

Integrasi *Aspect-Based Sentiment Analysis* dalam *Recommender System* Berbasis Ulasan untuk Mengurangi *Information Overload*: A *Systematic Literature Review*

Miranda Purdamasela¹ dan Riska Dhenabayu²

^{1,2} Bisnis Digital, Universitas Negeri Surabaya, Indonesia

*) Corresponding Author (Email: miranda.22082@mhs.unesa.ac.id)

ABSTRACT

The large volume of online reviews and the limited capacity of numerical ratings to capture consumer preferences in detail have given rise to information overload, leading to the integration of Aspect-Based Sentiment Analysis (ABSA) into review-based recommender systems. This study aims to map the ABSA methods, recommender system architectures, and application domains used in such integrations, along with their reported performance and contributions during the 2021–2025 period. A systematic literature review was conducted following the PRISMA 2020 guidelines. Searches across five electronic databases (ScienceDirect, Springer, Scopus, ACM Digital Library, and IEEE Xplore) yielded 169 articles, which were narrowed down through deduplication, screening, and eligibility assessment to 20 studies included in the narrative synthesis. The results show that deep learning methods, particularly Bi-LSTM with attention mechanisms and BERT-based approaches, are the predominant techniques for ABSA, while Collaborative Filtering, either independently or in combination with Content-Based Filtering, is the most widely adopted recommender system architecture across domains such as e-learning, e-commerce, restaurants, hospitality, film, and social platforms, with performance varying across RMSE, MAE, F1-score, and AUC metrics. The integration of ABSA contributes to finer-grained user preference representation, improved interpretability and explainability, and reduced cold-start and data sparsity issues. Overall, integrating ABSA into recommender systems effectively reduces information overload by enabling more granular and explainable recommendations.

Keywords: *Recommender System, Aspect-based sentiment analysis (ABSA), Information Overload, Collaborative Filtering, Systematic Literature Review.*



I. PENDAHULUAN

Perkembangan platform digital telah mengubah peran konsumen dari penerima informasi pasif menjadi pembuat konten aktif yang membagikan ulasan, foto, maupun pendapat di berbagai platform (Cao et al., 2021). Konten yang dihasilkan pengguna ini dipandang lebih kredibel karena bersifat sukarela, tidak komersial, dan mencerminkan pengalaman nyata, sehingga konsumen turut membentuk pengetahuan kolektif secara global (Schröder et al., 2025). Kondisi ini menjadikan ulasan daring sebagai salah satu sumber informasi utama dalam pengambilan keputusan pembelian (Alzaidi & Agag, 2022; Dwivedi et al., 2021), di mana *social proof* yang sebelumnya hanya berlaku pada lingkup kecil kini dapat menyebar luas melalui platform digital sehingga pendapat satu konsumen mampu memengaruhi audiens dalam skala besar (Dwivedi et al., 2021; H. Liu et al., 2024). Sebagai ilustrasi skala tersebut, *Google Maps* yang digunakan oleh lebih dari satu miliar pengguna memungkinkan akses terhadap ulasan secara *real-time* dalam hampir 40 bahasa (Gelashvili et al., 2024).

Ulasan daring umumnya terdiri atas rating numerik dan komentar berbentuk teks bebas. Rating Bintang atau numerik bersifat terlalu sederhana untuk merepresentasikan preferensi pengguna secara rinci, sementara komentar teks dapat bervariasi panjangnya dan sering mengandung sentimen campuran, misalnya memuji satu aspek namun mengeluhkan aspek lainnya dalam ulasan yang sama. Kondisi ini menyulitkan pembaca menyimpulkan kesan keseluruhan, dan ketika digabung dengan volume ulasan yang sangat besar, menimbulkan *cognitive overload* karena konsumen kesulitan menyaring informasi secara manual (AbdulAmeer & Hussein, 2024; Thomas & Jeba, 2024; L. Wang et al., 2024). Akibatnya, konsumen cenderung hanya membaca beberapa ulasan sebelum mengambil keputusan dan lebih mengandalkan sinyal sederhana seperti *rating* angka (Seutter et al., 2023), sementara ketidakkonsistenan kualitas ulasan serta variasi jenis konten turut menambah beban kognitif tersebut (Seutter et al., 2023; L. Wang et al., 2024). Rating angka semata cenderung menyederhanakan kualitas layanan menjadi satu nilai tunggal yang tidak sepenuhnya merepresentasikan kondisi sebenarnya (Kolesárová et al., 2025; Yum & Yoo, 2024), sehingga diperlukan mekanisme penyortiran, penyaringan, dan penonjolan ulasan kunci agar konsumen dapat memproses informasi secara lebih efektif (Alzate et al., 2021; Seutter et al., 2023).

Permasalahan *information overload* menjadi motivasi yang melatarbelakangi kemunculan *recommender system* sebagai solusi untuk membantu pengguna menemukan informasi paling relevan dari sekian banyak data yang tersedia (AbdulAmeer & Hussein, 2024; Hui et al., 2023; Umair & Masciari, 2024). *Recommender system* kemudian diterapkan secara luas di berbagai bidang, mulai dari kesehatan dan *e-commerce* hingga konteks yang lebih spesifik seperti pembelajaran daring, berita, dan restoran (Cai et al., 2022). Namun demikian, *recommender system* konvensional yang mengandalkan *rating* numerik maupun karakteristik semantik

antar konten masih menyisakan keterbatasan dalam merepresentasikan preferensi pengguna secara rinci. Pada domain pembelajaran daring, rating skala diskrit tunggal dinilai tidak mampu mengekspresikan opini pengguna secara detail (Hazar et al., 2022), sementara pada domain restoran, rating keseluruhan belum cukup untuk memahami preferensi spesifik terhadap aspek tertentu seperti rasa, layanan, atau suasana (S. Yang et al., 2024). Secara lebih luas, rating hanya mencerminkan kepuasan pengguna secara keseluruhan tanpa menjelaskan motivasi di balik preferensi tersebut (Wu, 2025.; H. Zhang, 2025).

Ulasan tekstual dinilai mengandung informasi yang jauh lebih detail mengenai preferensi pengguna terhadap fitur spesifik suatu item dibandingkan sekadar angka rating (Liao et al., 2025), sehingga pemanfaatan ulasan menjadi salah satu arah penelitian yang banyak diminati (Sun et al., 2021). Untuk menggali preferensi pengguna dari ulasan tersebut, *sentiment analysis* atau *opinion mining* digunakan untuk menganalisis opini, emosi, dan sikap seseorang terhadap suatu entitas dari data teks (B. Liu, 2012). Analisis sentimen sendiri terbagi menjadi tiga tingkat, yaitu *document level*, *sentence level*, dan *aspect level*. *Document level* hanya menghasilkan polaritas global dan tidak mampu menangkap variasi sentimen dalam satu teks (Obiedat et al., 2021), sementara *sentence level* masih terbatas ketika satu kalimat mengandung lebih dari satu emosi (Nandwani & Verma, 2021). Keterbatasan kedua tingkat tersebut mendorong pengembangan *Aspect-Based Sentiment Analysis* (ABSA), yang memungkinkan analisis opini secara lebih spesifik terhadap fitur tertentu dari suatu entitas sehingga mampu menangkap variasi sentimen yang berbeda dalam satu teks (B. Liu, 2012; Nandwani & Verma, 2021; Obiedat et al., 2021).

ABSA memungkinkan sentimen pengguna diekstraksi tidak hanya secara keseluruhan, tetapi juga pada tingkat aspek tertentu dari suatu pengalaman, sehingga variasi opini yang lebih rinci dapat ditangkap dari teks ulasan. Karakteristik ini yang mendasari pemanfaatan ABSA dalam sistem rekomendasi berbasis ulasan, di mana hasil ekstraksi berupa pasangan aspek dan sentimen digunakan sebagai dasar dalam proses pencocokan rekomendasi. Ketika pengguna menunjukkan preferensi terhadap aspek tertentu, sistem dapat mengarahkan rekomendasi pada entitas yang memiliki sentimen positif dominan pada aspek yang dimaksud, sehingga hasil rekomendasi lebih relevan dengan kebutuhan pengguna (S. Yang et al., 2024). Pendekatan ini menjadikan ABSA lebih presisi dibandingkan analisis sentimen konvensional, karena mampu mengidentifikasi aspek spesifik yang menjadi perhatian pengguna, alih-alih hanya menentukan polaritas sentimen suatu teks secara keseluruhan (AbdulAmeer & Hussein, 2024).

Karakteristik granular ABSA ini pada akhirnya memberikan sejumlah manfaat lanjutan yang tidak dapat diperoleh dari sistem rekomendasi berbasis rating konvensional. Pendekatan ini juga meningkatkan interpretabilitas dan *explainability* sistem rekomendasi, karena pengguna dapat mengetahui secara konkret aspek apa

yang mendasari suatu rekomendasi (Liao et al., 2025; P. Liu et al., 2021; C. Yang et al., 2021; Zanon et al., 2022).

Berbagai manfaat tersebut diwujudkan melalui beragam pendekatan metode dan arsitektur model. Dalam ranah ABSA, penelitian menggunakan kombinasi Bidirectional Long Short-Term Memory dengan mekanisme *attention* seperti *Classical Attention*, *Self-Attention*, atau *Multi-Head Attention* seperti pada HCFSAR, serta pendekatan berbasis BERT atau *transformer* untuk ekstraksi aspek dan sentiment (Hui et al., 2023; X. Liu et al., 2025; S. Yang, 2024). Pendekatan lain memanfaatkan *Latent Dirichlet Allocation* untuk *aspect extraction* (Cai et al., 2022; Hui et al., 2023), *Attention-Based Aspect Extraction* untuk *unsupervised aspect mining* (AbdulAmeer & Hussein, 2024), serta *Large Language Model* dengan *structured prompt framework* (Wu, 2025). Dari sisi arsitektur sistem rekomendasi, penelitian juga menerapkan *Collaborative Filtering* baik dalam bentuk dasar, *hybrid*, maupun berbasis waktu (Alatrash & Priyadarshini, 2023; Jun & Li, 2025; Wu, 2025), *Content-Based Filtering* melalui *k-Nearest Neighbors* dengan *semantic similarity* (C. Yang et al., 2021; Zanon et al., 2022), serta pendekatan *Knowledge-Based* melalui *Knowledge Graph Convolutional Neural Network* dan *Knowledge graph-enhanced LLMs* (Cui et al., 2024b, 2025). Integrasi ABSA ke dalam sistem rekomendasi ini juga diterapkan pada beragam domain, mulai dari e-commerce dan pembelajaran daring hingga restoran, perhotelan, perfilman, dan platform sosial (Alatrash et al., 2022; Cai et al., 2022; Ji & Ma, 2023; Jun & Li, 2025; S. Yang, 2024; Zanon et al., 2022).

Meskipun penelitian terkait integrasi ABSA ke dalam *recomender system* berbasis ulasan terus berkembang dengan variasi metode, domain, dan arsitektur yang beragam, kajian yang merangkum secara sistematis bagaimana ABSA diintegrasikan ke dalam sistem rekomendasi, beserta kontribusi dan keterbatasannya dalam pengurangan *information overload*, masih belum banyak ditemukan. Kondisi ini yang mendasari perlunya dilakukan *systematic literature review* untuk memetakan tren metode ABSA, jenis sistem rekomendasi yang digunakan, domain penerapan, serta kontribusi dan keterbatasan integrasi ABSA ke dalam sistem rekomendasi untuk mengurangi *information overload* yang masih belum banyak dipetakan secara sistematis pada literatur terkait. Berdasarkan penelitian pendahuluan dan gap yang teridentifikasi, pertanyaan penelitian yang diajukan dalam tinjauan sistematis ini adalah sebagai berikut:

RQ1: Metode *Aspect-Based Sentiment Analysis* apa saja yang digunakan dalam berbagai penelitian integrasi ABSA ke dalam sistem rekomendasi berbasis ulasan?

RQ2: Arsitektur sistem rekomendasi apa saja yang diadopsi dalam berbagai penelitian integrasi ABSA, dan bagaimana distribusi penggunaannya?

RQ3: Pada domain penerapan apa saja penelitian integrasi ABSA ke dalam sistem rekomendasi dilakukan, dan bagaimana performa yang dicapai?

RQ4: Kontribusi dan keterbatasan apa yang diidentifikasi berbagai penelitian dari integrasi ABSA ke dalam sistem rekomendasi berbasis ulasan?

II. TINJAUAN PUSTAKA

Sistem Rekomendasi

Sistem rekomendasi (*recommender systems*) didefinisikan sebagai seperangkat perangkat lunak dan teknik yang menyediakan saran mengenai item yang mungkin berguna bagi pengguna, dengan tujuan utama mengatasi *information overload* melalui penyaringan informasi yang otomatis dan personal (Boudaa et al., 2021; Ricci et al., 2015). Sistem ini mengidentifikasi preferensi pengguna melalui riwayat interaksi, penilaian, maupun spesifikasi kebutuhan eksplisit untuk menghasilkan rekomendasi yang relevan (D.Jannach, M.Zanker, 2011; Esheiba et al., 2021).

Secara umum terdapat tiga pendekatan utama dalam sistem rekomendasi. *Collaborative filtering* (CF) memprediksi minat pengguna berdasarkan riwayat penilaian komunitas pengguna lain yang memiliki kesamaan preferensi (Gil et al., 2019), namun pendekatan ini rentan terhadap masalah *cold-start* ketika data interaksi historis belum tersedia, serta masalah *data sparsity* akibat rendahnya frekuensi interaksi pengguna-item (Esheiba et al., 2021; Ngoc et al., 2023). *Content-based filtering* (CBF) menganalisis atribut item dan membandingkannya dengan profil preferensi pengguna (Ricci et al., 2015), namun tetap rentan terhadap *cold-start* pengguna baru karena profil preferensi tidak dapat dibangun tanpa riwayat interaksi awal (Ngoc et al., 2023), *knowledge-based filtering* mengatasi kedua keterbatasan tersebut dengan menghasilkan rekomendasi berbasis pengetahuan domain dan kebutuhan eksplisit pengguna, tanpa bergantung pada data historis interaksi (Esheiba et al., 2021; Tarus et al., 2018).

Sentiment Analysis dan Aspect-Based Sentiment Analysis

Sentiment analysis atau *opinion mining* adalah bidang kajian yang menganalisis opini, emosi, dan sikap seseorang terhadap entitas tertentu dari data teks (B. Liu, 2012). Terdapat tiga tingkat analisis yaitu *document level*, *sentence level*, dan *aspect level*. *Document level* hanya menghasilkan polaritas global dan tidak mampu menangkap variasi sentimen dalam satu teks (Obiedat et al., 2021), sedangkan *sentence level* masih terbatas ketika satu kalimat mengandung lebih dari satu emosi (Nandwani & Verma, 2021).

Aspect-Based Sentiment Analysis (ABSA) memungkinkan analisis opini yang lebih spesifik terhadap fitur tertentu dari suatu entitas (B. Liu, 2012) sehingga mampu menangkap variasi sentimen yang berbeda dalam satu teks, sesuatu yang tidak dapat dilakukan oleh tingkat dokumen maupun kalimat (Nandwani & Verma, 2021; Obiedat et al., 2021). ABSA bertujuan mengidentifikasi opini terhadap aspek tertentu dari sebuah entitas dan menentukan polaritas sentimennya (Alyami et al., 2022; B. Liu, 2012; Trisna & Jie, 2022), yang terdiri dari dua tugas utama, yaitu Aspect Term Extraction (ATE) untuk mengidentifikasi aspek atau target opini, dan Aspect

Sentiment Classification (ASC) untuk menentukan polaritas sentimen terhadap aspek yang telah diidentifikasi (B. Liu, 2012; Trisna & Jie, 2022).

Integrasi *Aspect-Based Sentiment Analysis* dalam Sistem Rekomendasi

Integrasi ABSA ke dalam sistem rekomendasi dilandasi oleh keterbatasan rating numerik yang hanya mencerminkan kepuasan pengguna secara keseluruhan tanpa mengungkap alasan spesifik di balik penilaian tersebut, sementara ulasan tekstual mengandung informasi semantik kaya mengenai preferensi pengguna terhadap atribut item tertentu (Cui et al., 2024a; P. Liu et al., 2021; Wu, 2025)). Melalui ekstraksi aspek dan analisis polaritas sentimen pada level aspek, preferensi pengguna terhadap suatu item dapat direpresentasikan secara lebih granular, yakni sejauh mana pengguna menyukai atau tidak menyukai atribut spesifik suatu item, bukan hanya secara umum. Pendekatan ini juga terbukti meningkatkan interpretabilitas dan *explainability* sistem rekomendasi karena rekomendasi dapat dijelaskan dari sudut pandang aspek yang disukai maupun tidak disukai pengguna (Q. Wang et al., 2025; Zanon et al., 2022; H. Zhang, 2025).

III. METODE

PRISMA 2020

Penelitian ini disusun menggunakan pendekatan *systematic literature review* (SLR) dengan mengikuti panduan *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) 2020 sebagai kerangka kerja pelaporan. PRISMA 2020 merupakan pembaruan dari pedoman PRISMA 2009 yang dikembangkan untuk membantu peninjau menyusun laporan tinjauan sistematis secara transparan, lengkap, dan akurat mengenai alasan dilakukannya tinjauan, langkah-langkah yang ditempuh, serta temuan yang diperoleh, sehingga proses identifikasi, penyeleksian, dan sintesis studi dapat ditelusuri dan direplikasi oleh peneliti lain (Page et al., 2021). Penggunaan PRISMA 2020 pada penelitian ini dimaksudkan untuk memastikan proses pencarian dan penyeleksian literatur terkait integrasi *Aspect-Based Sentiment Analysis* (ABSA) ke dalam sistem rekomendasi berbasis ulasan dilakukan secara sistematis, dapat dipertanggungjawabkan secara metodologis, dan meminimalkan bias seleksi pada tahap pemilihan studi.

Kriteria Kelayakan (*Eligibility Criteria*)

Kriteria kelayakan ditetapkan untuk menentukan literatur yang relevan dengan fokus penelitian, yaitu integrasi *Aspect-Based Sentiment Analysis* ke dalam sistem rekomendasi berbasis ulasan. Kriteria kelayakan ini mencakup dua jenis, yaitu kriteria inklusi dan kriteria eksklusi. Kriteria inklusi merupakan seperangkat syarat yang harus dipenuhi suatu studi agar dapat diikutsertakan dalam tinjauan, sehingga hanya literatur yang benar-benar relevan, memadai secara metodologis, dan sesuai dengan ruang lingkup penelitian yang masuk ke tahap analisis. Sebaliknya, kriteria eksklusi merupakan kondisi atau karakteristik yang menyebabkan suatu studi dikeluarkan dari tinjauan, meskipun tampak relevan secara topik, untuk menjaga konsistensi dan kualitas korpus literatur yang dianalisis.

Kriteria inklusi yang diterapkan dalam penelitian ini meliputi enam syarat sebagai berikut: (1) artikel merupakan *original research article* berbasis penelitian empiris, bukan tinjauan literatur, editorial, prosiding tanpa *peer-review*, bab buku, maupun makalah pendek; (2) artikel membahas penerapan ABSA atau analisis sentimen berbasis aspek yang diintegrasikan ke dalam arsitektur sistem rekomendasi sebagai fitur tambahan, pembobotan preferensi, atau komponen *explainability*, disertai penjelasan eksplisit metode ekstraksi aspek dan klasifikasi sentimen; (3) artikel menerapkan pendekatan *collaborative filtering*, *content-based filtering*, *knowledge-based*, maupun kombinasi hibrida; (4) artikel menyajikan evaluasi performa integrasi ABSA melalui metrik kuantitatif seperti *precision*, *recall*, *F1-score*, RMSE, MAE, NDCG, atau *metrics* kuantitatif lainnya maupun evaluasi kualitatif; (5) artikel dipublikasikan pada rentang tahun 2021–2025; dan (6) artikel terindeks pada basis data yang ditelusuri.

Adapun kriteria eksklusi dalam penelitian ini mencakup lima kondisi sebagai berikut: (1) artikel yang membahas *sentiment analysis* pada level dokumen atau kalimat tanpa ekstraksi aspek secara eksplisit; (2) artikel yang membahas *recommender system* tanpa keterkaitan dengan ulasan tekstual atau ABSA; (3) artikel yang tidak menyajikan evaluasi performa atau dampak integrasi ABSA terhadap sistem rekomendasi yang diusulkan; (4) artikel yang tidak dapat diakses secara penuh (*full text*); dan (5) duplikasi *record* yang mengacu pada studi yang sama pada lebih dari satu basis data.

Sumber Informasi (Information Sources)

Penelusuran literatur dilakukan pada lima *database* elektronik, yaitu ScienceDirect, Springer, Scopus, ACM Digital Library, dan IEEE Xplore. Pemilihan kelima basis data tersebut didasarkan pada cakupannya yang luas terhadap publikasi bidang ilmu komputer, kecerdasan buatan, dan sistem informasi, sehingga representatif untuk menjangkau literatur terkait *Aspect-Based Sentiment Analysis* dan sistem rekomendasi. Seluruh basis data ditelusuri pada periode yang sama dengan rentang tahun publikasi 2021 hingga 2025. Hasil penelusuran awal sebelum deduplikasi memperoleh 116 artikel dari ScienceDirect, 20 artikel dari Springer, 16 artikel dari Scopus, 14 artikel dari ACM Digital Library, dan 3 artikel dari IEEE Xplore, sehingga total *record* yang teridentifikasi pada tahap identifikasi berjumlah 169 artikel.

Strategi Pencarian (Search Strategy)

Strategi pencarian disusun melalui kombinasi kata kunci yang mencerminkan tiga konsep utama, yaitu *Aspect-Based Sentiment Analysis*, sistem rekomendasi, dan pendekatan arsitektur rekomendasi, yang dihubungkan menggunakan operator Boolean AND dan OR. String pencarian yang digunakan pada seluruh basis data adalah sebagai berikut:

("aspect-based sentiment analysis" OR "aspect-level sentiment analysis" OR "ABSA" OR "aspect sentiment classification" OR "aspect term extraction" OR "fine-

grained sentiment analysis") AND ("recommender system" OR "recommendation system" OR "personalized recommendation") AND ("collaborative filtering" OR "content based" OR "knowledge based")

Selain string kombinasi tersebut, pencarian tambahan dilakukan menggunakan empat frasa kunci spesifik, yaitu "sentiment-aware recommender system", "opinion-aware recommender system", dan "review-based recommender system", untuk menjangkau literatur relevan yang mungkin tidak tertangkap oleh string kombinasi akibat perbedaan istilah yang digunakan penulis.

Proses Seleksi (*Selection Process*) dan Hasil

Proses seleksi studi dilakukan melalui empat tahap berurutan sebagaimana digambarkan pada diagram alur PRISMA 2020, dengan hasil seleksi sebagai berikut:

Tahap Identifikasi

Pada tahap ini, seluruh *record* yang diperoleh dari kelima basis data berjumlah 169 artikel dikumpulkan ke dalam satu basis data referensi, kemudian diperiksa untuk mengidentifikasi dan menghapus duplikat. Hasil pengurangan duplikat berdasarkan judul, penulis, atau DOI menghasilkan 79 artikel unik yang dilanjutkan ke tahap *screening*.

Tahap Screening


Pada tahap ini, judul dan abstrak setiap *record* dari 79 artikel diperiksa kesesuaiannya dengan topik integrasi *ABSA* dan sistem rekomendasi berdasarkan kriteria kelayakan yang telah ditetapkan. Sebanyak 41 artikel dieksklusi karena tidak memenuhi kriteria relevansi. Alasan eksklusi pada tahap ini mencakup analisis sentimen hanya pada level dokumen atau kalimat tanpa ekstraksi aspek eksplisit, sistem rekomendasi tanpa keterkaitan dengan ulasan tekstual atau *ABSA*, dan tidak adanya kejelasan keterkaitan dengan *information overload*. Sebanyak 38 artikel lolos ke tahap berikutnya untuk dinilai kelayakannya lebih lanjut.

Tahap Penilaian Kelayakan (*Eligibility*)

Pada tahap ini, teks lengkap dari 38 artikel dibaca secara menyeluruh untuk memastikan kesesuaiannya dengan seluruh kriteria kelayakan. Dari 38 artikel yang dinilai kelayakannya, 20 artikel ditetapkan sebagai memenuhi semua kriteria inklusi. Sebanyak 18 artikel dieksklusi dengan alasan spesifik, antara lain arsitektur sistem rekomendasi tidak dijelaskan dengan jelas, tidak terdapat hasil evaluasi performa kuantitatif maupun kualitatif, dan metode ekstraksi aspek serta klasifikasi sentimen *ABSA* tidak dijelaskan secara eksplisit.

Tahap Included

Studi yang lolos seluruh tahap penilaian kelayakan ditetapkan sebagai *included studies* dan dilanjutkan ke tahap ekstraksi data, menghasilkan 20 studi final yang dianalisis dalam tinjauan sistematis ini.



Sumber : Diolah peneliti merujuk pada (Page et al., 2021)

Figure 1 Diagram Alur PRISMA 2020 untuk Proses Seleksi Studi

Proses Pengumpulan Data dan Item Data

Proses pengumpulan data dilakukan dengan mengekstraksi informasi yang relevan dari 20 studi yang disertakan ke dalam tabel ekstraksi data terstruktur. Item data yang diekstraksi meliputi identitas studi (penulis dan tahun publikasi), domain penerapan, metode ekstraksi aspek dan klasifikasi sentimen yang digunakan seperti *deep learning* dengan mekanisme *attention*, BERT, *Latent Dirichlet Allocation*, dan *Large Language Model*, serta arsitektur sistem rekomendasi yang diadopsi termasuk *collaborative filtering*, *content-based filtering*, *knowledge-based*, dan variasi hibrida. Data juga mencakup hasil performa integrasi ABSA yang dilaporkan dalam bentuk metrik kuantitatif seperti *precision*, *recall*, *F1-score*, RMSE, MAE, atau NDCG, maupun temuan evaluasi kualitatif, serta informasi mengenai keterbatasan atau tantangan penelitian yang diidentifikasi masing-masing studi. Proses ekstraksi data ini menjadi dasar bagi sintesis naratif untuk memetakan tren metode, arsitektur, dan kontribusi integrasi ABSA terhadap sistem rekomendasi berbasis ulasan, yang selanjutnya dianalisis untuk menjawab setiap pertanyaan penelitian.

IV. HASIL DAN PEMBAHASAN

Sebanyak 20 studi yang memenuhi kriteria inklusi dianalisis dalam tinjauan sistematis ini, mencakup penelitian dari rentang tahun 2021 hingga 2025 yang

mencerminkan perkembangan tren integrasi *ABSA* ke dalam sistem rekomendasi dalam periode terkini. Setiap studi dianalisis dengan mempertimbangkan metode *ABSA* yang digunakan untuk ekstraksi aspek dan klasifikasi sentimen, arsitektur sistem rekomendasi yang diadopsi sebagai fondasi integrasi, serta domain aplikasi dan performa yang dicapai. Tabel 1 menyajikan gambaran umum dari setiap studi, termasuk penulis, tahun publikasi, pendekatan metodologis, dan hasil performa yang dilaporkan. Informasi pada tabel ini menjadi dasar untuk analisis naratif yang mengeksplorasi pola dan tren metode, preferensi arsitektur, spektrum aplikasi, serta kontribusi dan keterbatasan dari integrasi *ABSA* dalam sistem rekomendasi berbasis ulasan.

Table 1. Karakteristik Metodologis dan Performa 20 Studi yang Dianalisis

No	Tahun	Penulis	Judul Studi	Pendekatan ABSA & Rs	Hasil / Performa
1.	2023	Alatrash & Priyadarshini	<i>Fine-grained Sentiment-enhanced Collaborative Filtering-based Hybrid Recommender System</i>	<i>Deep learning</i> menggunakan <i>attention mechanisms</i> dan <i>Bi-LSTM</i> , serta <i>collaborative filtering</i> menggunakan <i>Alternating Least Squares (ALS)</i> dan pendekatan <i>hybrid</i> .	Rekomendasi materi dan buku e-learning dengan akurasi 93,39% (MHAAM), meningkatkan personalisasi rekomendasi.
2.	2024	S. Yang	<i>An Attentive Aspect-Based Recommendation Model With Deep Neural Network</i>	<i>Deep learning</i> berbasis <i>BERT-based ABSA</i> dan <i>Neural Collaborative Filtering</i> .	Rekomendasi restoran, laptop, dan tablet dengan performa MAE/RMSE terendah, menghasilkan preferensi aspek yang lebih rinci dan personal.
3.	2022	Ali et al.	<i>SmartTips: Online</i>	<i>Machine learning</i>	Rekomendasi produk online

			<i>Products Recommendations System Based on Analyzing Customers Reviews</i>	menggunakan teknik berbasis leksikal (<i>lexical-based technique</i>) dan <i>dependency parser</i> , serta <i>collaborative filtering</i> .	(Amazon) dengan MSE terendah 0,405 rata-rata; mengatasi <i>cold start</i> dan <i>information overload</i> .
4.	2021	Xia et al.	<i>Smart recommendation for tourist hotels based on multidimensional information: a deep neural network model</i>	<i>Deep learning</i> dan <i>machine learning</i> menggunakan <i>Convolutional Neural Network (CNN)</i> , <i>Inception-V3</i> , dan <i>Latent Dirichlet Allocation (LDA)</i> , serta <i>content-based filtering</i> .	Rekomendasi hotel wisata: akurasi 0,83 dan F1-score 0,84, meningkatkan kualitas rekomendasi.
5.	2022	Zanon et al.	<i>A user study with aspect-based sentiment analysis for similarity of items in content-based recommendations</i>	<i>Machine learning</i> dan <i>content-based filtering</i> .	Rekomendasi film dengan MAP kompetitif; meningkatkan transparansi, persuasi, dan penemuan rekomendasi secara tidak terduga.
6.	2024	AbdulAmeer & Hussein	<i>Alleviating the User Cold-Start Problem in Recommendation Systems Based on Textual</i>	<i>Deep learning</i> menggunakan <i>LSTM</i> dan <i>BERTopic</i> , serta <i>collaborative filtering</i> dan <i>content-based</i>	Rekomendasi produk Amazon (Elektronik dan Fine Food): RMSE 1,02; MAE

			<i>Reviews Using Deep Learning</i>	<i>filtering</i> dengan pendekatan <i>hybrid</i> .	0,574, cold-start teratasi signifikan.
7.	2023	Hui et al.	<i>A Hybrid Deep Learning Method to Extract Multi-features from Reviews and User-Item Relations for Rating Prediction</i>	<i>Deep learning</i> menggunakan BERT dan <i>Sentiment Latent Dirichlet Allocation (SLDA)</i> , serta <i>collaborative filtering</i> dan <i>content-based filtering</i> dengan pendekatan <i>hybrid</i> .	Rekomendasi produk elektronik Amazon: RMSE dan MAE terendah dengan fitur review dan relasi.
8.	2024	Alatrash et al.	<i>Collaborative filtering integrated fine-grained sentiment for hybrid recommender system</i>	<i>Deep learning</i> menggunakan CNN, LSTM, Peephole, dan GRU, serta <i>collaborative filtering</i> .	Rekomendasi buku <i>e-learning</i> dengan MAE 0,699 (MSE 0,8454) dan akurasi Peephole 0,9264, sistem diperbarui kontinu.
9.	2025	Q. Wang et al.	<i>SentiEntityRec: Entity-level sentiment perception graph neural network for news recommendation</i>	<i>Deep learning</i> menggunakan <i>Graph Neural Network (GNN)</i> , serta <i>content-based filtering</i> dan <i>collaborative filtering</i> berbasis graf (<i>graph-based collaborative filtering</i>).	Rekomendasi artikel berita: AUC meningkat 0,5% dibanding GLoCIM dengan pemahaman sentimen entitas lebih baik.

10.	2022	Cai et al.	<i>A deep learning recommendation model of cross-grained sentiments of user reviews and ratings</i>	<i>Deep learning dan collaborative filtering berbasis matrix factorization serta pendekatan deep learning.</i>	Rekomendasi produk e-commerce, meningkatkan akurasi 14,113% serta kualitas penjelasan teks.
11.	2025	Mohammed et al.	<i>Combining review elements for modelling various multi-criteria collaborative recommendation on models</i>	<i>Machine learning dan collaborative filtering.</i>	Rekomendasi film berbasis ulasan pengguna dengan MAE 0.7473 dan F1-score 0.65, mengatasi sparsity data.
12.	2025	Jun & Li	<i>Collaborative filtering recommendation algorithm based on fine-grained mining and neighborhood awareness attention</i>	<i>Fine-grained mining, Singular Value Decomposition (SVD) (matrix factorization), dan algoritma Dijkstra, serta collaborative filtering.</i>	Rekomendasi pada jaringan sosial (Facebook, Twitter, Douban); RMSE ~0.31-0.38, MAE ~0.29-0.36, serta metrik AUC dan AP yang superior.
13.	2021	C. Yang et al.	<i>Leveraging semantic features for recommendation: Sentence-level emotion analysis</i>	<i>Metode lexicon-based unsupervised dan hybrid collaborative filtering serta content-based filtering.</i>	Rekomendasi film berbasis ulasan pengguna Douban; mengatasi cold-start, F1 meningkat 8,9% dibanding NMF/UCF/ICF

14.	2023	Ji & Ma	<i>A fuzzy Dependency intelligent structure group recommender method in sparse-data environments based on multi-agent negotiation</i>	<i>collaborative filtering.</i>	Rekomendasi restoran untuk grup wisatawan; mengatasi data jarang, konflik preferensi, dan meningkatkan performa nDCG.
15.	2023	Zhang et al.	<i>Multi-Aspect enhanced Graph Neural Networks for recommendation</i>	Sentires, BERT dan Graph-based collaborative filtering	Rekomendasi berbasis preferensi aspek detail; performa meningkat signifikan pada NDCG/Recall dan transparansi.
16.	2022	Sharma & Sadagopan	<i>Influence of conditional holoentropy-based feature selection on automatic recommendation system in E-commerce sector</i>	<i>Deep learning menggunakan Deep Belief Network (DBN), serta content-based filtering.</i>	Rekomendasi produk e-commerce; akurasi tertinggi 94,02% (pada dataset pakaian wanita), mengungguli DBN konvensional.
17.	2022	Alatrash et al.	<i>Augmented language model with deep learning adaptation on sentiment</i>	<i>Deep learning menggunakan Convolutional Neural Network (CNN), serta hybrid</i>	Klasifikasi sentimen fine-grained (5 kelas) untuk rekomendasi e-learning

			<i>analysis for E-learning recommendation system.</i>	mencapai akurasi 90,37%.
18.	2022	Hazar et al.	<i>Learner comments-based Recommendation system</i>	Rule-based lexicon dan Content-based filtering Rekomendasi sumber belajar video Coursera; performa cosine similarity 0.98 menunjukkan akurasi tinggi.
19.	2024	S. Yang et al.	<i>Deep learning mechanism and big data in hospitality and tourism: Developing personalized restaurant recommendation model to customer decision-making</i>	<i>Deep learning</i> menggunakan <i>fine-tuned DeBERTa-V3</i> , serta <i>hybrid collaborative filtering</i> dan <i>content-based filtering</i> . Rekomendasi restoran personal berbasis ulasan Yelp; mengungguli baseline dengan MAE 0,489 dan RMSE 0,660.
20.	2024	Y. Cui et al.	<i>RAKCR: Reviews sentiment-aware based knowledge graph convolutional networks for Personalized Recommendation</i>	<i>Deep learning</i> menggunakan <i>Knowledge Graph Convolutional Neural Network (KGCN/GCN)</i> dan <i>Knowledge Graph Convolutional Neural Network (RAKCR)</i> dengan modul <i>alignment</i> . Rekomendasi film, buku, bisnis: AUC naik 6,4–3,4%, F1 naik 7,2–4,1%, CTR meningkat.

Hasil analisis dari 20 studi tersebut disajikan secara sistematis mengikuti keempat pertanyaan penelitian yang telah ditetapkan, dimulai dari identifikasi metode *ABSA*, arsitektur sistem rekomendasi, domain penerapan, hingga kontribusi dan keterbatasan integrasi.

RQ1: Metode Aspect-Based Sentiment Analysis yang Digunakan dalam Penelitian Integrasi ABSA ke Dalam Sistem Rekomendasi Berbasis Ulasan (2021–2025)

Analisis terhadap 20 studi yang diikutsertakan dalam tinjauan ini menunjukkan bahwa *deep learning* menjadi pendekatan yang paling banyak diadopsi dalam implementasi *ABSA*, digunakan pada lebih dari separuh studi yang dianalisis dengan variasi arsitektur yang cukup beragam. Kombinasi *Bidirectional Long Short Term Memory* (Bi-LSTM) dengan mekanisme *attention*, mencakup *Classical Attention*, *Self-Attention*, maupun *Multi-Head Attention*, diterapkan pada penelitian Alatrash & Priyadarshini (2023) untuk menghasilkan rekomendasi materi dan buku *e-learning* yang lebih personal. Arsitektur *deep learning* lain yang memadukan beberapa jenis *recurrent neural network* turut ditemukan pada Alatrash et al. (2024) yang menggabungkan *Convolutional Neural Network* (CNN), *Long Short Term Memory* (LSTM), *Peephole*, dan *Gated Recurrent Unit* (GRU) untuk rekomendasi buku *e-learning*, serta Alatrash et al. (2022) yang menggunakan CNN dengan *augmented language model* untuk klasifikasi sentimen *fine-grained* pada domain yang sama. Pendekatan hybrid *deep learning* juga ditemukan pada AbdulAmeer & Hussein (2024) yang memadukan LSTM dengan BERTopic untuk mengatasi masalah *cold-start* pada rekomendasi produk Amazon, pada Cai et al. (2022) yang menerapkan *deep learning* untuk menangkap sentimen lintas granularitas pada domain *e-commerce*, pada (Sharma & Sadagopan, 2022) yang memanfaatkan *Deep Belief Network* (DBN) untuk rekomendasi produk *e-commerce*, serta pada Xia et al. (2021) yang menggabungkan CNN dan Inception-V3 untuk rekomendasi hotel wisata. Selain itu, Jun & Li (2025) menggunakan pendekatan *fine-grained mining* yang dipadukan dengan *Singular Value Decomposition* dan algoritma *Dijkstra* untuk rekomendasi pada jaringan sosial. Dominasi *deep learning* dalam *ABSA* ini sejalan dengan kemampuannya menangkap ketergantungan jangka panjang dalam teks ulasan sekaligus memproses konteks lokal aspek dengan lebih baik dibanding metode tradisional.

Pendekatan *transformer-based*, khususnya BERT dan variannya seperti DeBERTa, juga menunjukkan penggunaan yang signifikan pada studi yang dianalisis. S. Yang (2024) menerapkan *ABSA* berbasis BERT yang dipadukan dengan *Neural Collaborative Filtering* untuk rekomendasi restoran, laptop, dan tablet dengan galat prediksi yang relatif rendah dibanding baseline pembandingan. Hui et al. (2023) memanfaatkan BERT bersama *Sentiment Latent Dirichlet Allocation* (SLDA) untuk mengekstraksi fitur dari ulasan produk elektronik Amazon, sementara Zhang et al.

(2023) menggabungkan metode *Sentires* dengan BERT dalam kerangka *graph-based collaborative filtering* untuk menghasilkan rekomendasi berbasis preferensi aspek yang lebih detail. S. Yang (2024) menggunakan *fine-tuned* DeBERTa-V3 untuk rekomendasi restoran berbasis ulasan Yelp, sedangkan pemanfaatan BERTopic pada AbdulAmeer & Hussein (2024) turut menunjukkan variasi penggunaan arsitektur berbasis BERT di luar tugas klasifikasi sentimen konvensional. Adopsi pendekatan transformer ini berkaitan dengan keunggulannya dalam merepresentasikan konteks global melalui mekanisme *self-attention*, sementara pemahaman semantik yang telah diperoleh pada tahap pralatih dapat ditransfer ke tugas spesifik dengan penyesuaian yang relatif minimal.

Metode probabilistik seperti *Latent Dirichlet Allocation* (LDA) dan variannya turut memberikan kontribusi pada beberapa studi, misalnya Xia et al. (2021) yang memanfaatkan LDA untuk *aspect extraction* pada rekomendasi hotel wisata, dan Hui et al. (2023) yang mengintegrasikan *Sentiment* LDA sebagai bagian dari ekstraksi fitur ulasan. Pendekatan ini memberikan fleksibilitas dalam menemukan aspek implisit tanpa memerlukan banyak label manual sehingga cukup relevan digunakan pada domain dengan keterbatasan data berlabel.

Pendekatan berbasis *Graph Neural Network* (GNN) diintegrasikan pada Q. Wang et al. (2025) yang mengusulkan model *SentiEntityRec* untuk rekomendasi artikel berita dengan mempertimbangkan sentimen pada tingkat entitas, serta pada C. Zhang et al. (2023) yang telah disebutkan sebelumnya dalam konteks pemanfaatan *graph-based collaborative filtering*. Cui et al. (2024a) memperluas pendekatan berbasis graf ini ke arah *Knowledge Graph Convolutional Network* melalui model RAKCR yang dilengkapi modul alignment, digunakan untuk rekomendasi film, buku, dan bisnis. Perkembangan ini menunjukkan pemahaman yang berkembang bahwa ABSA dapat diposisikan sebagai masalah struktural yang melibatkan hubungan antarentitas dalam graf pengetahuan, sehingga bukan hanya sekadar tugas klasifikasi teks.

Metode tradisional seperti *dependency parser* dan teknik leksikal tetap memberikan kontribusi pada beberapa studi dalam korpus ini. Ali et al. (2022) menerapkan teknik berbasis leksikal yang dipadukan dengan *dependency parser* untuk rekomendasi produk online, Hazar et al. (2022) menggunakan *rule-based lexicon* untuk rekomendasi sumber belajar video pada platform Coursera, C. Yang et al. (2021) memanfaatkan metode *lexicon-based unsupervised* untuk rekomendasi film berbasis ulasan Douban, dan Ji & Ma (2023) menerapkan pendekatan *dependency structure* untuk rekomendasi restoran bagi kelompok wisatawan. Selain *deep learning* dan metode tradisional tersebut, terdapat juga studi yang menerapkan pendekatan *machine learning* yang lebih sederhana tanpa arsitektur *deep learning* eksplisit, seperti Zanon et al. (2022) yang mengukur kesamaan aspek antar item untuk rekomendasi film dan Mohammed et al. (2025) yang menggabungkan elemen ulasan untuk pemodelan rekomendasi multikriteria pada domain film. Variasi

metode tradisional dan machine learning sederhana ini menunjukkan bahwa pilihan metode ABSA sangat bergantung pada karakteristik domain dan ketersediaan data pelatihan berlabel, bukan semata-mata mengikuti tren metodologis terkini.

Dari sisi tren temporal, studi yang mengadopsi pendekatan *transformer-based* dan *graph-based* cenderung terkonsentrasi pada publikasi tahun 2023 hingga 2025, sementara metode berbasis leksikal dan *dependency parser* lebih banyak ditemukan pada studi tahun 2021 hingga 2023, dengan mayoritas studi bertahun 2021–2022 dan satu studi Ji & Ma (2023) yang tetap mengadopsi pendekatan *dependency structure* pada tahun 2023. Pola ini mengindikasikan pergeseran preferensi metodologis dari pendekatan *rule-based* menuju pendekatan berbasis representasi kontekstual, sejalan dengan semakin matangnya adopsi model bahasa prelatih dalam periode yang dianalisis.

RQ2: Arsitektur Sistem Rekomendasi yang Diadopsi dalam Penelitian Integrasi ABSA dan Distribusi Pendekatannya

Collaborative Filtering (CF), baik dalam bentuk dasar, *hybrid*, maupun berbasis graf, merupakan arsitektur yang paling banyak diadopsi dalam integrasi ABSA, ditemukan pada 15 dari 20 studi yang dianalisis. Dalam bentuk dasarnya, CF diterapkan pada Ali et al. (2022) untuk rekomendasi produk Amazon, Alatrash et al. (2024) untuk rekomendasi buku *e-learning*, Cai et al. (2022) untuk rekomendasi produk *e-commerce*, Mohammed et al. (2025) untuk rekomendasi film, Jun & Li (2025) untuk rekomendasi pada jaringan sosial, Ji & Ma (2023) untuk rekomendasi restoran bagi kelompok wisatawan, S. Yang (2024) melalui skema *Neural Collaborative Filtering* untuk rekomendasi restoran, serta Alatrash & Priyadarshini (2023) yang memadukan CF berbasis *Alternating Least Squares* (ALS) dengan pendekatan *hybrid* untuk rekomendasi *e-learning*, dengan variasi teknik meliputi *matrix factorization* melalui *Singular Value Decomposition* (SVD) maupun *Alternating Least Squares* (ALS).

Content-Based Filtering (CBF) murni digunakan pada empat studi, yaitu Hazar et al. (2022), Sharma & Sadagopan (2022), Xia et al. (2021), Zanon et al. (2022), dengan memanfaatkan kesamaan semantik antar atribut item. Pendekatan *hybrid* yang menggabungkan CF dan CBF ditemukan pada lima studi lain, yaitu AbdulAmeer & Hussein (2024), Alatrash et al. (2022), Hui et al. (2023), C. Yang et al. (2021), S. Yang et al. (2024), untuk memanfaatkan kekuatan kedua pendekatan sekaligus saling menutupi kelemahannya.

Pendekatan berbasis graf, sebagai varian dari CF yang merepresentasikan relasi pengguna dan item dalam struktur graf, ditemukan pada Q. Wang et al. (2025) yang memadukan *graph-based collaborative filtering* dengan *elemen content-based filtering* untuk rekomendasi artikel berita, serta pada C. Zhang et al. (2023) yang menerapkan *graph-based collaborative filtering* untuk rekomendasi berbasis preferensi aspek. Adapun pendekatan *knowledge-based* hanya diwakili oleh satu

studi dalam korpus ini, yaitu Cui et al. (2024a) yang mengintegrasikan *Knowledge Graph Convolutional Network* untuk merepresentasikan informasi aspek-sentimen dalam struktur graf pengetahuan, memungkinkan sistem menangani relasi kompleks antarentitas yang tidak dapat ditangkap oleh CF maupun CBF konvensional. Minimnya representasi *knowledge-based filtering*, yang hanya ditemukan pada satu dari 20 studi, menunjukkan bahwa integrasi ABSA ke dalam arsitektur berbasis pengetahuan domain eksplisit masih jarang diteliti dibandingkan *collaborative filtering* dan *content-based filtering*, meskipun ketiga pendekatan tersebut sama-sama dikategorikan sebagai pendekatan utama sistem rekomendasi dalam literatur.

Pemilihan arsitektur tampak dipengaruhi oleh karakteristik domain penerapan. Penelitian pada domain dengan volume interaksi pengguna yang tinggi, seperti *e-commerce* dan platform sosial, cenderung menggunakan *collaborative filtering* karena data interaksi historis yang tersedia sudah memadai. Sebaliknya, domain dengan tantangan *cold-start* yang lebih besar, seperti *e-learning*, lebih sering mengadopsi *content-based filtering* atau pendekatan *hybrid* untuk memanfaatkan fitur aspek dari ulasan sebagai pengganti data interaksi yang masih terbatas.

RQ3: Domain Penerapan Penelitian Integrasi ABSA ke Dalam Sistem Rekomendasi dan Performa yang Dicapai

Integrasi ABSA ke dalam sistem rekomendasi telah diterapkan pada beragam domain, dengan *e-commerce* dan *e-learning* sebagai dua domain yang paling banyak diteliti. Domain *e-learning* menjadi fokus pada empat studi, yaitu Alatrash et al. (2022), Alatrash & Priyadarshini (2023), Hazar et al. (2022), dengan akurasi mencapai 93,39% pada metrik MHAAM dan 90,37% dalam klasifikasi sentimen lima kelas. Domain *e-commerce* ditangani oleh lima studi, yaitu AbdulAmeer & Hussein (2024), Ali et al. (2022), Cai et al. (2022), Hui et al. (2023), Sharma & Sadagopan (2022), dengan performa bervariasi dari MSE 0,405 hingga RMSE 1,02 pada dataset Amazon serta akurasi tertinggi 94,02% pada dataset produk pakaian wanita. Domain restoran ditangani oleh tiga studi, yaitu Ji & Ma (2023), S. Yang (2024), S. Yang et al. (2024), menghasilkan MAE serendah 0,489, sementara domain film ditangani oleh empat studi, yaitu Cui et al. (2024b), Mohammed et al. (2025), C. Yang et al. (2021), Zanon et al. (2022) dengan MAE mencapai 0,7473. Domain lain yang lebih spesifik mencakup hotel wisata pada Xia et al. (2021), berita pada Q. Wang et al. (2025), dan jaringan sosial pada Jun & Li (2025). Adapun C. Zhang et al. (2023) tidak secara eksplisit menyebutkan domain aplikasi tertentu dan lebih menekankan peningkatan performa NDCG dan Recall melalui representasi preferensi aspek yang lebih detail, sehingga studi ini bersifat lebih generik dibanding studi lain yang terikat pada domain aplikasi spesifik.

Metrik evaluasi yang digunakan dalam berbagai studi ini mencakup *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE) untuk mengukur kesalahan prediksi rating, *Precision*, *Recall*, dan *F1-Score* untuk mengukur kemampuan sistem

mengidentifikasi item relevan, *Normalized Discounted Cumulative Gain* (NDCG) dan *Mean Average Precision* (MAP) untuk mengevaluasi kualitas peringkat rekomendasi, serta *Area Under the Curve* (AUC) untuk mengukur kemampuan classifier membedakan item relevan dan non-relevan. Angka performa yang dilaporkan pada masing-masing studi tidak dapat dibandingkan secara langsung antarstudi, mengingat setiap penelitian menggunakan dataset, skala rating, dan protokol evaluasi yang berbeda. Sebagai contoh, nilai MAE 0,489 pada domain restoran dan MAE 0,7473 pada domain film berasal dari basis data serta tingkat kompleksitas data yang tidak sama, sehingga perbedaan angka tersebut tidak dapat diartikan sebagai perbedaan kualitas model secara langsung. Keberagaman metrik evaluasi serta belum tersedianya *benchmark dataset* yang seragam menjadi salah satu keterbatasan metodologis yang ditemukan lintas studi, sekaligus membatasi ruang bagi *meta-analysis* performa secara kuantitatif dalam tinjauan ini.

RQ4: Kontribusi dan Keterbatasan dari Integrasi ABSA ke Dalam Sistem Rekomendasi Berbasis Ulasan

Integrasi ABSA ke dalam sistem rekomendasi memberikan kontribusi utama pada peningkatan granularitas preferensi pengguna, di mana sistem tidak lagi bergantung pada rating tunggal melainkan mampu mencocokkan pengguna dengan *item* berdasarkan sentimen pada aspek spesifik. Kontribusi ini secara langsung berkaitan dengan pengurangan *information overload*, karena pengguna tidak perlu lagi membaca dan menyaring seluruh ulasan secara manual untuk memahami kelebihan dan kekurangan suatu item pada atribut tertentu. Peningkatan *interpretabilitas* dan *explainability* menjadi salah satu manfaat yang paling banyak ditekankan dalam studi yang dianalisis, sebagaimana ditunjukkan oleh Alatrash & Priyadarshini (2023), Zanon et al. (2022), C. Zhang et al. (2023), yang melaporkan bahwa rekomendasi dapat dijelaskan secara konkret berdasarkan aspek yang disukai atau kurang disukai pengguna, sehingga meningkatkan transparansi dan kepercayaan pengguna terhadap hasil rekomendasi.

Kontribusi lain yang teridentifikasi adalah kemampuan integrasi ABSA dalam mengatasi permasalahan *cold-start* dan *data sparsity* yang selama ini menjadi tantangan klasik pada sistem rekomendasi konvensional. AbdulAmeer & Hussein (2024), Ali et al. (2022) melaporkan bahwa pemanfaatan fitur aspek dari ulasan tekstual membantu sistem tetap menghasilkan rekomendasi yang relevan meskipun data interaksi pengguna baru masih terbatas, sementara C. Yang et al. (2021) mencatat peningkatan *F1-score* sebesar 8,9% dibanding *baseline collaborative filtering* konvensional pada kondisi *cold-start*. Pada sisi lain, Ji & Ma (2023), Mohammed et al. (2025), menunjukkan bahwa integrasi aspek dari ulasan turut membantu mengatasi *data sparsity* dan konflik preferensi, khususnya pada skenario rekomendasi kelompok. Temuan ini menunjukkan bahwa kontribusi ABSA tidak

terbatas pada peningkatan kualitas rekomendasi, tetapi juga mencakup ketahanan sistem terhadap keterbatasan data yang umum dijumpai dalam praktik.

Dari sisi performa kuantitatif, sebagaimana telah diuraikan pada RQ3, sebagian besar studi melaporkan peningkatan akurasi maupun penurunan galat prediksi dibanding *baseline* pembandingan, misalnya peningkatan akurasi sebesar 14,113% pada Cai et al. (2022) dan peningkatan AUC hingga 6,4% pada Cui et al. (2024b). Temuan ini konsisten ditemukan pada studi dengan arsitektur dan domain yang berbeda-beda, sehingga menunjukkan bahwa penambahan informasi sentimen pada level aspek umumnya berkontribusi positif terhadap performa sistem rekomendasi, terlepas dari variasi metode ABSA maupun arsitektur yang digunakan.

Meskipun demikian, sejumlah keterbatasan turut teridentifikasi dari korpus studi yang dianalisis. Keberagaman *dataset*, skala rating, dan protokol evaluasi antarstudi menyebabkan hasil performa tidak dapat diperbandingkan secara langsung, sehingga belum tersedia *benchmark* yang seragam untuk mengukur efektivitas integrasi ABSA secara kuantitatif lintas domain. Metode berbasis *deep learning* dan *transformer* yang mendominasi implementasi ABSA pada studi-studi terkini, seperti *Bi-LSTM* dengan *attention* dan *BERT*, umumnya membutuhkan data berlabel dalam jumlah besar serta sumber daya komputasi yang signifikan untuk proses pelatihan, sehingga penerapannya pada domain atau bahasa dengan ketersediaan data terbatas masih menjadi tantangan tersendiri. Pemilihan arsitektur dan metode ABSA yang sangat bergantung pada karakteristik domain juga mengindikasikan bahwa generalisasi suatu model ke domain lain tanpa penyesuaian ulang belum tentu dapat dilakukan secara langsung. Kondisi ini menunjukkan bahwa meskipun integrasi ABSA terbukti memberikan kontribusi nyata dalam mengurangi *information overload* dan meningkatkan kualitas rekomendasi, upaya standarisasi metode evaluasi serta pengembangan pendekatan yang lebih efisien dari sisi data dan komputasi masih diperlukan untuk memperluas penerapannya secara lebih konsisten lintas domain.

V. KESIMPULAN DAN REKOMENDASI

Tinjauan sistematis ini mengkaji 20 studi periode 2021–2025 untuk memetakan integrasi *Aspect-Based Sentiment Analysis* ke dalam sistem rekomendasi berbasis ulasan sebagai upaya mengatasi *information overload* pada ulasan daring. Dari sisi metode, *deep learning* mendominasi implementasi ABSA, terutama melalui kombinasi *Bi-LSTM* dengan mekanisme *attention* dan pendekatan berbasis *BERT*. Adapun dari sisi arsitektur sistem rekomendasi, *Collaborative Filtering*, baik dalam bentuk dasar, *hybrid*, maupun berbasis graf, menjadi pilihan yang paling banyak digunakan dan ditemukan pada 15 dari 20 studi. Integrasi ini diterapkan pada berbagai domain, dengan e-commerce dan e-learning sebagai domain yang paling banyak dikaji, diikuti restoran, film, hotel wisata, berita, dan jaringan sosial, dengan performa yang bervariasi tergantung metrik dan dataset yang digunakan. Dari sisi

kontribusi, integrasi ABSA terbukti meningkatkan granularitas preferensi pengguna serta interpretabilitas dan *explainability* rekomendasi, sekaligus membantu mengatasi *cold-start* dan *data sparsity*, sehingga berperan langsung dalam mengurangi *information overload*. Meski demikian, tinjauan ini juga menemukan sejumlah keterbatasan, yaitu keberagaman dataset, skala rating, dan protokol evaluasi antarstudi yang menyebabkan hasil performa tidak dapat diperbandingkan secara langsung, kebutuhan data berlabel dan sumber daya komputasi yang besar pada metode *deep learning* dan *transformer*, serta ketergantungan pemilihan arsitektur dan metode ABSA pada karakteristik domain yang membatasi generalisasi model ke domain lain.

Berdasarkan pola yang ditemukan dalam tinjauan ini, kombinasi metode berbasis *transformer* dengan *Collaborative Filtering* cenderung melaporkan keseimbangan yang baik antara akurasi prediksi dan *explainability*, sehingga pendekatan ini dapat menjadi pertimbangan bagi peneliti maupun praktisi yang mengembangkan sistem rekomendasi pada domain dengan tantangan *cold-start*, seperti *e-learning*. Meski demikian, keberagaman dataset, skala rating, dan protokol evaluasi antarstudi yang teridentifikasi dalam tinjauan ini membuat perbandingan performa antarpendingkatan perlu dimaknai secara hati-hati dan tidak digeneralisasi ke seluruh domain. Penelitian selanjutnya juga dapat diarahkan pada pengembangan metode ABSA yang lebih efisien dari sisi data berlabel dan sumber daya komputasi, mengingat sebagian besar studi masih bergantung pada *deep learning* dan *transformer* yang cukup membutuhkan sumber daya besar, serta perluasan eksplorasi arsitektur *knowledge-based* dan pengujian generalisasi model pada domain dan bahasa yang belum banyak diteliti.

REFERENSI

- AbdulAmeer, A. N., & Hussein, M. H. (2024). Alleviating the User Cold-Start Problem in Recommendation Systems Based on Textual Reviews Using Deep Learning. *Iraqi Journal of Science*, 65(12), 7276–7286. <https://doi.org/10.24996/ijs.2024.65.12.38>
- Alatrash, R., & Priyadarshini, R. (2023). Fine-grained Sentiment-enhanced Collaborative Filtering-based Hybrid Recommender System. *Journal of Web Engineering*, 22(7), 983–1035. <https://doi.org/10.13052/jwe1540-9589.2273>
- Alatrash, R., Priyadarshini, R., & Ezaldeen, H. (2024). Collaborative filtering integrated fine - grained sentiment for hybrid recommender system. *The Journal of Supercomputing*, 80(4), 4760–4807. <https://doi.org/10.1007/s11227-023-05600-w>
- Alatrash, R., Priyadarshini, R., Ezaldeen, H., & Alhinnawi, A. (2022). Augmented language model with deep learning adaptation on sentiment analysis for E-learning recommendation. *Cognitive Systems Research*, 75(July), 53–69. <https://doi.org/10.1016/j.cogsys.2022.07.002>
- Ali, N. M., Alshahrani, A., Alghamdi, A. M., & Novikov, B. (2022). SmartTips: Online Products Recommendations System Based on Analyzing Customers Reviews. *Applied Sciences (Switzerland)*, 12(17). <https://doi.org/10.3390/app12178823>

- Alyami, S., Alhothali, A., & Jamal, A. (2022). Systematic literature review of arabic aspect-based sentiment analysis. *Journal of King Saud University - Computer and Information Sciences*, 34(9), 6524–6551. <https://doi.org/10.1016/j.jksuci.2022.07.001>
- Alzaidi, M. S., & Agag, G. (2022). The role of trust and privacy concerns in using social media for e-retail services: The moderating role of COVID-19. *Journal of Retailing and Consumer Services*, 68(March), 103042. <https://doi.org/10.1016/j.jretconser.2022.103042>
- Alzate, M., Arce-Urriza, M., & Cebollada, J. (2021). Online Reviews and Product Sales: The Role of Review Visibility. *Journal of Theoretical and Applied Electronic Commerce Research*, 16(1), 638–669. <https://doi.org/10.3390/jtaer16010038>
- Boudaa, B., Figuir, D., Hammoudi, S., & Benslimane, S. M. (2021). DATAtourist: A constraint-based recommender system using datatourisme ontology. *International Journal of Decision Support System Technology*, 13(2), 62–84. <https://doi.org/10.4018/IJDSST.2021040104>
- Cai, Y., Ke, W., Cui, E., & Yu, F. (2022). A deep recommendation model of cross-grained sentiments of user reviews and ratings. *Information Processing and Management*, 59(2), 102842. <https://doi.org/10.1016/j.ipm.2021.102842>
- Cao, D., Meadows, M., Wong, D., & Xia, S. (2021). Understanding consumers' social media engagement behaviour: An examination of the moderation effect of social media context. *Journal of Business Research*, 122(June), 835–846. <https://doi.org/10.1016/j.jbusres.2020.06.025>
- Cui, Y., Wang, K., Yu, H., Guo, X., & Cao, H. (2025). KLLMs4Rec : Knowledge graph-enhanced LLMs sentiment extraction for personalized recommendations. *Expert Systems With Applications*, 282(March), 127430. <https://doi.org/10.1016/j.eswa.2025.127430>
- Cui, Y., Yu, H., Guo, X., Cao, H., & Wang, L. (2024a). RAKCR : Reviews sentiment-aware based knowledge graph convolutional networks for Personalized Recommendation. *Expert Systems With Applications*, 248(February), 123403. <https://doi.org/10.1016/j.eswa.2024.123403>
- Cui, Y., Yu, H., Guo, X., Cao, H., & Wang, L. (2024b). RAKCR: Reviews sentiment-aware based knowledge graph convolutional networks for Personalized Recommendation. *Expert Systems with Applications*, 248(January). <https://doi.org/10.1016/j.eswa.2024.123403>
- D.Jannach, M.Zanker, A. F. (2011). *Recommender An Introduction Systems* (Vol. 17).
- Dwivedi, Y. K., Ismagilova, E., Hughes, D. L., Carlson, J., Filieri, R., Jacobson, J., Jain, V., Karjaluoto, H., Kefi, H., Krishen, A. S., Kumar, V., Rahman, M. M., Raman, R., Rauschnabel, P. A., Rowley, J., Salo, J., Tran, G. A., & Wang, Y. (2021). Setting the future of digital and social media marketing research: Perspectives and research propositions. *International Journal of Information Management*, 59(June 2020), 102168. <https://doi.org/10.1016/j.ijinfomgt.2020.102168>
- Esheiba, L., Elgammal, A., Helal, I. M. A., & El-Sharkawi, M. E. (2021). A hybrid knowledge-based recommender for product-service systems mass customization. *Information (Switzerland)*, 12(8). <https://doi.org/10.3390/info12080296>
- Gelashvili, V., Martínez-Navalón, J. G., DeMatos, N., & de Brito Correia, M. (2024). Technological transformation: The importance of E-WOM and perceived privacy in the context of opinion platforms. *Technological Forecasting and Social*

- Change, 205(September 2023).
<https://doi.org/10.1016/j.techfore.2024.123472>
- Gil, M., El Sherif, R., Pluye, M., Fung, B. C. M., Grad, R., & Pluye, P. (2019). Towards a Knowledge-Based Recommender System for Linking Electronic Patient Records with Continuing Medical Education Information at the Point of Care. *IEEE Access*, 7, 15955–15966. <https://doi.org/10.1109/ACCESS.2019.2894421>
- Hazar, M. J., Zrigui, M., & Maraoui, M. (2022). Learner comments-based Recommendation system. *Procedia Computer Science*, 207, 2000–2012. <https://doi.org/10.1016/j.procs.2022.09.259>
- Hui, C., Pang, L., & Peng, Y. (2023). A Hybrid Deep Learning Method to Extract Multi - features from Reviews and User - Item Relations for Rating Prediction. *International Journal of Computational Intelligence Systems*, 5, 1–17. <https://doi.org/10.1007/s44196-023-00288-5>
- Ji, P., & Ma, X. (2023). A fuzzy intelligent group recommender method in sparse-data environments based on multi-agent negotiation. 213(October 2022), 0–2. <https://doi.org/10.1016/j.eswa.2022.119294>
- Jun, J., & Li, Y. (2025). Collaborative filtering recommendation algorithm based on fine-grained mining and neighborhood awareness attention.
- Kolesárová, S., Šenková, A., Kormaníková, E., & Šambronská, K. (2025). The Quality of Hilton Hotel Services in the V4 Countries: The Impact of the Platform on Ratings and Customer Satisfaction. *Tourism and Hospitality*, 6(4). <https://doi.org/10.3390/tourhosp6040169>
- Liao, H. A. O., Wang, S., Cheng, H. A. O., Zhang, W. E. I., & Zhang, J. (2025). Aspect-Enhanced Explainable Recommendation with Multi-modal Contrastive Learning. *ACM Transactions on Intelligent Systems and Technology*, 16(1). <https://doi.org/10.1145/3673234>
- Liu, B. (2012). Sentiment Analysis and Opinion Mining. In *Synthesis Lectures on Human Language Technologies publishes*. <https://doi.org/10.1007/978-3-031-02145-9>
- Liu, H., Jayawardhena, C., Shukla, P., Osburg, V. S., & Yoganathan, V. (2024). Electronic word of mouth 2.0 (eWOM 2.0) – The evolution of eWOM research in the new age. *Journal of Business Research*, 176(January), 114587. <https://doi.org/10.1016/j.jbusres.2024.114587>
- Liu, P., Zhang, L., & Gulla, J. A. (2021). Multilingual Review-Aware Deep Recommender System via Aspect-based Sentiment Analysis. *ACM Transactions on Information Systems*, 39(2). <https://doi.org/10.1145/3432049>
- Liu, X., Guo, J., Hao, Q., Wang, H., Yu, Z., & Yang, Q. (2025). Bridging the gap between ratings and true user opinions with dynamic review alignment for personalized recommendation \$. *Neural Networks*, 191(January), 107706. <https://doi.org/10.1016/j.neunet.2025.107706>
- Mohammed, S., Ghuribi, A. L., Azman, S., Noah, M., Tiun, S., Mohammed, M. A., Izyan, N., & Saat, Y. (2025). Combining review elements for modelling various multi - criteria collaborative recommendation models.
- Nandwani, P., & Verma, R. (2021). A review on sentiment analysis and emotion detection from text. *Social Network Analysis and Mining*, 11(1). <https://doi.org/10.1007/s13278-021-00776-6>
- Ngoc, L. Le, Zhong, J., & Negre, E. (2023). Constraint-based recommender system for crisis management simulations. <https://doi.org/10.48550/arXiv.2306.04553>

- Obiedat, R., Al-Darras, D., Alzaghouli, E., & Harfoushi, O. (2021). Arabic Aspect-Based Sentiment Analysis: A Systematic Literature Review. *IEEE Access*, 9, 152628–152645. <https://doi.org/10.1109/ACCESS.2021.3127140>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-wilson, E., McDonald, S., ... Yhec, C. (2021). The PRISMA 2020 statement : An updated guideline for reporting systematic reviews. *Journal of Clinical Epidemiology*, 134, 178–189. <https://doi.org/10.1016/j.jclinepi.2021.03.001>
- Ricci, F., Shapira, B., & Rokach, L. (2015). Recommender systems handbook, Second edition. In *Recommender Systems Handbook, Second Edition*. <https://doi.org/10.1007/978-1-4899-7637-6>
- Schröder, N., Schultz, C. D., Paetz, F., Grzadziel, A., & Clegg, M. (2025). Unraveling the Influence: Exploring the Role of User Generated Content Along the Customer Journey and Understanding Its Relevance for Research and Practice. *Schmalenbach Journal of Business Research*, 77(3), 457–496. <https://doi.org/10.1007/s41471-025-00214-9>
- Seutter, J., Kutzner, K., Stadtländer, M., Kundisch, D., & Knackstedt, R. (2023). “Sorry, too much information”—Designing online review systems that support information search and processing. *Electronic Markets*, 33(1). <https://doi.org/10.1007/s12525-023-00664-1>
- Sharma, S. N., & Sadagopan, P. (2022). Journal of King Saud University – Computer and Influence of conditional holoentropy-based feature selection on automatic recommendation system in E-commerce sector. *Journal of King Saud University - Computer and Information Sciences*, 34(8), 5564–5577. <https://doi.org/10.1016/j.jksuci.2020.12.022>
- Sun, P., Wu, L. E., Zhang, K. U. N., Su, Y. U., & Wang, M. (2021). *An Unsupervised Aspect-Aware Recommendation Model*. 40(3).
- Tarus, J. K., Niu, Z., & Mustafa, G. (2018). Knowledge-based recommendation: a review of ontology-based recommender systems for e-learning. *Artificial Intelligence Review*, 50(1), 21–48. <https://doi.org/10.1007/s10462-017-9539-5>
- Thomas, R., & Jeba, J. R. (2024). *Revolutionizing E-Commerce : A Deep Learning-Based Sentiment-Driven Recommendation System*. 11(8), 111–122.
- Trisna, K. W., & Jie, H. J. (2022). Deep Learning Approach for Aspect-Based Sentiment Classification: A Comparative Review. *Applied Artificial Intelligence*, 36(1). <https://doi.org/10.1080/08839514.2021.2014186>
- Umair, A., & Masciari, E. (2024). Sentiment Analysis Using Improved CT - BERT _ CONVLayr Fusion Model for COVID - 19 Vaccine Recommendation. *SN Computer Science*. <https://doi.org/10.1007/s42979-024-03296-0>
- Wang, L., Che, G., Hu, J., & Chen, L. (2024). Online Review Helpfulness and Information Overload: The Roles of Text, Image, and Video Elements. *Journal of Theoretical and Applied Electronic Commerce Research*, 19(2), 1243–1266. <https://doi.org/10.3390/jtaer19020064>
- Wang, Q., Wang, J., & Farizah, N. (2025). *SentiEntityRec: Entity-level sentiment perception graph neural network for news recommendation*. <https://doi.org/10.1007/s44443-025-00087-2>
- Wu, S. (n.d.). Temporal-Aware and Aspect Sentiment Driven Recommender Model for Rating Prediction. In *2025 2nd International Conference on Digital Society and*

- Artificial Intelligence (DSAI 2025)*, May 2325, 2025, Wuhan, China (Vol. 1, Issue 1). Association for Computing Machinery.
<https://doi.org/10.1145/3748825.3748901>
- Xia, H., An, W., Liu, G., Hu, R., & Zhang, J. Z. (2021). Smart recommendation for tourist hotels based on multidimensional information : a deep neural network model. *Enterprise Information Systems*, 00(00), 1–25.
<https://doi.org/10.1080/17517575.2021.1959651>
- Yang, C., Chen, X., Liu, L., & Sweetser, P. (2021). *Leveraging semantic features for recommendation : Sentence-level emotion analysis*. 58(February).
<https://doi.org/10.1016/j.ipm.2021.102543>
- Yang, S. (2024). An Attentive Aspect-Based Recommendation Model With Deep Neural Network. *IEEE Access*, 12(December 2023), 5781–5791.
<https://doi.org/10.1109/ACCESS.2023.3349291>
- Yang, S., Li, Q., Jang, D., & Kim, J. (2024). Deep learning mechanism and big data in hospitality and tourism: Developing personalized restaurant recommendation model to customer decision-making. *International Journal of Hospitality Management*, 121(June 2023), 103803.
<https://doi.org/10.1016/j.ijhm.2024.103803>
- Yum, K., & Yoo, B. (2024). Enhancing online reviews: exploring the impact of characteristic-based review system on customer engagement for offline sellers. *Humanities and Social Sciences Communications*, 11(1).
<https://doi.org/10.1057/s41599-024-04082-2>
- Zanon, A. L., Souza, L., Pressato, D., & Manzato, M. G. (2022). A user study with aspect-based sentiment analysis for similarity of items in content-based recommendations. *Expert Systems*, 39(8), 1–15.
<https://doi.org/10.1111/exsy.12991>
- Zhang, C., Xue, S., Li, J., Wu, J., Du, B., Liu, D., & Chang, J. (2023). *Multi-Aspect enhanced Graph Neural Networks for recommendation*. 157, 90–102.
<https://doi.org/10.1016/j.neunet.2022.10.001>
- Zhang, H. (2025). Data & Knowledge Engineering Aspect-level recommendation fused with review and rating representations. *Data & Knowledge Engineering*, 157(February), 102417. <https://doi.org/10.1016/j.datak.2025.102417>