p_u$  menggambarkan interaksi antara pengguna  $u$  dan item  $i$  terhadap karakteristik dari item tersebut.

### C. Context-Aware Matrix Factorization (CAMF)

Secara umum, *context awareness* dapat didefinisikan sebagai proses untuk menganalisis, mengekstrak, dan memanfaatkan data kontekstual untuk menyediakan fungsi tertentu yang sesuai dengan konteks saat ini dari tugas tertentu. Dalam penelitian ini, informasi kontekstual digabungkan dengan tujuan menghasilkan saran yang lebih relevan dengan menyesuaikannya terhadap situasi kontekstual pengguna. Ada tiga pendekatan model CAMF yang menangani konteks secara berbeda [26]. Untuk CAMF-C, diasumsikan bahwa setiap nilai konteks memiliki pengaruh global pada peringkat secara independen dari item tersebut. CAMF-C menggunakan satu parameter untuk setiap nilai faktor kontekstual. Model kedua adalah CAMF-CI, yang akan menggunakan satu parameter untuk setiap pasangan nilai dan item kontekstual. Dengan pemodelan seperti ini, menangkap faktor kontekstual akan memiliki efek yang berbeda pada peringkat, tergantung pada item. Ekspresi untuk prediksi peringkat dengan CAMF ditunjukkan pada (2) [26].

$$r_{ui c_1 \dots c_k} = \vec{v}_u \times \vec{q}_i + \bar{r} + b_u + \sum_{j=1}^k B_{ij} c_j \quad (2)$$

dengan  $r_{ui c_1 \dots c_k}$  adalah hasil prediksi terhadap pengguna  $u$  untuk item  $i$  dengan nilai konteks  $c_1 \dots c_k$ . Variabel  $\vec{v}_u$  dan  $\vec{q}_i$  adalah vektor pengguna  $u$  dan item  $i$ . Model rekomendasi yang dicobakan dalam penelitian ini, dengan AC-CAMF merupakan varian dari TopC-CAMF yang diusulkan, adalah sebagai berikut.

1) *Context-Aware Matrix Factorization (CAMF)*: Model CAMF merupakan model perbandingan (*baseline*) yang menggunakan informasi kontekstual saat memberikan prediksi peringkat. Informasi kontekstual yang digunakan adalah data tinjauan pengguna yang tidak melalui proses apa pun (asli). Metode ini dianalisis untuk melihat pengaruh ulasan data asli dalam memberikan rekomendasi kepada pengguna.

2) *Top Dominant Context-Aware Matrix Factorization (TopC-CAMF)*: TopC-CAMF adalah model berbasis CAMF yang menggunakan variasi pada jumlah konteks yang digunakan saat menghasilkan rekomendasi. Pada data ulasan pengguna, preferensi pengguna akan diekstraksi dengan lima variasi konteks, yaitu *top 5*, *top 10*, *top 15*, *top 20*, dan *top 25*.

Kemudian, berdasarkan lima variasi konteks, satu variasi konteks yang memiliki kinerja terbaik akan dipilih (sebagai konteks dominan) dalam melakukan preferensi pengguna.

3) *All Context-Context-aware Matrix Factorization (AC-CAMF)*: AC-CAMF adalah model berbasis CAMF dengan menggunakan semua konteks yang ada yang diperoleh dari teks ulasan pengguna. Metode ini dianalisis untuk melihat pengaruh keseluruhan konteks dalam memberikan rekomendasi kepada pengguna.

### D. Bidirectional Encoder Representations from Transformer (BERT)

BERT merupakan model transformator dua arah yang mempelajari konteks kata berdasarkan kata-kata di sekitarnya (*context words*), sehingga model ini memiliki pemahaman konteks yang lebih dalam dibandingkan model bahasa satu arah. Ada langkah-langkah yang dilakukan untuk mengekstrak konteks dari data ulasan pengguna menggunakan BERT, yaitu sebagai berikut.

1) *Extract Feature*: Tahap ini merupakan langkah awal dalam proses implementasi model BERT. Data yang telah diproses sebelumnya akan diproses dengan tujuan untuk mengekstrak daftar kandidat kata kunci dari dokumen tinjauan.

2) *Word Embedding*: Setelah daftar kandidat kata kunci diperoleh, data ulasan dan daftar kandidat akan diubah masing-masing ke dalam bentuk vektor. Untuk tujuan ini, digunakan BERT karena telah menunjukkan hasil yang baik untuk tugas kesamaan dan parafrasa.

3) *Extract Keyword*: Tahap ini dilakukan untuk mengekstrak kata dan frasa yang paling relevan dengan data yang ditinjau. Pada penelitian ini digunakan metode KeyBERT untuk mengekstrak kata kunci dengan memanfaatkan model bahasa BERT. Digunakan penyematan BERT dan *cosine similarity* untuk menentukan subfrasa dalam dokumen yang paling mirip dengan dokumen itu sendiri. Hasil *embedding* pada tahap sebelumnya akan diekstraksi untuk kata-kata, kemudian akan dipilih kata-kata yang paling mirip sesuai dengan *cosine similarity*.

$$\text{similarity} = \cos(\theta) = \frac{A \cdot B}{\|A\| \cdot \|B\|} \quad (3)$$

dengan  $A$  merepresentasikan vektor kata  $A$  dan  $B$  merepresentasikan vektor dari kata  $B$ . Kemiripan dua buah kata dilakukan dengan mengalikan vektor  $A \cdot B$  dengan  $\|A\| \|B\|$  masing-masing adalah panjang dari vektor  $A$  dan vektor  $B$ . hal ini berbeda dengan kerangka kerja pada penelitian terdahulu, yaitu hanya menggunakan nama *item* sebagai konteks untuk menghasilkan sistem rekomendasi *item* [9]. Sementara itu, pada [10] dihasilkan klasifikasi teks dengan mengekstrak konteks utama dari setiap kalimat dan menggabungkan konteks tersebut menggunakan *graph neural network*. Pada penelitian ini, konteks yang paling penting bagi seorang pengguna dicari berdasarkan ulasan teks pengguna. Kemudian, jumlah konteks yang digunakan untuk menghasilkan rekomendasi dievaluasi terlebih dahulu untuk memastikan bahwa konteks tersebut dapat meningkatkan kinerja sistem rekomendasi.

## IV. METODE EVALUASI EKSPERIMEN

TABEL I  
DATASETA. *Experimental Setup*

Eksperimen dilakukan dengan menggunakan tiga *dataset*, yaitu *dataset* produk Beauty, Office, dan InCarMusic, seperti yang disajikan pada Tabel I. *Dataset* produk Beauty dan Office diambil dari Amazon Product Data, yang berisi ulasan produk dan metadata. Kumpulan data InCarMusic diambil dari Github dan merupakan data yang berisi informasi tentang konteks/faktor dan pengaruhnya terhadap pengemudi mobil. Pada data Beauty dan Office, digunakan konteks ulasan dan kata kunci. Pada InCarMusic, karena kumpulan data tidak memiliki ulasan, digunakan informasi kontekstual apa pun yang dimiliki kumpulan data, seperti gaya mengemudi, suasana hati, dan cuaca.

*Dataset* dibagi menjadi data pelatihan dan data pengujian, sebesar 90% dan 10%. Data pelatihan digunakan oleh model untuk mempelajari preferensi pengguna mengingat konteksnya dan data pengujian digunakan untuk menilai kinerja model.

B. *Metode Evaluasi*

Evaluasi digunakan sebagai dasar atau *benchmark* untuk mengetahui kinerja model yang telah dibangun dalam membuat prediksi dan memberikan rekomendasi. Eksperimen ini bertujuan untuk menjawab tiga pertanyaan penelitian (*research question*, RQ) sebagai berikut.

1. [RQ-1]: Bagaimana cara mengidentifikasi konteks yang memengaruhi preferensi pengguna dari ulasan teks pengguna pada *item* dan/atau metadata dari *item* dan pengguna?
2. [RQ-2]: Bagaimana jumlah konteks yang digunakan dapat memengaruhi kinerja dari sistem rekomendasi?
3. [RQ-3]: Seefektif apakah metode yang diusulkan, yaitu TopC-CAMF, dalam merekomendasikan *item* yang paling relevan kepada pengguna?

Ketiga RQ ini dievaluasi menggunakan tiga kategori metrik, yaitu metrik akurasi prediktif, meliputi *mean average error* (MAE), *mean squared error* (MSE), dan *root mean square error* (RMSE); metrik akurasi peringkat (*normalized discounted cumulative gain*, NDCG); dan metrik akurasi klasifikasi (*recall*). Metrik akurasi prediktif melihat keefektifan model rekomendasi dalam memprediksi peringkat dan memberikan rekomendasi kepada pengguna. Dalam (4)-(6),  $N$  adalah jumlah data sampel,  $Y_i$  adalah label dari data yang aktual, dan  $Y'_i$  adalah label hasil prediksi.

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i - Y'_i| \quad (4)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - Y'_i)^2 \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y'_i)^2} \quad (6)$$

Metrik akurasi peringkat mengukur kemampuan sistem pemberi rekomendasi untuk menempatkan *item* yang paling relevan bagi pengguna para peringkat atas dibandingkan pada peringkat akhir. Pada (7),  $Z$  adalah normalisasi yang membuat peringkat NDCG bernilai sempurna dengan nilai 1 dan  $r(j)$  adalah relevansi posisi  $j$  pada hasil pemeringkatan.

<i>Dataset</i>	Beauty	Office	IncarMusic
#Pengguna	167.725	110.472	42
#Item	29.004	14.224	139
#Ulasan	252.056	138.084	4.012
Konteks	ulasan, kata kunci	ulasan, kata kunci	judul, gaya mengemudi, pemandangan, suasana hati, fenomena alam, tipe jalan, kantuk, kondisi lalu lintas, cuaca
Ukuran	336 MB	238 MB	93 KB

$$NDCG = \frac{1}{Z} \sum_{j=1}^n \frac{2^{r(j)}}{\log 2(1+j)} = \sum_{j=1}^n \frac{G_i}{D_i} \quad (7)$$

Metrik akurasi klasifikasi mengukur frekuensi sistem rekomendasi membuat keputusan yang benar atau salah tentang baik atau tidaknya suatu *item* untuk direkomendasikan. Pada (8),  $TP$  adalah benar positif dan  $FN$  adalah salah negatif.

$$Recall = \frac{TP}{TP+FN} \quad (8)$$

## V. HASIL DAN PEMBAHASAN

Bagian ini menjelaskan hasil eksperimen dan diskusi hasil yang diperoleh.

A. *Mengidentifikasi Preferensi Pengguna dalam Hal Konteks*

Untuk menjawab RQ1, diidentifikasi preferensi pengguna dalam konteks dari ulasan teks pengguna yang dinyatakan untuk *item*, metadata *item*, dan metadata pengguna. Dipercaya bahwa tidak semua konteks memengaruhi pengguna dalam mengambil keputusan. Oleh karena itu, pemilihan konteks yang paling penting bagi pengguna harus dilakukan dengan teliti. Di sini, konteks pengguna teratas (5, 10, 15, 20, 25) dinilai dan kinerja model dalam mengembalikan rekomendasi saat memanfaatkan jumlah konteks yang bervariasi ini dibandingkan. Pada subbagian berikutnya, disajikan langkah-langkah untuk menangkap konteks yang paling berpengaruh untuk setiap pengguna.

1) *Prapemrosesan Teks*: Informasi kontekstual pengguna, seperti data ulasan, merupakan data yang bentuknya tidak terstruktur dan tidak konsisten, sehingga diperlukan proses untuk membersihkan dan menyiapkan data tersebut agar dapat digunakan dengan baik. Prapemrosesan teks yang dilakukan meliputi pengubahan ke huruf kecil, penghilangan tanda baca, penghilangan kata berhenti, dan *lemmatization*. Semua data teks diubah menjadi huruf kecil sehingga penggunaan huruf kapital setara dalam data ulasan. Penghapusan tanda baca dilakukan untuk menghilangkan karakter atau derau yang tidak relevan dan tidak berpengaruh pada pemrosesan, seperti tanda baca dan karakter lain yang tidak dikenali dalam kumpulan data. Penghilangan kata berhenti dilakukan untuk menyaring kata-kata penting, sedangkan *lemmatization* digunakan untuk mengurangi atau mengubah kata menjadi bentuk dasar yang bermakna. Misalnya, diberikan ulasan dari seorang pengguna "I BOUGHT THIS Avalon Organics: Biotin B Complex

TABEL II  
VARISASI JUMLAH KONTEKS

<b>Ulasan Pengguna</b>	<i>I have a very dry, frizzy hair. I have tried many hair products and cannot make it look sleek. I bought KMS product through my friend recommendation. It was not overnight change, but after a month, my hair looks much sleek. The conditioner is very rich and I do like the light smell a lot. The product arrives on time although the package looks different from what is on the picture.</i>
<b>Top 5</b>	<i>dry, conditioner, sleek, hair, frizzy.</i>
<b>Top 10</b>	<i>change, package, recommendation, product, products, dry, conditioner, sleek, hair, frizzy.</i>
<b>Top 15</b>	<i>smell, try, buy, light, look, change, package, recommendation, product, products, dry, conditioner, sleek, hair, frizzy.</i>
<b>Top 20</b>	<i>month, make, arrive, overnight, different, smell, try, buy, light, look, change, package, recommendation, product, products, dry, conditioner, sleek, hair, frizzy.</i>
<b>Top 25</b>	<i>kms, like, picture, friend, time, month, make, arrive, overnight, different, smell, try, buy, light, look, change, package, recommendation, product, products, dry, conditioner, sleek, hair, frizzy.</i>

*Thickening Conditioner, 14 oz AND THE SHAMPOO AND USED IT DURING THE WHOLE 2012 AND NOT ONLY DID NOT THICKENED MY HAIR BUT IT MADE IT VERY DRIED*". Hasil dari pemrosesan ulasan tersebut adalah "buy avalon organics biotin b complex thicken conditioner oz shampoo use whole thicken hair make dry". Di sini dapat dilihat bahwa pada ulasan pengguna tersebut terdapat beberapa kata yang sering muncul, seperti kata "I" dan "the", yang dihilangkan setelah prapemrosesan kata. Teks yang telah diproses sebelumnya akan digunakan untuk mengekstrak kandidat konteks pada langkah berikutnya. Kandidat konteks ini kemudian digunakan sebagai model dari preferensi pengguna.

2) *Mengekstrak Kandidat Konteks*: Pada penelitian ini, digunakan BERT untuk mengekstrak konteks pengguna dalam tiga langkah. Pertama, dihasilkan daftar konteks kandidat dengan mengambil kata-kata penting dari data yang telah diproses sebelumnya, yang mewakili preferensi pengguna mengenai suatu *item*. Pada penelitian ini, digunakan BERT dengan *n-gram* pada rentang (0, 1), yang menentukan panjang kandidat konteks yang akan dihasilkan, misalnya *unigram* atau konteks yang terdiri atas satu kata saja. Sebagai contoh, diketahui ulasan dari seorang pengguna "love moisturizer would recommend someone dry skin fine line wrinkle use brand day night serum". Maka, konteks kandidat yang dihasilkan adalah "[brand, day, dry, fine, line, love, moisturizer, night, recommend, serum, skin, use, wrinkle]". Tampak jelas bahwa pencarian kandidat konteks mengembalikan kata-kata penting tanpa merusak makna ulasan itu sendiri. Kedua, dievaluasi kesamaan di antara konteks dan kemudian konteks yang paling penting dikembalikan sebagai konteks *top 5, top 10, top 15, top 20, dan top 25*. *Top 5* dapat diartikan sebagai lima konteks terpenting yang mewakili preferensi pengguna. Informasi ini diambil dengan terlebih dahulu menyajikan ulasan pengguna dalam bentuk vektor menggunakan BERT. Misalnya, pada

TABEL III  
PERBANDINGAN JUMLAH KONTEKS PADA CAMF BERDASARKAN METRIK MSE, RMSE, DAN MAE

Dataset	Top	Metrik		
		MSE	RMSE	MAE
Beauty	5	<b>0,2825</b>	<b>0,5315</b>	<b>0,3841</b>
	10	0,3196	0,5653	0,4137
	15	0,3196	0,5653	0,4137
	20	0,3924	0,6264	0,4553
	25	0,3924	0,6264	0,4553
Office	5	<b>0,2643</b>	<b>0,5141</b>	<b>0,3806</b>
	10	0,3093	0,5561	0,4182
	15	0,3093	0,5561	0,4182
	20	0,3093	0,5561	0,4182
	25	0,3093	0,5561	0,4182
InCarMusic	5	<b>0,4149</b>	0,6441	0,5084
	10	0,4185	<b>0,6440</b>	<b>0,5074</b>
	15	0,4185	0,6440	0,5074
	20	NA	NA	NA
	25	NA	NA	NA

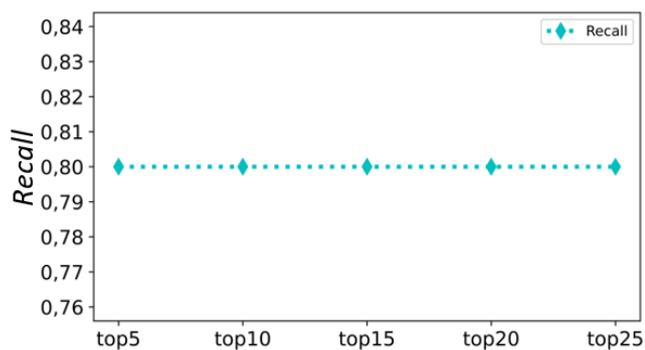
ulasan pengguna yang diberikan pada Tabel II, konteks yang diambil dapat berupa pelembab, kulit, dan serum. Terakhir, setelah diperoleh bentuk vektor dari daftar kata kunci kandidat dan dokumen ulasan, dilakukan ekstraksi konteks dengan mencari kandidat konteks yang serupa dan mewakili dokumen ulasan. Kesamaan kandidat konteks dinilai menggunakan *cosine similarity*.

Perhitungan kesamaan dilakukan dengan menghitung ukuran kesamaan antara semua kandidat *keyword embeddings* dan *embedding document*. Kemudian, hasilnya diurutkan dalam urutan menurun untuk mendapatkan konteks relevan teratas. Ada lima variasi konteks yang diekstraksi, yaitu *top 5, top 10, top 15, top 20, dan top 25*, seperti yang digambarkan pada Tabel II. Dari Tabel II, dapat dilihat bahwa dengan ulasan pengguna, dapat diambil konteks penting dari pengguna. Misalnya, untuk konteks *top 5*, dimiliki 'dry', 'conditioner', 'sleek', 'hair', dan 'frizzy'. Jika hal ini diperluas ke 10 konteks (*top 10*), akan dimiliki konteks tambahan seperti 'produk' yang dapat dilihat sebagai konteks yang lebih umum daripada konteks *top 5* sebelumnya, 'kondisioner'. Dengan demikian, makin banyak konteksnya, makin umum preferensi dan makin sedikit kemampuannya dalam membedakan satu pengguna dengan yang lain.

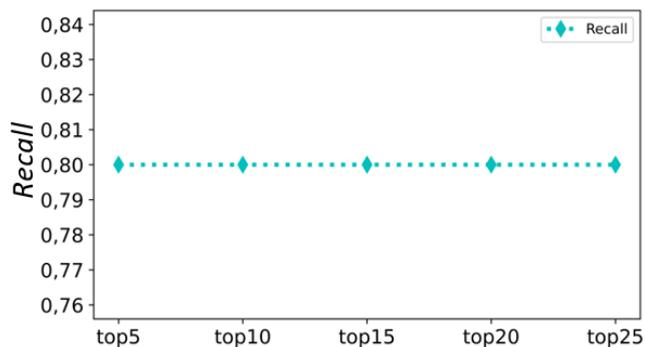
**B. Pengaruh Jumlah Konteks terhadap Pemodelan Preferensi Pengguna**

Untuk menjawab RQ2, dinilai kinerja model dalam mengembalikan daftar rekomendasi dengan jumlah konteks yang bervariasi untuk setiap pengguna. Secara khusus, setiap preferensi pengguna dimodelkan menggunakan konteks *top 5, top 10, top 15, top 20, dan top 25*. Mengingat *dataset InCarMusic* tidak memiliki teks ulasan pengguna sebagai konteks, tetapi konteks yang telah ditentukan, untuk *dataset* ini, hanya dimiliki konteks *top 5, top 10, dan top 15*.

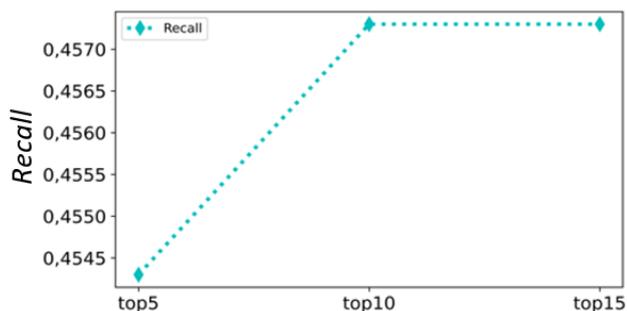
Tabel III menunjukkan kinerja model, yakni MSE, RMSE, dan MAE memberikan jumlah konteks yang berbeda. Kinerja terbaik ditunjukkan dengan nilai yang dicetak tebal. Dari Tabel III dapat dilihat bahwa konteks *top 5* menunjukkan kinerja yang



(a)



(b)



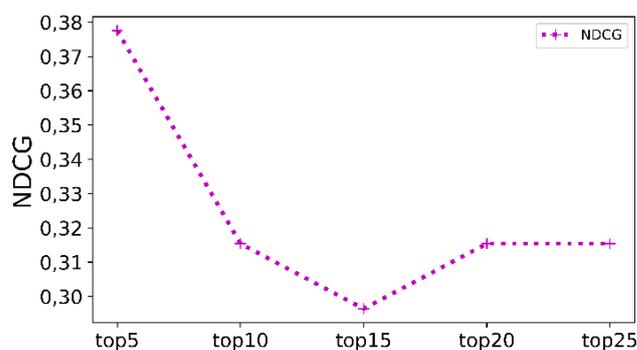
(c)

Gbr. 2 Pengaruh perbedaan jumlah konteks terhadap kinerja sistem perekomendasi berdasarkan metrik *recall* pada ketiga *dataset*, (a) *dataset* Office, (b) *dataset* Beauty, (c) *dataset* InCarMusic.

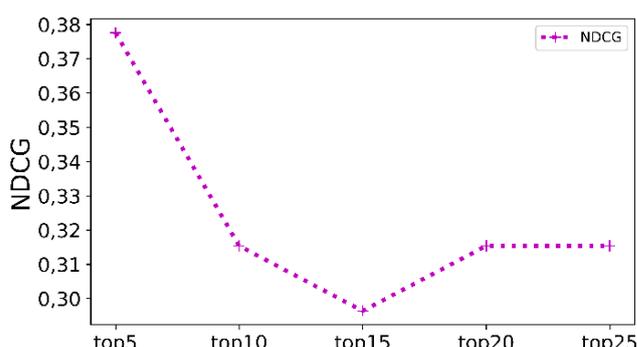
paling baik dengan mengembalikan nilai *error* terendah, yaitu 0,2825, 0,5315, dan 0,3841 pada metrik MSE, RMSE, dan MAE untuk *dataset* Beauty; dan 0,2643, 0,5141, serta 0,3806 untuk *dataset* Office. *Top 10* menampilkan jumlah konteks yang ideal untuk *dataset* InCarMusic. Hal ini disebabkan oleh konteks InCarMusic yang tidak memadai dan tidak adanya teks ulasan pengguna.

Namun, dapat dilihat bahwa perbedaan kinerja dengan jumlah konteks *top 5* dan *top 10* pada InCarMusic tidak begitu signifikan. Maka, dapat disimpulkan bahwa dengan menggunakan metrik MSE, RMSE, dan MAE, konteks *top 5* masih lebih baik dibandingkan dengan alternatif jumlah konteks lainnya.

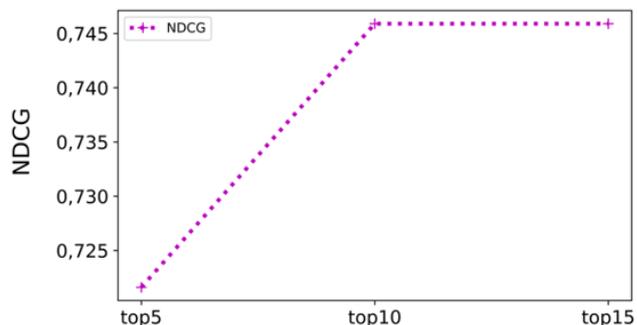
Pengaruh jumlah konteks yang berbeda dalam preferensi pengguna untuk kinerja rekomendasi digambarkan pada Gbr. 2 dan Gbr. 3. Hasil pada Gbr. 2 menunjukkan bahwa dalam hal



(a)



(b)



(c)

Gbr. 3 Pengaruh variasi jumlah konteks terhadap kinerja sistem perekomendasi berdasarkan metrik NDCG pada ketiga *dataset*, (a) *dataset* Office, (b) *dataset* Beauty, (c) *dataset* InCarMusic.

*recall* untuk *dataset* Office dan Beauty, model dapat mengembalikan rekomendasi terbaik dengan menggunakan lima konteks paling dominan (*top 5*). Namun, untuk InCarMusic yang tidak memiliki tinjauan pengguna sebagai konteks, penambahan konteks dari lima hingga 10 konteks dapat meningkatkan kinerja model. Ini membuktikan bahwa identifikasi konteks kepentingan sangat penting dalam memahami preferensi pengguna.

Gbr. 3 menunjukkan bahwa *top 5* adalah jumlah konteks terbaik untuk *dataset* Office dan Beauty dengan mengembalikan nilai NDCG tertinggi, sedangkan untuk *dataset* InCarMusic dengan konteks yang buruk, model perlu meningkatkan konteks untuk mendapatkan preferensi pengguna yang lebih baik. Jadi, untuk InCarMusic, penarikan yang lebih baik ditampilkan dalam konteks *top 10*.

TABEL IV  
PERBANDINGAN TOPC-CAMF DENGAN KOMPETITOR BERDASARKAN  
METRIK MSE

Dataset	TopC-CAMF	CAMF	AC-CAMF
Beauty	<b>0,2825</b>	0,3199	0,5066
Office	<b>0,2643</b>	0,3114	0,5375
InCarMusic	0,4149	<b>0,4148</b>	0,6151

TABEL V  
PERBANDINGAN TOPC-CAMF DENGAN KOMPETITOR BERDASARKAN  
METRIK MAE

Dataset	TopC-CAMF	CAMF	AC-CAMF
Beauty	<b>0,3841</b>	0,5329	0,4138
Office	<b>0,3806</b>	0,5573	0,4187
InCarMusic	<b>0,5084</b>	0,6054	0,5074

TABEL VI  
PERBANDINGAN TOPC-CAMF DENGAN KOMPETITOR BERDASARKAN  
METRIK NDCG

Dataset	TopC-CAMF	CAMF	AC-CAMF
Beauty	<b>0,3776</b>	0,3389	0,3216
Office	<b>0,3528</b>	0,3286	0,3490
InCarMusic	0,7216	0,7074	<b>0,7459</b>

### C. Perbandingan Efektivitas Model terhadap Kompetitor

Untuk menjawab RQ3, TopC-CAMF penelitian ini dibandingkan dengan CAMF dan alternatif lain yang diberi nama AC-CAMF, dengan metrik evaluasi berbasis *error* (RMSE, MAE, dan MSE) serta metrik peringkat (NDCG dan *recall*). Perbandingan kompetitor untuk ketiga *dataset* dapat dilihat pada Tabel IV dan Tabel V. Detail ketiga metode dijelaskan sebagai berikut.

1) *TopC-CAMF*: Metode ini merupakan CAMF yang diusulkan, yang menggunakan konteks *top 5* untuk memodelkan preferensi pengguna.

2) *CAMF*: Metode ini tidak menggunakan konteks yang berasal dari teks ulasan pengguna.

3) *AC-CAMF*: AC-CAMF merupakan metode alternatif yang diusulkan. Metode ini tidak menyaring jumlah konteks yang akan digunakan untuk memodelkan pengguna.

Model TopC-CAMF memprediksi peringkat lebih akurat daripada dua pendekatan lainnya untuk seluruh *dataset* yang diperiksa dengan menggunakan MSE, RMSE, dan MAE. Hal ini terjadi karena metode CAMF dan AC-CAMF tidak mendukung strategi TopC-CAMF untuk memilih konteks yang paling penting untuk mengekspresikan preferensi pengguna. Konteks diperhitungkan saat membuat saran untuk AC-CAMF. Akan tetapi, metode ini menggunakan semua konteks, bukan hanya yang paling penting.

Tabel VI menunjukkan perbandingan metode dalam hal nilai NDCG. Berdasarkan perbandingan ketiga model dalam hal nilai NDCG, model TopC-CAMF lebih unggul daripada CAMF dan AC-CAMF pada semua *dataset*. Di sini tidak ada perbedaan mencolok di antara strategi-strategi dalam hal *recall*. Untuk *dataset* Beauty, Office, dan InCarMusic, masing-masing TopC-CAMF menghasilkan berturut-turut, 0,8000, 0,7900, dan

0,4543. Sebaliknya, CAMF memberikan penarikan yang sama untuk kumpulan data Beauty, dengan penarikan yang lebih tinggi untuk Office (0,8250), tetapi penarikan yang lebih rendah untuk Office (0,3655). Di sisi lain, AC-CAMF menghasilkan hasil yang lebih baik untuk *dataset* Beauty dan Office, masing-masing 0,8200 dan 0,8500, serta 0,4573 untuk *dataset* InCarMusic. Terlepas dari kenyataan bahwa ada lebih sedikit pengguna dan *item* dalam *dataset* InCarMusic, tampaknya AC-CAMF memiliki kinerja lebih baik. Akibatnya, hampir semua *item* dapat diambil dengan tepat untuk pengguna target ketika model memberikan hasil dalam hal penarikan.

## VI. KESIMPULAN

Dalam penelitian ini, diusulkan pendekatan baru MF yang menggunakan konteks dalam sistem rekomendasi, yaitu TopC-CAMF. Dijawab tiga pertanyaan penelitian, yaitu RQ-1 tentang cara mengidentifikasi konteks penting pengguna; RQ-2 tentang pemeriksaan jumlah konteks yang optimal dalam mewakili profil pengguna setelah konteks kandidat diambil; dan RQ-3 tentang perbandingan TopC-CAMF yang diusulkan dengan CAMF dan pendekatan alternatif AC-CAMF.

TopC-CAMF memodelkan preferensi pengguna melalui konteks yang terkandung pada teks ulasan pengguna tersebut dan metadata *item* serta pengguna. Konteks yang paling memengaruhi keputusan pengguna dijadikan sebagai representasi dari profil pengguna, yaitu konteks *top 5*. Kemudian, keefektifan metode yang diusulkan dalam hal menghasilkan rekomendasi *item* kepada pengguna dievaluasi, dengan menggunakan beberapa metrik evaluasi. Melalui evaluasi tersebut, terbukti bahwa TopC-CAMF mampu melampaui kinerja metode lainnya, yaitu CAMF dan metode alternatif, yaitu AC-CAMF.

Untuk penelitian selanjutnya, akan ditingkatkan kinerja TopC-CAMF untuk menangkap konteks pengguna, termasuk menangkap konteks lainnya yang dapat diturunkan dari konteks semula.

## KONFLIK KEPENTINGAN

Penulis yang namanya tertera pada penelitian dengan judul “TopC-CAMF: Sistem Rekomendasi *Matrix Factorization* Berbasis *Top Context*” menyatakan bahwa tidak ada konflik kepentingan dengan pihak mana pun yang dapat memengaruhi representasi atau interpretasi hasil penelitian ini.

## KONTRIBUSI PENULIS

Konseptualisasi, Rosni Lumbantoran, Ingrid Aritonang, Erika Simaremare, Paulus Simanjuntak; metodologi, Rosni Lumbantoran, Ingrid Aritonang, Erika Simaremare, Paulus Simanjuntak; perangkat lunak, Paulus Simanjuntak, Rosni Lumbantoran; validasi, Rosni Lumbantoran, Ingrid Aritonang, Erika Simaremare, Paulus Simanjuntak; analisis formal, Rosni Lumbantoran; investigasi, Paulus Simanjuntak, Rosni Lumbantoran; sumber daya, Paulus Simanjuntak, Rosni Lumbantoran, Ingrid Aritonang, Erika Simaremare; kurasi data, Rosni Lumbantoran, Erika Simaremare; penulisan—penyusunan draf asli, Rosni Lumbantoran, Erika Simaremare, Ingrid Aritonang, Paulus Simanjuntak; penulisan—

peninjauan dan penyuntingan, Rosni Lumbantoruan, Paulus Simanjuntak, Erika Simaremare, Ingrid Aritonang; visualisasi, Paulus Simanjuntak; pengawasan, Rosni Lumbantoruan; administrasi proyek, Rosni Lumbantoruan.

#### UCAPAN TERIMA KASIH

Penelitian ini didanai oleh Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) Institut Teknologi Del.

#### REFERENSI

- [1] G. Zhang, Y. Liu, dan X. Jin, "A Survey of Autoencoder-Based Recommender Systems," *Front. Comput. Sci.*, Vol. 14, No. 2, hal. 430–450, Apr. 2020.
- [2] A.H. Ali dan M.Z. Abdullah, "Recent Trends in Distributed Online Stream Processing Platform for Big Data: Survey," *2018 1st Annu. Int. Conf. Inf. Sci. (AiCIS)*, 2018, hal. 140–145.
- [3] S. Raza dan C. Ding, "Progress in Context-Aware Recommender Systems-An Overview," *Comput. Sci. Rev.*, Vol. 31, hal. 84–97, Feb. 2019.
- [4] M. C. Rodríguez-Hernández dan S. Ilarri, "AI-Based Mobile Context-Aware Recommender Systems from an Information Management Perspective: Progress and Directions," *Knowl.-Based Syst.*, Vol. 215, hal. 1–29, Mar. 2021.
- [5] M.H. Abdi, G.O. Okeyo, dan R.W. Mwangi, "Matrix Factorization Techniques for Context-Aware Collaborative Filtering Recommender Systems: A Survey," *Comput. Inf. Sci.*, Vol. 11, No. 2, hal. 1–10, Mar. 2018.
- [6] D. Monti, G. Rizzo, dan M. Morisio, "A Systematic Literature Review of Multicriteria Recommender Systems," *Artif. Intell. Rev.*, Vol. 54, No. 1, Jan. 2021.
- [7] Z. Cui, dkk., "Personalized Recommendation System Based on Collaborative Filtering for IoT Scenarios," *IEEE Trans. Serv. Comput.*, Vol. 13, No. 4, hal. 685–695, Jul.-Agu. 2020.
- [8] S. Kulkarni dan S.F. Rodd, "Context Aware Recommendation Systems: A Review of the State of the Art Techniques," *Comput. Sci. Rev.*, Vol. 37, hal. 1–33, Agu. 2020.
- [9] F. Sun, dkk., "Bert4rec: Sequential Recommendation with Bidirectional Encoder Representations from Transformer," *Int. Conf. Inf., Knowl. Manag.*, 2019, hal. 1441–145.
- [10] Z. Lu, P. Du, dan J.-Y. Nie, "VGCN-BERT: Augmenting BERT with Graph Embedding for Text Classification," *Adv. Inf. Retr.*, 2020, hal. 369–382.
- [11] S. Zhang, L. Yao, A. Sun, dan Y. Tay, "Deep Learning Based Recommender System: A Survey and New Perspectives," *ACM Comput. Surv.*, Vol. 52, No. 1, hal. 1–38, Jan. 2020.
- [12] R. Lumbantoruan, X.M. Zhou, Y.L. Ren, dan Z.F. Bao, "D-CARS: A Declarative Context-Aware Recommender System," *IEEE Int. Conf. Data Mining (ICDM)*, 2018, hal. 1152–1157.
- [13] R. Lumbantoruan, X. Zhou, Y. Ren, dan L. Chen, "I-CARS: An Interactive Context-Aware Recommender System," *IEEE Int. Conf. Data Mining (ICDM)*, 2019, hal. 1240–1245.
- [14] R. Lumbantoruan, X. Zhou, dan Y. Ren, "Declarative User-Item Profiling Based Context-Aware Recommendation," *Int. Conf. Adv. Data Mining, Appl.*, 2020, hal. 413–427.
- [15] A.S. Tewari, J.P. Singh, dan A.G. Barman, "Generating Top-N Items Recommendation Set Using Collaborative, Content Based Filtering and Rating Variance," *Procedia Comput. Sci.*, Vol. 132, hal. 1678–1684, 2018.
- [16] R. Logesh, dkk., "Enhancing Recommendation Stability of Collaborative Filtering Recommender System Through Bio-Inspired Clustering Ensemble Method," *Neural Comput., Appl.*, Vol. 32, No. 7, hal. 2141–2164, 2020.
- [17] A.K. Sahoo, C. Pradhan, R.K. Barik, dan H. Dubey, "DeepReco: Deep Learning Based Health Recommender System Using Collaborative Filtering," *Comput.*, Vol. 7, No. 2, Jun. 2019.
- [18] M. Terzi, M. Rowe, M.A. Ferrario, dan J. Whittle, "Text-Based User-kNN: Measuring User Similarity Based on Text Reviews," dalam *User Modeling, Adaptation, and Personalization. Lecture Notes in Computer Science*, Vol. 8538, V. Dimitrova, dkk, Eds., Cham, Denmark: Springer, 2014, hal. 195–206.
- [19] W. Intayoad, T. Becker, dan P. Temdee, "Social Context-Aware Recommendation for Personalized Online Learning," *Wirel. Pers. Commun.*, Vol. 97, No. 1, hal. 163–179, Nov. 2017.
- [20] C. Xu, "A Novel Recommendation Method Based on Social Network Using Matrix Factorization Technique," *Inf. Process., Manag.*, Vol. 54, No. 3, hal. 463–474, Mei 2018.
- [21] L.R. Divyaa, A. Tamhane, dan N. Pervin, "A Clustering Based Social Matrix Factorization Technique for Personalized Recommender Systems," *AMCIS 2018 Proc.*, 2018, hal. 1–10.
- [22] L. Zheng, V. Noroozi, dan P.S. Yu, "Joint Deep Modeling of Users and Items Using Reviews for Recommendation," *Proc. 10th ACM Int. Conf. Web Search, Data Min. (WSDM 2017)*, 2017, hal. 425–433.
- [23] R. van den Berg, T.N. Kipf, dan M. Welling, "Graph Convolutional Matrix Completion," 2017, *arXiv:1706.02263v2*.
- [24] H. Zhuang, dkk., "Ensemble Distillation for BERT-Based Ranking Models," *Proc. 2021 ACM SIGIR Int. Conf. Theory Inf. Retr. (ICTIR 2021)*, 2021, hal. 131–136.
- [25] R. Lumbantoruan, "Declarative Context-Aware Recommendation," Disertasi Ph.D., RMIT University, Melbourne, Australia, 2021.
- [26] L. Baltrunas, B. Ludwig, dan F. Ricci, "Matrix Factorization Techniques for Context Aware Recommendation," *Proc. Fifth ACM Conf. Recommender System.*, 2011, hal. 301–304.