

BAB II

LANDASAN TEORI

2.1 Model Rekomendasi

Model Rekomendasi adalah sebuah alat yang mempermudah pengguna dalam menemukan informasi dari jumlah data yang sangat besar dengan memberikan rekomendasi item yang sesuai dengan preferensi pengguna (Yang et al., 2024). Model ini mengandalkan teknik seperti personalisasi dan pembelajaran representasi untuk mengoptimalkan interaksi antara pengguna dan item, sehingga dapat memberikan rekomendasi yang lebih akurat di berbagai sektor (Kukalakunta et al., 2024).

Model rekomendasi yang umum digunakan, yaitu *content-based filtering*, *collaborative filtering*, dan *hybrid model*. *Content-based filtering* memberikan rekomendasi berdasarkan kemiripan atribut item dengan preferensi pengguna sebelumnya, sedangkan *collaborative filtering* memanfaatkan interaksi antar pengguna dan item, baik melalui pendekatan *user-based* maupun *item-based*. Sementara itu, *hybrid model* menggabungkan keunggulan dari kedua metode sebelumnya untuk meningkatkan akurasi dan mengatasi kelemahan masing-masing, seperti masalah *cold-start* atau *sparse data*. Dengan berbagai pendekatan ini, sistem rekomendasi dapat disesuaikan dengan kebutuhan dan karakteristik data dalam berbagai domain aplikasi.

2.2 *Sentiment analysis*

Sentiment analysis merupakan teknik yang digunakan untuk mengidentifikasi opini, emosi, atau perasaan yang terkandung dalam suatu teks. Teknologi ini bertujuan untuk mengklasifikasikan sentimen dalam teks ke dalam kategori positif atau negatif (Sultana dkk., 2024). Dengan dukungan pemrosesan bahasa alami (*Natural Language Processing*), metode ini telah berkembang dari pendekatan berbasis aturan yang mengandalkan kamus kata sentimen menjadi pendekatan berbasis pembelajaran mesin. Hal tersebut memungkinkan pemrosesan data dalam jumlah besar dengan lebih cepat dan efisien.

Sentiment analysis sering diterapkan dalam sektor *e-commerce* untuk menganalisis ulasan pelanggan terhadap suatu produk atau layanan (Hicham & Nassera, 2024). Pendekatan ini memberikan wawasan mendalam bagi pelaku bisnis dalam memahami kepuasan pelanggan serta tren pasar yang sedang berkembang. Sebagai contoh, ulasan positif dapat meningkatkan kepercayaan calon pembeli terhadap suatu produk, sementara ulasan negatif dapat menurunkan minat pembelian dan mendorong calon pelanggan untuk mencari alternatif (Zhu dkk., 2021).

Sentiment analysis semakin penting karena pendekatan model rekomendasi konvensional yang hanya bergantung pada *rating* numerik sering kali tidak cukup untuk menangkap opini subjektif pengguna (Ait elouli dkk., 2024). Dengan adanya model berbasis *Transformer* seperti *BERT* dan *RoBERTa*, *sentiment analysis* dalam *e-commerce* dapat digunakan untuk menyaring produk dengan ulasan negatif,

sehingga rekomendasi yang dihasilkan lebih relevan dan sesuai dengan preferensi pengguna (Liu dkk., 2024).

2.2.1 Kelas Sentimen

Kelas sentimen merujuk pada kategori yang digunakan untuk mengelompokkan opini atau emosi dalam suatu teks berdasarkan polaritasnya (Zafar et al., 2024). Dalam penelitian ini, *sentiment analysis* dilakukan dengan mengklasifikasikan ulasan pengguna ke dalam dua kelas utama:

1. Sentimen positif

Mencerminkan kepuasan pengguna terhadap suatu produk atau layanan. Ulasan dengan sentimen ini umumnya mengandung kata-kata dengan konotasi positif dan menunjukkan pengalaman yang baik.

2. Sentimen negatif

Mengindikasikan ketidakpuasan pengguna yang dapat disebabkan oleh berbagai faktor, seperti kualitas produk yang tidak sesuai, keterlambatan pengiriman, atau pelayanan yang kurang memuaskan.

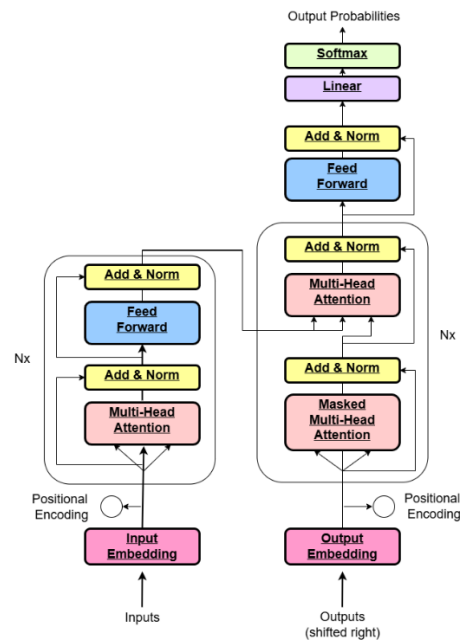
Dalam penelitian ini, kedua kelas sentimen tersebut digunakan untuk menyaring dan menganalisis opini pengguna terhadap suatu produk. Dengan mengintegrasikan model *RoBERTa* dalam *sentiment analysis*, sistem dapat mengidentifikasi polaritas sentimen secara lebih akurat, yang selanjutnya digunakan untuk meningkatkan relevansi rekomendasi produk dalam sistem rekomendasi berbasis *Collaborative Filtering*.

2.3 Transformer

Transformer adalah arsitektur *deep learning* yang diperkenalkan pada penelitian (Vaswani dkk., 2017) yang berjudul "*Attention is All You Need.*" Model ini merevolusi bidang pemrosesan bahasa alami (*NLP*) dengan memperkenalkan mekanisme *self-attention*, yang memungkinkan model untuk menangkap hubungan antar kata dalam teks tanpa harus bergantung pada urutan kata seperti pada model berbasis *Recurrent Neural Network* (RNN) atau *Long Short-Term Memory* (LSTM).

Transformer terdiri dari *encoder* dan *decoder*, yang masing-masing memiliki beberapa lapisan *self-attention* dan *feed-forward neural networks*. *Encoder* merepresentasikan input teks dalam bentuk vektor bermakna dengan menangkap hubungan antar kata melalui *multi-head self-attention*, lalu diproses lebih lanjut oleh *feed-forward neural networks* untuk menghasilkan pemahaman yang lebih kaya.

Dalam *sentiment analysis* dan sistem rekomendasi, *encoder* lebih sering digunakan karena kemampuannya memahami konteks teks secara mendalam. Gambar 2.1 menunjukkan arsitektur *Transformer* yang menggambarkan interaksi antara *encoder* dan *decoder*.



Gambar 2. 1 Transformer Model

Sumber: (Vaswani dkk., 2017)

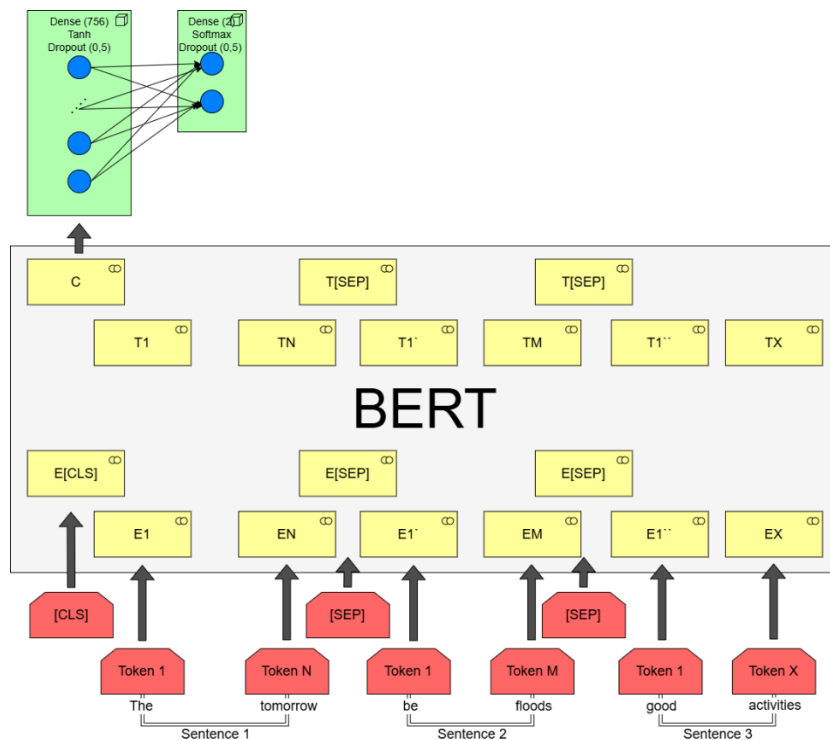
Keunggulan utama *Transformer* dalam *NLP* meliputi:

1. Pemrosesan Paralel: Tidak seperti RNN yang memproses teks secara berurutan, *Transformer* dapat memproses semua kata dalam satu waktu, sehingga lebih efisien dalam melatih model pada dataset besar.
2. Mekanisme *Self-attention*: Model dapat menangkap hubungan kata dalam teks secara global, bukan hanya bergantung pada kata-kata yang berdekatan.
3. *Scalability*: Model berbasis *Transformer* seperti *BERT* dan *RoBERTa* dapat dilatih pada dataset besar dan diadaptasi untuk berbagai tugas *NLP*, termasuk *sentiment analysis* dan sistem rekomendasi.

Transformer digunakan sebagai dasar dari model *BERT* dan *RoBERTa* untuk meningkatkan akurasi *sentiment analysis* dalam sistem rekomendasi produk *e-commerce*.

2.4 Bidirectional Encoder Representation from Transformers

BERT adalah model *deep learning* berbasis *Transformer* yang dikembangkan oleh Google (Devlin dkk., 2019) Berbeda dengan model *NLP* sebelumnya yang membaca teks dari kiri ke kanan (seperti *RNN*) atau dari kanan ke kiri (seperti *bidirectional RNN*), *BERT* membaca teks dalam dua arah sekaligus (*bidirectional*). Berikut pada Gambar 2.2. Merupakan arsitektur *BERT*.



Gambar 2. 2 BERT Model

Sumber: (Ripa'i dkk., 2024)

Keunggulan utama *BERT* dibandingkan model sebelumnya adalah kemampuannya dalam memahami konteks kata secara lebih dalam, karena model ini dilatih menggunakan teknik *Masked Language Model* (MLM) dan *Next Sentence Prediction* (NSP):

1. *Masked Language Model* (MLM): Sebagian kata dalam teks dihapus (masked), lalu model diminta untuk menebak kata yang hilang berdasarkan konteks sekitarnya.
2. *Next Sentence Prediction* (NSP): Model belajar memahami hubungan antar kalimat dengan memprediksi apakah dua kalimat memiliki hubungan semantik atau tidak.

BERT merupakan dasar model *RoBERTa*. Dalam melakukan *sentiment analysis* pada ulasan produk *e-commerce*, kemampuan *BERT* dalam memahami konteks kata memungkinkan model untuk menangkap makna yang lebih kompleks dalam teks ulasan pelanggan, sehingga menghasilkan rekomendasi produk yang lebih relevan.

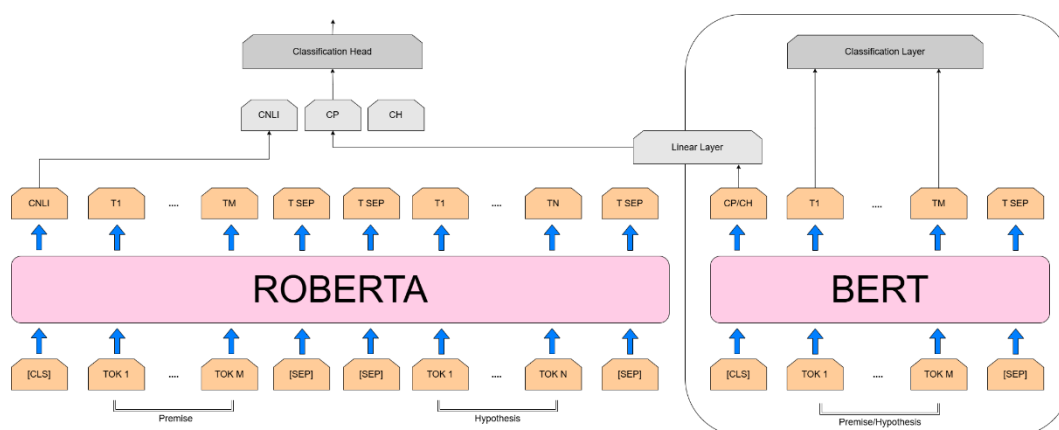
2.5 Robustly Optimized BERT Pretraining Approach

Model *RoBERTa* (*Robustly Optimized BERT Pretraining Approach*) merupakan pengembangan dari *BERT* (*Bidirectional Encoder Representations from Transformers*) yang dirancang untuk meningkatkan pemahaman model terhadap teks dengan cara melakukan pretraining lebih lama pada dataset yang lebih besar. *RoBERTa* menghilangkan tugas *Next Sentence Prediction* (NSP) yang terdapat pada *BERT* serta menerapkan masking dinamis, yang membuat model lebih adaptif dalam menangkap pola linguistik dari teks (Rahman dkk., 2024).

RoBERTa dapat dioptimalkan untuk memahami ulasan pelanggan dengan lebih akurat. Model ini mampu menangkap nuansa bahasa yang lebih kompleks, seperti sarkasme atau opini implisit, yang sering muncul dalam ulasan produk (Zhao dkk., 2024).

Untuk menangani berbagai ekspresi sentimen dalam bahasa yang digunakan dalam *e-commerce*, model yang digunakan dalam penelitian ini adalah *RoBERTa-base*, sebuah versi yang telah dilatih pada dataset besar guna meningkatkan akurasi dalam tugas klasifikasi teks (Rahman dkk., 2024). Model ini kemudian menjalani proses *fine-tuning* menggunakan dataset ulasan produk dari *e-commerce* guna menyesuaikan pemahaman model terhadap pola bahasa yang sering digunakan oleh pelanggan. Dengan pendekatan ini, model diharapkan dapat lebih akurat dalam mengklasifikasikan sentimen ulasan serta memberikan kontribusi dalam meningkatkan sistem rekomendasi produk.

RoBERTa-Base dirancang dengan arsitektur berbasis *transformer* dan memiliki sekitar 125 juta parameter, terdiri atas 12 lapisan, 768 dimensi hidden states, serta 12 attention heads. Model ini dapat menerima input hingga 512 token, dengan token pertama selalu berupa [CLS], yang berfungsi sebagai representasi keseluruhan teks. Dalam tugas klasifikasi sentimen, hidden state terakhir dari [CLS] kemudian diteruskan ke lapisan softmax untuk memprediksi probabilitas sentimen positif atau negatif (Rahman dkk., 2024).



Gambar 2. 3 RoBERTa Model

Sumber: (Naseer dkk., 2022)

Pada Gambar 2.3, dapat dilihat mengenai arsitektur *RoBERTa*, yang menggunakan transformer encoder untuk memproses teks. Model ini dibandingkan dengan *BERT* dalam tugas klasifikasi teks. Berikut penjelasan komponen utama dalam model:

1. [CLS]: Token spesial di awal input, digunakan untuk merepresentasikan keseluruhan teks dalam tugas klasifikasi.
2. Token1-N: Tokenisasi teks input menjadi *subword* unit menggunakan *Tokenizer RoBERTa* atau *BERT*.
3. E[CLS], E1-N: *Embedding* dari masing-masing token setelah melalui lapisan *embedding*, yang merepresentasikan kata dalam ruang vektor.
4. C, T1-N: Representasi akhir dari token setelah diproses oleh *Transformer*. C merupakan keluaran dari token [CLS], yang biasanya digunakan untuk klasifikasi teks.
5. *Classification Head & Linear Layer*: Lapisan tambahan di atas *RoBERTa* atau *BERT* untuk tugas klasifikasi. *RoBERTa* memiliki struktur yang lebih

kompleks dengan *multiple classification heads* dibandingkan *BERT* yang hanya menggunakan satu lapisan linear.

6. *Softmax*: Fungsi aktivasi di lapisan output yang mengubah nilai logits menjadi probabilitas untuk menentukan kelas teks yang dianalisis.

Gambar ini menunjukkan bahwa *RoBERTa* memiliki arsitektur serupa dengan *BERT* tetapi dengan optimasi tambahan, seperti penggunaan lebih banyak data pretraining dan tanpa penggunaan pemilihan urutan NSP (*Next Sentence Prediction*).

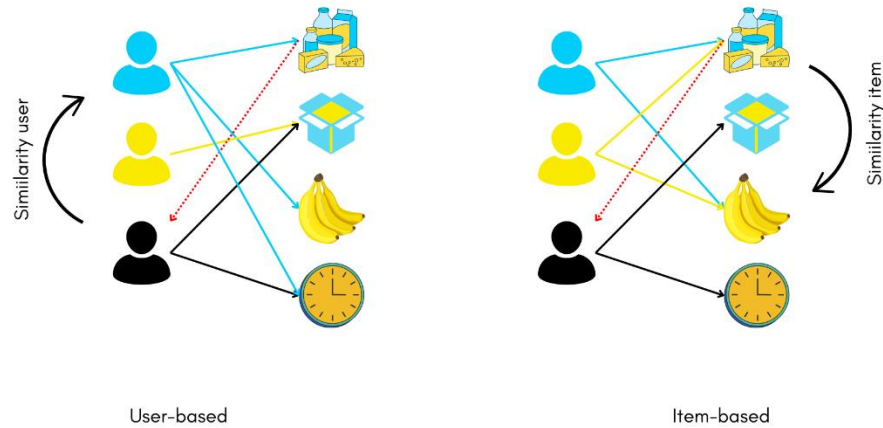
2.6 Collaborative Filtering

Collaborative Filtering adalah metode sistem rekomendasi yang bekerja dengan menganalisis pola perilaku pengguna untuk menemukan hubungan antara pengguna atau produk yang berbeda (Hasan, 2024). Metode ini dibagi menjadi dua jenis utama:

1. *User-Based Collaborative Filtering*: Menganalisis kesamaan antar pengguna berdasarkan pola pembelian atau penilaian terhadap produk.
2. *Item-Based Collaborative Filtering*: Menganalisis kesamaan antar produk berdasarkan preferensi pengguna sebelumnya.

Gambar 2.4 merupakan konsep *Collaborative Filtering* (CF) dalam sistem rekomendasi, di mana preferensi pengguna lain digunakan untuk memberikan rekomendasi kepada pengguna target.

Collaborative Filtering



Gambar 2. 4 Model Collaborative Filtering

Gambar 2.4. mengilustrasikan bagaimana *User-based Collaborative Filtering* dan *Item-based Collaborative Filtering* bekerja. *User-based Collaborative Filtering* mengelompokkan pengguna dengan preferensi serupa untuk merekomendasikan item yang disukai oleh pengguna lain dalam kelompok tersebut. Sementara itu, *Item-based Collaborative Filtering* menganalisis keterkaitan antar item berdasarkan pola interaksi pengguna, sehingga item yang sering dipilih bersama dapat direkomendasikan. Pendekatan ini banyak digunakan dalam *e-commerce* dan layanan streaming untuk meningkatkan relevansi rekomendasi.

2.7 Perhitungan Kemiripan

Perhitungan kemiripan untuk menentukan hubungan antara pengguna atau item yang umum menggunakan *Cosine Similarity* dan *PCC*:

1. *Cosine Similarity*

Cosine Similarity mengukur kesamaan antara dua vektor berdasarkan sudut di antara keduanya, dengan menggunakan persamaan 2.1:

$$\text{sim}(A, B) = \frac{A \cdot B}{\|A\| \times \|B\|} \quad (\text{Persamaan 2. 1})$$

Penjelasn:

$A \cdot B$: Dot produk (perkalian titik) antara dua vector A dan B

$\|A\|$: Panjang (norma) dari vector A

$\|B\|$: Panjang (norma) vector B

2. *Pearson Correlation Coefficient (PCC)*

PCC menghitung korelasi linier antara dua pengguna atau item dengan mempertimbangkan perbedaan rata-rata *ratingnya*, dengan persamaan 2.2:

$$\text{PCC}(A, B) = \frac{\sum(A_i - \bar{A})(B_i - \bar{B})}{\sqrt{\sum(A_i - \bar{A})^2} \times \sqrt{\sum(B_i - \bar{B})^2}} \quad (\text{Persamaan 2. 2})$$

Penjelasan :

A_i : *Rating* pengguna/item A terhadap item/i ke-i.

B_i : *Rating* pengguna/item B terhadap item/i ke-i.

\bar{A} : Rata-rata *rating* yang diberikan oleh pengguna/item A.

\bar{B} : Rata-rata *rating* yang diberikan oleh pengguna/item B.

\sum : Simbol penjumlahan atas seluruh item yang sama-sama diberi *rating* oleh A dan B.

$A_i - \bar{A}$: Selisih antara *rating* aktual dan rata-rata *rating* A.

$B_i - \bar{B}$: Selisih antara *rating* aktual dan rata-rata *rating* B.

2.8 Prediksi *Rating*

Model rekomendasi memprediksi *rating* menggunakan dua pendekatan yang utama :

1. *User-Based Collaborative Filtering*

Metode ini menggunakan *rating* dari pengguna yang memiliki kemiripan tinggi untuk memperkirakan *rating* pengguna target dengan Persamaan 2.3 berikut:

$$\hat{r}_{u,i} = \bar{r}_u + \frac{\sum_{v \in N} (sim(u, v) \times (r_{v,i} - \bar{r}_v))}{\sum_{v \in N} |sim(u, v)|} \quad (\text{Persamaan 2. 3})$$

$\hat{r}_{u,i}$: Prediksi *rating* yang diberikan oleh pengguna u terhadap item i.

\bar{r}_u : Rata-rata *rating* yang diberikan oleh pengguna u (target).

$v \in N$: Sekumpulan pengguna tetangga (neighbors) yang mirip dengan pengguna u dan telah memberi *rating* pada item i.

$sim(u, v)$: Nilai kemiripan antara pengguna u dan pengguna v, dihitung menggunakan *Cosine Similarity*, PCC, atau metode lain.

$\hat{r}_{v,i}$: *Rating* yang diberikan oleh pengguna v terhadap item i.

\bar{r}_v : Rata-rata *rating* dari pengguna v.

$|sim(u, v)|$: Nilai absolut dari kemiripan, digunakan untuk normalisasi agar pembagi tetap positif.

2. *Item-Based Collaborative Filtering*

Metode ini memprediksi *rating* berdasarkan kesamaan antar item yang sudah diberi *rating* oleh pengguna, berikut persamaan pada 2.4:

$$\hat{r}_{u,i} = \frac{\sum_{j \in N} (sim(i,j) \times r_{u,j})}{\sum_{j \in N} |sim(i,j)|} \quad (\text{Persamaan 2. 4})$$

Penjelasan:

$\hat{r}_{u,i}$: Prediksi *rating* yang akan diberikan oleh pengguna u terhadap item i .

$j \in N$: Sekumpulan item tetangga yang mirip dengan item i , dan telah diberi *rating* oleh pengguna u .

$sim(i,j)$: Nilai kemiripan antara item i dan item j .

$r_{u,j}$: *Rating* aktual yang diberikan oleh pengguna u terhadap item j .

$|sim(i,j)|$: Nilai absolut kemiripan antar item, digunakan untuk normalisasi.

2.9 Integrasi *Sentiment analysis* dan *Collaborative Filtering*

Integrasi antara hasil *sentiment analysis* dan metode *Collaborative Filtering* (CF) diterapkan untuk meningkatkan akurasi rekomendasi produk dalam model *e-commerce*. CF digunakan untuk memprediksi peringkat suatu produk berdasarkan pola interaksi pengguna, sementara *sentiment analysis* dengan *RoBERTa* mengevaluasi opini pengguna melalui ulasan yang diberikan. Integrasi kedua metode ini dilakukan dengan mengombinasikan hasil prediksi *rating* dari CF dan skor sentimen dari analisis ulasan menggunakan persamaan 2.5 berikut:

$$H = R * \lambda + (1 - \lambda) S \quad (\text{Persamaan 2. 5})$$

di mana:

H : adalah skor akhir yang digunakan sebagai dasar rekomendasi,

R : merupakan *rating* produk yang diprediksi menggunakan metode CF tanpa mempertimbangkan *sentiment analysis*,

S : adalah skor sentimen yang diperoleh dari model *RoBERTa* berdasarkan analisis ulasan pengguna, dan

λ : adalah bobot yang diberikan untuk menyesuaikan kontribusi antara CF dan *sentiment analysis* dalam menentukan skor akhir.

2.10 Evaluasi Model

Evaluasi model bertujuan untuk mengukur kinerja sistem dalam menghasilkan hasil yang akurat dan relevan. Proses ini melibatkan pengukuran sejauh mana model mampu memprediksi dengan benar serta menilai tingkat kesalahan yang terjadi. Dengan menggunakan berbagai metrik evaluasi, performa model dapat dianalisis secara objektif untuk menentukan efektivitasnya dalam menyelesaikan tugas yang diberikan.

2.11.1 *Sentiment analysis*

Model dievaluasi berdasarkan kemampuannya dalam mengklasifikasikan ulasan pengguna ke dalam kategori seperti positif atau negatif pada *sentiment analysis*. Beberapa metrik utama yang digunakan adalah *Accuracy*, *Precision*, *Recall*, F1-score, dan AUC-ROC (Wang, 2024). *Accuracy* menunjukkan proporsi prediksi yang benar terhadap total data uji, yang dirumuskan pada persamaan 2.6.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{Persamaan 2. 6})$$

Precision mengukur seberapa tepat model dalam memberikan prediksi positif, rumusnya ada pada persamaan 2.7.

$$Precision = \frac{TP}{TP + FP} \quad (\text{Persamaan 2. 7})$$

Sementara itu, *Recall* menilai sejauh mana model dapat mengidentifikasi data positif dari seluruh data positif yang tersedia, sebagaimana dirumuskan pada Persamaan 2.8.

$$Recall = \frac{TP}{TP + FP} \quad (\text{Persamaan 2. 8})$$

F1-score merupakan rata-rata harmonis antara *Precision* dan *Recall* yang digunakan untuk memberikan penilaian yang lebih seimbang, terutama dalam dataset yang tidak seimbang, seperti pada persamaan 2.9.

$$F1Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (\text{Persamaan 2. 9})$$

Penjelasan :

TP (*True Positive*) : Jumlah data positif yang diprediksi benar oleh model.

TN (*True Negative*) : Jumlah data negatif yang diprediksi benar oleh model.

FP (*False Positive*) : Jumlah data negatif yang salah diprediksi sebagai positif

FN (*False Negative*) : Jumlah data positif yang salah diprediksi sebagai negatif.

2.11.2 Collaborative Filtering

Evaluasi model *Collaborative Filtering* (CF) dilakukan untuk mengukur akurasi prediksi *rating* serta relevansi rekomendasi yang diberikan kepada pengguna. Beberapa metrik utama yang digunakan pada penelitian ini adalah *RMSE* (Elahi & Zirak, 2024).

Root Mean Square Error (*RMSE*) digunakan untuk mengukur rata-rata kesalahan kuadrat antara *rating* yang diprediksi dan *rating* aktual, yang dinyatakan dalam persamaan 2.10.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (r_i - \hat{r}_i)^2} \quad (\text{Persamaan 2. 10})$$

Penjelasan:

r_i : Nilai aktual (misalnya *rating* aktual dari pengguna untuk item ke-i).

\hat{r}_i : Nilai prediksi dari model untuk item ke-i.

N : Jumlah total data (contohnya jumlah prediksi yang dilakukan).

$(r_i - \hat{r}_i)$: Kuadrat dari selisih antara nilai aktual dan nilai prediksi (error).

Kombinasi metrik evaluasi pada *sentiment analysis* dan model rekomendasi memberikan dasar yang kuat untuk menilai performa masing-masing pendekatan. Evaluasi ini memastikan model tidak hanya akurat dalam klasifikasi sentimen, tetapi juga mampu membuat rekomendasi produk yang lebih relevan dan akurat.

2.11 *State of The Art*Tabel 2. 1 *State of The Art*

No	Nama Peneliti/Journal		Hasil Penelitian
1	Peneliti (tahun)	(Karabila dkk., 2023)	Penelitian ini mengintegrasikan <i>BiLSTM</i> ke dalam <i>Collaborative Filtering</i> untuk <i>sentiment analysis</i> . Evaluasi pada <i>Amazon Kindle book</i> menunjukkan AUC 92%, <i>Accuracy</i> 93%, dan F1-score 94%, sedangkan pada <i>Amazon digital music</i> , AUC 78%, <i>Accuracy</i> 94%, dan F1-score 96%. Hasil membuktikan peningkatan efektivitas rekomendasi dibandingkan metode konvensional.
	Judul	Enhancing <i>Collaborative Filtering</i> Based Recommender System Using <i>Sentiment analysis</i>	
	Algoritma/Metode	CF + <i>BiLSTM</i>	
2	Peneliti (tahun)	(Barzan Abdalla dkk., n.d.)	Penelitian ini mengembangkan sistem rekomendasi <i>e-commerce</i> dengan <i>Passer Learning Optimization</i> berbasis <i>BiLSTM</i> . Model mencapai F1-score 92.51%, MSE 1.24%-1.58%, <i>Precision</i> 91.90%-92.69%, dan <i>Recall</i> 90.76%-93.47% pada tiga dataset.
	Judul	An Efficient Recommendation System in Ecommerce using <i>Passer learning optimization</i> based on <i>BiLSTM</i>	
	Algoritma/Metode	PSO + <i>BiLSTM</i>	

No	Nama Peneliti/Journal		Hasil Penelitian
3	Peneliti (tahun)	(Pokhrel, 2024)	<p>Penelitian ini membandingkan CNNLSTM dan WolfWhale Fusion, di mana WolfWhale Fusion unggul dengan MAE 0.3575, MSE 0.3575, RMSE 2.9677, MAPE 0.0110, dan MEAE 0.8445, menunjukkan prediksi lebih akurat dan stabil.</p>
	Judul	Enhancing Ecommerce Recommendations Using <i>Hybrid</i> Models	
	Algoritma/Metode	Whale Optimization Algorithm Grey Wolf Optimizer (WOAGWO)	
4	Peneliti (tahun)	(Gunawan dkk., 2024)	<p>Penelitian ini menerapkan algoritma Apriori untuk rekomendasi <i>e-commerce</i> di Toko Hocki Jaya. Hasilnya, pasangan item seperti NIPPON 5400 WALL SEALER dan NIPPON VINILEX 5000 memenuhi threshold dan direkomendasikan ke pelanggan.</p>
	Judul	Sistem Rekomendasi Produk ECommerce Menggunakan Algoritma Apriori	
	Algoritma/Metode	Algoritma Apriori	
5	Peneliti (tahun)	(Song, 2024)	<p>Penelitian ini membandingkan kinerja Machine Learning dan <i>Deep learning</i> dalam sistem rekomendasi, fokus pada akurasi, cakupan,</p>
	Judul	Analysis on recommendation systems based on ML and DL Approaches	

No	Nama Peneliti/Journal		Hasil Penelitian
	Algoritma/Metode	Machine Learning dan <i>Deep learning</i>	kualitas peringkat, dan cold start. Hasilnya, model DL, khususnya multimodal, mengungguli CF dan SVD. CNN dan RNN menunjukkan <i>Accuracy</i> dan <i>Recall</i> terbaik pada dataset <i>Amazon</i> dan <i>MovieLens</i> .
6	Peneliti (tahun)	(Renukadevi dkk., 2024)	Hasil penelitian menunjukkan bahwa model rekomendasi yang diusulkan mengungguli metode seperti Basic CF, PCA + KMeans, dan TriFac. Model ini meningkatkan <i>Precision</i> , <i>Recall</i> , dan Fscore pada berbagai tingkat sparsity (100%).
	Judul	An Improved Collaborative User Product Recommendation System Using Computational Intelligence with Association Rules	
	Algoritma/Metode	PCA + KMeans	
7	Peneliti (tahun)	(Saputro & Amin, 2024)	Penelitian ini mengkaji sistem rekomendasi ecommerce untuk skincare face wash pria menggunakan metode contentbased filtering dengan algoritma TF IDF dan <i>Cosine Similarity</i> . Hasilnya, produk 'Facial
	Judul	SISTEM REKOMENDASI CONTENT-BASED FILTERING SKINCARE PRIA DI ECOMMERCE SHOPEE	

No	Nama Peneliti/Journal		Hasil Penelitian
	Algoritma/Metode	Content-Based Filtering	Wash Brightening Benings' memiliki tingkat kesamaan tertinggi (0,5611).
8	Peneliti (tahun)	(Salsabil dkk., 2024)	Penelitian ini merancang sistem rekomendasi berbasis CBF dengan membandingkan TFIDF, <i>BERT</i> , GPT2, dan <i>RoBERTa</i> . Hasilnya, <i>RoBERTa</i> unggul dengan loss 0,6514, <i>Accuracy</i> 95,59%, <i>Precision</i> 95,76%, <i>Recall</i> 95,41%, dan <i>F1Score</i> 95,58%, serta <i>RMSE</i> dan <i>MAE</i> terendah, menghasilkan rekomendasi yang akurat.
	Judul	Content-based filtering movie recommender system using semantic approach with recurrent neural network classification and SGD	
	Algoritma/Metode	Content-based Filtering	
9	Peneliti (tahun)	(M. Guo et al., 2020)	Penelitian ini mengevaluasi model rekomendasi berbasis <i>deep learning</i> dibandingkan Attributed Based dan Frequently Compared dengan ambang <i>Cosine Similarity</i> ≥ 0.8 . Hasilnya, model <i>deep learning</i> unggul dalam <i>Precision</i> , <i>Recall</i> (Top 1, 5, 10), serta meningkatkan cakupan rekomendasi
	Judul	<i>Deep learning</i> -based Online Alternative Product Recommendations at Scale	
	Algoritma/Metode	<i>Deep learning</i> berbasis <i>Cosine Similarity</i>	

No	Nama Peneliti/Journal		Hasil Penelitian
			hingga 81.2%83.4%, melampaui Attributed Based (31.5%) dan Frequently Compared (47.1%).
10	Peneliti (tahun)	(Anugerah Rahayu Kasim et al., 2024)	Penelitian ini mengkaji penerapan algoritma User-Based <i>Collaborative Filtering</i> pada sistem rekomendasi produk UMKM. Hasilnya, algoritma ini berhasil diterapkan dengan baik pada sistem rekomendasi yang dibangun. Evaluasi <i>Accuracy</i> menunjukkan nilai MAE sebesar 1.11, MSE sebesar 0.0649, dan MAPE sebesar 1.65%, yang menunjukkan kinerja rekomendasi yang baik.
	Judul	Sistem Rekomendasi Produk UMKM Menggunakan Algoritma User-Based <i>Collaborative Filtering</i> Berbasis Website	
	Algoritma/Metode	<i>Collaborative Filtering</i>	
11	Peneliti (tahun)	(Zuhdiansyah & Luthfiarta, 2024)	Penelitian ini mengembangkan sistem rekomendasi berbasis <i>Collaborative Filtering</i> model-based dengan algoritma SVD, dikombinasikan dengan KMeans untuk
	Judul	Sistem Rekomendasi Pembelian Smartphone berbasis Algoritma K-Means dan Singular Value Decomposition	

No	Nama Peneliti/Journal		Hasil Penelitian
	Algoritma/Metode	KMeans + SVD	mengelompokkan produk. Hasilnya, sistem lebih efektif dalam rekomendasi dan prediksi <i>rating</i> , dengan MAE 0.8150 dan <i>RMSE</i> 1.1781 pada cluster 0. Meski <i>RMSE</i> masih tinggi akibat sparsitas data, Matrix Factorization terbukti lebih unggul dari model Neighborhood-based.
12	Peneliti (tahun)	(Ramadhan Putra & Fathur Rahman, 2024)	Penelitian ini menggunakan Item-based <i>Collaborative Filtering</i> dengan KNN (K=2) dan data splitting 70:30, menghasilkan MAE 1.058 dan <i>RMSE</i> 1.362. Semakin kecil nilai error, semakin akurat model, sehingga penelitian ini dapat menjadi referensi untuk studi sistem rekomendasi selanjutnya.
	Judul	Pemanfaatan Metode <i>Collaborative Filtering</i> dengan Algoritma KNN pada Sistem Rekomendasi Produk	
	Algoritma/Metode	<i>Collaborative Filtering</i> + KNN	
13	Peneliti (tahun)	(Zhang & Wu, 2024)	Penelitian ini mengembangkan sistem rekomendasi <i>e-commerce</i> dengan KMeans yang ditingkatkan oleh algoritma
	Judul	<i>Ecommerce recommender system based on improved Kmeans commodity</i>	

No	Nama Peneliti/Journal		Hasil Penelitian
		<i>information management model</i>	genetika (GA), meningkatkan akurasi dan kecepatan pencarian. Hasilnya, <i>Recall</i> 42.8% dengan konvergensi 207 iterasi. Pada MovieLens (1M), <i>RMSE</i> 0.68 (sparsitas 60%), dan pada Epinions, <i>RMSE</i> 0.71. Model ini mengurangi kesalahan prediksi <i>rating</i> , namun perlu uji lebih lanjut dalam aplikasi praktis.
	Algoritma/Metode	Improved K-Means	
14	Peneliti (tahun)	(Syah, 2020)	Penelitian ini menerapkan User KNN untuk prediksi peringkat produk di Tokopedia. Evaluasi menunjukkan <i>RMSE</i> 0.713, <i>MAE</i> 0.488, dan <i>NMAE</i> 0.122, menandakan efektivitas algoritma dalam sistem rekomendasi.
	Judul	Performa Algoritma User K-Nearest Neighbors pada Sistem Rekomendasi di Tokopedia	
	Algoritma/Metode	Content-Based Filtering	
15	Peneliti (tahun)	(X. Guo, 2024)	Penelitian ini mengusulkan model rekomendasi berbasis <i>sentiment analysis</i> deep learning menggunakan <i>RoBERTa</i> dan regresi time-series pada ulasan produk
	Judul	<i>Sentiment analysis</i> Based on <i>RoBERTa</i> for Amazon Review: An Empirical Study on Decision Making	
	Algoritma/Metode	<i>RoBERTa</i>	

No	Nama Peneliti/Journal		Hasil Penelitian
			<i>Amazon</i> . Model mencapai <i>Accuracy</i> 88.44%, <i>Precision</i> 0.8836, <i>Recall</i> 0.8844, dan F1-score 0.8840.
16	Peneliti (tahun)	(Shang et al., 2024)	Penelitian ini mengusulkan model rekomendasi berbasis <i>sentiment analysis deep learning</i> dan Neural Collaborative Filtering (NCF) dengan <i>BERT</i> untuk menangkap nuansa ulasan. Model "Ours" unggul dibandingkan baseline seperti ItemKNN, BPR, dan <i>BERT4Rec</i> , dengan NDCG 0.4678, <i>Precision</i> 0.2890, <i>Recall</i> 0.3456, MAP 0.3012, dan MRR 0.3789, serta keberagaman 0.8567 dan novelty 0.4956.
	Judul	Enhancing <i>E-commerce Recommendation Systems with Deep learning Based Sentiment analysis of User Reviews</i>	
	Algoritma/Metode	NCF + <i>BERT</i>	
17	Peneliti (tahun)	<i>Our Research</i>	Penelitian ini mengembangkan model rekomendasi yang mengintegrasikan model Collaborative Filtering dan <i>RoBERTa</i> , dimana <i>RoBERTa</i> disini berfungsi untuk menghasilkan
	Judul Penelitian	INTEGRASI <i>ROBERTA</i> -BASED <i>SENTIMENT ANALYSIS</i> DAN <i>COLLABORATIVE FILTERING</i> UNTUK REKOMENDASI	

No	Nama Peneliti/Journal		Hasil Penelitian
		PRODUK <i>E-COMMERCE</i>	sentiment score dari ulasan pengguna, dan nantinya akan diintegrasikan dengan hasil <i>Collaborative Filtering</i> .
	Algoritma/Metode	CF + <i>RoBERTa</i>	

Penelitian sebelumnya telah mengeksplorasi berbagai pendekatan dalam sistem rekomendasi, dengan beberapa di antaranya mengintegrasikan *sentiment analysis* untuk meningkatkan akurasi rekomendasi. Seperti pada penelitian terdapatnya yaitu pada penelitian Karabila et al., (2023) yang menggunakan *BiLSTM* untuk *sentiment analysis* dan kemudian diintegrasikan dengan *Collaborative Filtering*.

Namun, pendekatan pada penelitian Karabila et al., (2023) masih memiliki keterbatasan dalam hal representasi konteks dan nuansa bahasa dalam ulasan pengguna. *BiLSTM*, meskipun efektif, tidak sekuat model transformer modern seperti *RoBERTa* dalam memahami dependensi panjang dan makna semantik yang kompleks dalam teks. Selain itu, integrasi yang dilakukan pada penelitian sebelumnya cenderung masih bersifat sederhana dan belum memanfaatkan kekuatan representasi bahasa dari *transformer* secara optimal.

Gap yang diisi dari penelitian Karabila et al., (2023) adalah penggunaan model *RoBERTa* yang lebih unggul dalam pemrosesan bahasa alami untuk *sentiment analysis*, yang kemudian diintegrasikan dengan *Collaborative Filtering* dalam konteks *e-commerce*.

2.12 Matriks Penelitian

Tabel 2. 2 Matriks Penelitian

No	Penulis	Algoritma	Pendekatan	
			Technical Analysis	Sentiment analysis
1	Karabila dkk. (2023)	CF + <i>BiLSTM</i>	✓	✓
2	Barzan Abdalla dkk. (n.d.)	PSO + <i>BiLSTM</i>	✓	✓
3	Pokhrel (2024)	WOAGWO (WolfWhale Optimization)	✓	-
4	Gunawan dkk. (2024)	Algoritma Apriori	✓	-
5	Song (2024)	Machine Learning dan <i>Deep learning</i>	✓	-
6	Renukadevi dkk. (2024)	PCA + KMeans	✓	-
7	Saputro & Amin (2024)	Content-Based Filtering	✓	-
8	Salsabil dkk. (2024)	Content-Based Filtering	✓	-
9	Guo dkk. (2020)	<i>Deep learning</i> berbasis <i>Cosine Similarity</i>	✓	-
10	Anugerah Rahayu	<i>Collaborative Filtering</i>	✓	✓

No	Penulis	Algoritma	Pendekatan	
			Technical Analysis	<i>Sentiment analysis</i>
	Kasim dkk. (2024)			
11	Zuhdiansyah & Luthfiarta (2024)	KMeans + SVD	✓	✓
12	Ramadhan Putra & Fathur Rahman (2024)	<i>Collaborative Filtering</i> + KNN	✓	-
13	Zhang & Wu (2024)	Improved KMeans	✓	✓
14	Syah (2020)	Content-Based Filtering	✓	-
15	Dewi & Ciptayani (2022)	<i>Hybrid Deep learning</i> (SOM + RNN)	✓	-
16	Shang dkk. (2024)	NCF + <i>BERT</i>	✓	✓
17	<i>Our Research</i>	CF + <i>RoBERTa</i>	✓	✓

Penelitian ini berfokus pada evaluasi kinerja model rekomendasi dan *sentiment analysis* dengan pendekatan yang lebih canggih dibandingkan penelitian yang terdekatnya yaitu penelitian yang dilakukan oleh Karabila et al., (2023) yang menggabungkan *Collaborative Filtering* (CF) dengan *BiLSTM*, penelitian ini

menekankan optimalisasi model rekomendasi melalui kombinasi pendekatan yang lebih adaptif.

Penelitian ini menghadirkan kebaruan dengan menggabungkan metode pemrosesan teks yang lebih canggih untuk *sentiment analysis* serta optimasi teknik rekomendasi yang lebih dinamis. Pendekatan dalam penelitian ini mengintegrasikan *RoBERTa* untuk *sentiment analysis* dan *Collaborative Filtering* untuk menghasilkan rekomendasi, yang menitikberatkan pada peningkatan akurasi dengan mempertimbangkan aspek ketidaklengkapan data serta hubungan antar-item yang lebih kompleks. Dengan demikian, penelitian ini berkontribusi dalam meningkatkan efektivitas model rekomendasi dengan menggabungkan pendekatan untuk mencapai hasil yang lebih optimal.