


BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 *Aspect-Base Sentiment Analysis*

Aspect-Based Sentiment Analysis (ABSA) merupakan cabang dari analisis sentimen yang berfokus pada identifikasi dan penentuan sentimen terhadap aspek tertentu dalam suatu kalimat (Zhu dkk., 2023). *ABSA* secara khusus menganalisis sentimen yang diarahkan pada aspek-aspek spesifik dari suatu entitas. Secara umum, penelitian dalam bidang ini mencakup identifikasi elemen-elemen sentimen pada berbagai tingkatan, seperti aspek, kategori aspek, opini, dan polaritas sentimen (Wankhade dkk., 2024). Berdasarkan keluaran yang diharapkan, tugas *Aspect-Based Sentiment Analysis (ABSA)* dapat dikategorikan menjadi dua jenis, yaitu tugas tunggal dan tugas gabungan. Jenis-jenis tugas ABSA secara lebih rinci dapat dilihat pada Gambar 2.1. Pada penelitian ini akan difokuskan pada *ABSA* jenis tugas tunggal, yaitu *Aspect Sentiment Classification*.



Gambar 2. 1 *Aspect-Based Sentiment Analysis Tasks* (Wankhade dkk., 2024)

Aspect Sentiment Classification (ASC) merupakan sub-tugas dari *Aspect-Based Sentiment Analysis (ABSA)* yang fokus pada pengklasifikasian polaritas sentimen positif, negatif, atau netral berdasarkan aspek-aspek tertentu yang telah diekstraksi dari teks. Setelah proses ekstraksi dan identifikasi istilah aspek dilakukan, pendekatan *ABSA* kemudian berlanjut ke tahap klasifikasi polaritas sentimen terhadap masing-masing aspek tersebut (Mao dkk., 2024).

2.1.2 Berita

Berita dan jurnalisme terus berkembang seiring dengan kemajuan teknologi dan perubahan pola konsumsi media. Saat ini, media tidak hanya berperan sebagai penyebar informasi, tetapi juga sebagai instrumen dalam membentuk opini publik, kebijakan sosial, dan dinamika politik. Narasi yang dibangun oleh media dapat memengaruhi persepsi masyarakat terhadap suatu peristiwa, tokoh, atau kebijakan (Abu Draz & Abdelhay, 2025). Selain itu, cara penyajian berita mulai dari pemilihan judul, penggunaan bahasa, hingga sudut pandang yang diangkat dapat secara halus membentuk opini publik. Dunia bisnis juga dipengaruhi oleh pemberitaan mengenai tren ekonomi, inflasi, atau kebijakan pemerintah yang berperan memengaruhi kepercayaan konsumen dan investor. (Haryono dkk., 2022).


2.1.3 *Graph Convolutional Network*

Graph Convolutional Network (GCN) telah menjadi pendekatan populer dalam *Aspect-Based Sentiment Analysis (ABSA)* karena kemampuannya menangkap hubungan kontekstual dan sintaksis dalam teks. *ABSA* bertujuan menentukan sentimen terkait aspek tertentu dari suatu entitas dalam ulasan, dan

GCN meningkatkan akurasi analisis dengan memanfaatkan struktur graf. Dalam *ABSA*, *GCN* digunakan untuk mengembangkan representasi yang lebih kaya dengan menangkap ketergantungan sintaksis dan hubungan semantik antara aspek dan kata-kata di sekitarnya (Wankhade dkk., 2024).

2.1.4 Aspect-Specific Graph Convolutional Network

Model *Aspect-Specific Graph Convolutional Network (ASGCN)* diperkenalkan oleh (C. Zhang dkk., 2019) sebagai solusi untuk mengatasi keterbatasan dalam *Aspect-Based Sentiment Analysis (ABSA)*, khususnya dalam tugas *Aspect Sentiment Classification (ASC)*.



Gambar 2. 2 Arsitektur ASGCN (C. Zhang dkk., 2019)

Model ini mengadopsi pendekatan berbasis *graf* dengan memanfaatkan *Graph Convolutional Networks (GCN)* untuk menangkap hubungan sintaksis antara kata-kata dalam sebuah kalimat, sehingga dapat memahami konteks yang lebih

mendalam terhadap aspek tertentu. Model ini terdiri dari beberapa komponen utama, termasuk *bidirectional LSTM* untuk menangkap informasi kontekstual, *multi-layered GCN* untuk mengekstrak fitur berbasis aspek, serta *aspect-specific masking* yang memastikan hanya kata-kata relevan yang dipertimbangkan dalam analisis sentimen. Penjelasan lebih lanjut mengenai komponen utama *ASGCN* berdasarkan (C. Zhang dkk., 2019) diantaranya:

A. *Embedding* dan *Bidirectional LSTM*

Sebuah kalimat dengan panjang n kata, yang mengandung aspek dengan panjang m kata, model akan mengubah setiap kata ke dalam vektor berdimensi rendah menggunakan matriks *embedding*

$$E \in \mathbb{R}^{V \times d_e}$$

Persamaan (1)

Dimana:

- V adalah ukuran kosa kata.
- d_e adalah dimensi dari *word embedding*.

Setelah *embedding* diperoleh, model menggunakan *Bidirectional LSTM* (*BiLSTM*) untuk mendapatkan representasi konteks dalam kalimat tersebut.

BiLSTM akan menghasilkan vektor hidden state H_c yang berisi:

$$H_c = [h_1, h_2, \dots, h_{n-1}, h_n]$$

Persamaan (2)

di mana setiap vektor hidden state $h_t \in \mathbb{R}^{2d_h}$ pada waktu t merupakan output dari *BiLSTM*, dan d_h adalah dimensi dari hidden state yang dihasilkan oleh *LSTM unidirectional*.

B. Ekstraksi Fitur Berorientasi Aspek

Klasifikasi sentimen berbasis aspek memerlukan fitur yang mempertimbangkan konteks aspek dalam suatu kalimat. *ASGCN* memperoleh fitur ini dengan menerapkan konvolusi *graf* berbasis *dependensi* sintaksis kalimat dan lapisan masking spesifik aspek.

1) *Graph Convolutional Network (GCN)* pada Pohon *Dependensi*

Model menggunakan *Graph Convolutional Network (GCN)* yang dioperasikan pada pohon *dependensi* sintaksis dari kalimat. Pohon ini direpresentasikan dalam bentuk matriks ketetanggaan $A \in \mathbb{R}^{n \times n}$.

Setiap *node* dalam *graf* diperbarui melalui operasi konvolusi sebagai berikut:

$$h_i^l = \sum_j^n A_{ij} W^l g_j^{l-1}$$

Persamaan (3)

$$h_i^l = \text{ReLU}(h_i^l(d_i + 1) + b^l)$$

Persamaan (4)

Dimana:

- $h_i^l \in \mathbb{R}^{2d_h}$ adalah representasi token i setelah lapisan *GCN* ke- l .
- $g_j^{l-1} \in \mathbb{R}^{2d_h}$ adalah representasi token j dari lapisan sebelumnya.
- $d_i = \sum_{j=1}^n A_{ij}$ adalah derajat node i dalam pohon.
- W^l dan b^l adalah bobot yang dapat dilatih.

Untuk meningkatkan pemahaman konteks terkait aspek, diterapkan transformasi berbasis posisi sebagai berikut:

$$g_i^l = F(h_i^l)$$

Persamaan (5)

Dengan fungsi $F()$ sebagai berikut:

$$q_i = \begin{cases} 1, & 1 \leq i < s+1 \\ 0, & s+1 \leq i \leq s+m \\ 1, & s+m < i \leq n \end{cases}$$

$$F(h_i^l) = q_i h_i^l$$

Persamaan (6)

Dimana :

- q_i adalah bobot posisi untuk token ke- i
- s adalah posisi awal aspek dalam kalimat
- m adalah jumlah kata dalam aspek,
- n adalah panjang total kalimat
- h_i^l adalah representasi hidden state dari token ke- i pada lapisan ke- l

Fungsi ini memastikan bahwa aspek mendapatkan bobot yang lebih besar dibandingkan kata-kata lain di luar aspek, sehingga dapat membantu model fokus pada aspek yang relevan.

Setelah melewati L lapisan GCN , representasi akhirnya adalah:

$$H^L = [h_1^L, h_2^L, \dots, h_8^L, h_{8+1}^L, \dots, h_{8+m}^L, h_{8+m+1}^L, \dots, h_n^L]$$

Persamaan (7)

Dengan $h_t^L \in \mathbb{R}^{2d_h}$ sebagai representasi hidden state akhir dari token ke- t

2) *Aspect-Specific Masking*

Tahapan ini hanya *hidden state* dari kata-kata aspek yang dipertahankan, sedangkan kata-kata lain dimasking dengan nol:

$$h_t^L = \begin{cases} 0, & 1 \leq t < s + 1 \text{ atau } s + m < t \leq n \\ h_t^L, & s + 1 \leq t \leq s + m \end{cases}$$

Persamaan (8)

Sehingga, output yang diperoleh adalah:

$$H_{mask}^L = \{0, h_{s+1}^L, \dots, h_{s+m}^L, 0\}$$

Persamaan (9)

Fitur yang diperoleh melalui konvolusi *graf* ini mampu menangkap hubungan sintaksis dan hubungan antar-kata dalam jarak panjang.

C. Atensi Berbasis Aspek

Fitur berorientasi aspek yang telah diperoleh digunakan oleh model untuk menerapkan mekanisme *retrieval-based attention* guna mendapatkan representasi fitur yang lebih relevan terhadap aspek..

Bobot atensi dihitung sebagai berikut:

$$a_t = \sum_{i=1}^n h_t^c \cdot h_i^L = \sum_{i=s+1}^{s+m} h_t^c \cdot h_i^L$$

$$a_t = \frac{\exp(a_t)}{\sum_{i=1}^n \exp(a_i)}$$

Persamaan (10)

Representasi akhir fitur sebelum klasifikasi dihitung sebagai:

$$r = \sum_{t=1}^n a_t h_t^c$$

Persamaan (11)

D. Klasifikasi Sentimen

Fitur r kemudian digunakan sebagai input ke dalam lapisan *fully-connected* dan *softmax* untuk menghasilkan distribusi probabilitas sentimen:

$$p = \text{softmax}(W_p r + b_p)$$

Persamaan (12)

Dimana:

- $p \in \mathbb{R}^{d_p}$ adalah vektor probabilitas kelas sentimen,
- $W_p \in \mathbb{R}^{d_p \times 2d_h}$ dan $b_p \in \mathbb{R}^{d_p}$ adalah bobot dan bias yang dipelajari.
- d_p adalah jumlah kelas sentimen (misalnya: positif, negatif, netral).

E. Pelatihan Model

Model dilatih menggunakan algoritma *gradient descent* dengan fungsi *loss cross-entropy* serta regularisasi L2:

$$Loss = - \sum_{(c,p) \in C} \log p_p + \frac{\lambda}{2} \|\theta\|^2$$

Persamaan (13)

Dimana:

- C adalah dataset latih.
- p_p adalah probabilitas prediksi kelas benar.
- θ mewakili semua parameter model.
- λ adalah koefisien regulasi L2

2.2 State-of-the-Art

State of the art yang disajikan pada Tabel 2.1 berisi tentang hasil penelitian yang sudah dilakukan sebelumnya, berkaitan dengan penerapan judul penelitian yang dilakukan yaitu "Klasifikasi Sentimen Berbasis Aspek Pada Berita Saham Menggunakan model *Aspect-Specific Graph Convolutional Network*".

Tabel 2. 1 *State-Of-The-Art*

No	Nama Peneliti/Journal		Hasil Penelitian
1	Peneliti (tahun)	(Haryono dkk., 2022)	Metode gabungan antara <i>semantic similarity</i> , <i>BLSTM</i> dan <i>word embedding Word2Vec</i> menghasilkan performa terbaik dalam klasifikasi aspek, dengan akurasi dan <i>F1-score</i> mencapai 88,1%. Untuk klasifikasi sentimen, akurasi mencapai 77%, dengan <i>F1-score</i> sebesar 74%. Analisis menunjukkan bahwa aspek <i>stock</i> paling banyak memiliki sentimen positif, dengan selisih tertinggi sebesar 2,84% dibanding <i>ground truth</i> .
	Judul	<i>Aspect-Based Sentiment Analysis of Financial Headlines and Microblogs Using Semantic Similarity and Bidirectional Long Short-Term Memory</i>	
	Algoritma/Metode	<i>BiLSTM</i>	
2	Peneliti (tahun)	(Tyas dkk., 2024)	Pendekatan <i>Transfer Learning</i> , khususnya <i>BERT</i> , menghasilkan akurasi tertinggi sebesar 81%, diikuti oleh <i>RoBERTa</i> dengan 79%, dan <i>GCN</i> dengan 73.1%. Sementara itu, metode <i>Deep Learning</i> seperti <i>Bi-LSTM</i> mencetak 71%, dan metode <i>Machine Learning</i> klasik seperti <i>Logistic Regression</i> hanya mencapai 68.5%. Menegaskan bahwa metode berbasis <i>Transfer Learning</i> dan <i>Graph</i> lebih unggul dalam menangkap konteks dan nuansa bahasa dalam berita saham dibandingkan metode lainnya.
	Judul	Analisis Perbandingan Metode Klasifikasi Sentimen Berita Saham: Pendekatan <i>Machine Learning</i> , <i>Deep Learning</i> , <i>Transfer Learning</i> , dan <i>Graph</i>	
	Algoritma/Metode	<i>LR, LSTM, BiLSTM, BERT, RoBERTa, GCN</i>	

No	Nama Peneliti/Journal		Hasil Penelitian
3	Peneliti (tahun)	(Sousa dkk., 2019)	Model <i>BERT</i> menunjukkan performa terbaik dibandingkan metode lain seperti <i>Naive Bayes</i> , <i>Support Vector Machine (SVM)</i> , dan <i>TextCNN</i> . <i>BERT</i> memperoleh akurasi sebesar 82.5% dan <i>F1-score</i> sebesar 72.5%, jauh melampaui metode lain yang berada di bawah 74%. Selain itu, analisis perbandingan sentimen berita terhadap fluktuasi indeks DJI menunjukkan bahwa dalam 69% kasus, sentimen yang dihasilkan model konsisten dengan arah pergerakan indeks saham pada hari tersebut.
	Judul	<i>BERT for Stock Market Sentiment Analysis</i>	
	Algoritma/Metode	<i>BERT</i>	
4	Peneliti (tahun)	(Alifi dkk., 2023)	Model <i>IndoNLU</i> berhasil mencapai performa yang tinggi dengan rata-rata akurasi, <i>precision</i> , <i>recall</i> , dan <i>F1-score</i> sebesar 90% pada ketiga kelas sentimen. Secara spesifik, kelas negatif mencetak <i>F1-score</i> sebesar 95%, netral sebesar 89%, dan positif sebesar 87%.
	Judul	<i>Implementation of IndoNLU Pre-Trained Model for Aspect-Based Sentiment Analysis of Indonesian Stock News</i>	
	Algoritma/Metode	<i>BERT</i>	
5	Peneliti (tahun)	(Aziz dkk., 2024)	Model <i>Enhanced UrduAspectNet</i> menunjukkan peningkatan kinerja yang signifikan dibandingkan <i>UrduAspectNet</i> sebelumnya. Untuk identifikasi aspek, model baru mencetak <i>precision</i> sebesar 92.85% dan <i>F1-score</i> 84.67%, sementara untuk klasifikasi sentimen, ia mencapai akurasi 92.19% dan <i>F1-score</i> 85.72%. Hasil <i>ablation study</i> menunjukkan bahwa penghapusan <i>GCN</i> atau <i>Biaffine Attention</i> mengakibatkan penurunan yang nyata dalam performa, menegaskan pentingnya setiap komponen dalam arsitektur.
	Judul	<i>Enhanced urduaspectnet: leveraging biaffine attention for superior aspect-based sentiment analysis</i>	
	Algoritma/Metode	<i>GCN, BiLSTM</i>	

No	Nama Peneliti/Journal		Hasil Penelitian
6	Peneliti (tahun)	(Hridoy dkk., 2021)	<i>Bernoulli Naive Bayes</i> menunjukkan performa terbaik dengan <i>F1-score</i> sebesar 70.75% dan akurasi 68.08%. <i>Logistic Regression</i> mengikuti dengan <i>F1-score</i> 70.6%, sedangkan algoritma lain seperti <i>SVM</i>, <i>SGD</i>, dan <i>Random Forest</i> mencetak hasil yang lebih rendah. Model yang diusulkan juga berhasil mengekstraksi aspek dari headline secara efektif menggunakan pendekatan linguistik dan mendapatkan hasil klasifikasi sentimen yang kompetitif, menunjukkan bahwa pendekatan ini layak untuk diterapkan lebih luas.
	Judul	<i>Aspect Based Sentiment Analysis for Bangla Newspaper Headlines</i>	
	Algoritma/Metode	<i>BERT, NB, LR, SVM</i>	
7	Peneliti (tahun)	(Nadeem dkk., 2025)	Model yang diusulkan menghasilkan akurasi tertinggi dibandingkan baseline seperti <i>Naive Bayes</i>, <i>Random Forest</i>, <i>BiLSTM</i>, dan model <i>ABSA</i> terkini seperti <i>SenticGCN</i> dan <i>T-GCN-BERT</i>. Akurasi klasifikasi sentimen per kategori mencapai 90.52% (positif), 89.12% (negatif), dan 84.32% (netral), dengan <i>F1-score</i> masing-masing 85.03%, 86.05%, dan 71.06%. Studi ablation menunjukkan bahwa modul <i>WSD</i> memberikan kontribusi signifikan terhadap peningkatan performa. <i>Cosine similarity</i> terbukti sebagai metrik kesamaan paling efektif dalam proses disambiguasi.
	Judul	<i>Resolving ambiguity in natural language for enhancement of aspect-based sentiment analysis of hotel reviews</i>	
	Algoritma/Metode	<i>BERT, BiLSTM, GCN</i>	
8	Peneliti (tahun)	(Fu dkk., 2024)	Model <i>LSEMH-GCN</i> menghasilkan rata-rata peningkatan <i>F1-score</i> sebesar 15.52% pada dataset <i>Restaurant-ACOS</i> dan 12.30% pada dataset <i>Laptop-ACOS</i>. Evaluasi berdasarkan metrik <i>presisi</i>, <i>recall</i>, dan <i>F1</i> menunjukkan bahwa model ini sangat efektif dalam menangani aspek eksplisit maupun implisit. Selain itu,
	Judul	<i>Label-semantics enhanced multi-layer heterogeneous GCN for Aspect Sentiment Quadruplet Extraction</i>	

No	Nama Peneliti/Journal		Hasil Penelitian
	Algoritma/Metode	<i>GCN, BERT</i>	eksperimen ablation menegaskan kontribusi krusial dari modul semantik label dan fitur linguistik terhadap peningkatan performa secara keseluruhan dalam ekstraksi kuadruplet.
9	Peneliti (tahun)	(Q. Zhao dkk., 2024)	<i>SDTGCN</i> menunjukkan performa terbaik mencapai akurasi dan <i>macro-F1</i> yang lebih tinggi secara konsisten, pada <i>dataset Rest16</i> , <i>SDTGCN</i> mencetak 91.53% akurasi dan 77.08% <i>F1-score</i> , mengungguli model seperti <i>SenticGCN</i> dan <i>InterGCN</i> . Studi ablation juga menunjukkan bahwa setiap komponen dalam <i>SDTGCN</i> , seperti struktur pohon dan agregasi berbobot, memberikan kontribusi signifikan terhadap peningkatan performa.
	Judul	<i>Modeling Structured Dependency Tree with Graph Convolutional Networks for Aspect-Level Sentiment Classification</i>	
	Algoritma/Metode	<i>GCN, BiLSTM</i>	
10	Peneliti (tahun)	(Yi dkk., 2024)	Model <i>CSADGCN</i> secara konsisten melampaui baseline terkini baik berbasis attention maupun <i>GCN</i> , terutama dalam akurasi dan skor F1 di ketiga dataset. Model ini unggul dalam menangani data dengan struktur sintaksis lemah, serta mampu menurunkan noise yang dihasilkan oleh mekanisme attention. Studi <i>ablation</i> menunjukkan bahwa setiap komponen (<i>attention</i> terpandu, <i>SemGCN</i> , <i>SynGCN</i> , dan <i>agregasi</i>) berkontribusi signifikan terhadap performa akhir.
	Judul	<i>Context-guided and syntactic augmented dual GCN for aspect-based sentiment analysis</i>	
	Algoritma/Metode	<i>GCN, BERT</i>	
11	Peneliti (tahun)	(K. Yang dkk., 2025)	Model ini secara konsisten menghasilkan peningkatan presisi dan akurasi dalam mengekstraksi <i>triplet</i> , termasuk pada kasus-kasus dengan opini implisit atau struktur kalimat kompleks. Studi ablation juga menunjukkan bahwa penghapusan modul apa pun (<i>GCN</i> , strategi pemurnian, atau <i>PagFM</i>) menyebabkan penurunan performa, menegaskan bahwa setiap komponen memberikan kontribusi signifikan.
	Judul	<i>Multi-channel GCN network based on position-aware gating fusion for aspect sentiment triplet extraction</i>	
	Algoritma/Metode	<i>BERT, GCN</i>	

No	Nama Peneliti/Journal		Hasil Penelitian
12	Peneliti (tahun)	(Zhu dkk., 2023b)	<i>KMGCN</i> secara konsisten mengungguli baseline model termasuk <i>BERT-BASE</i>, <i>MGAN</i>, dan <i>SenticGCN-BERT</i> dalam 12 dataset uji <i>robustness</i> yang bervariasi dari <i>SemEval-2014</i>. Model ini menunjukkan peningkatan signifikan dalam akurasi dan <i>F1-score</i>, terutama pada skenario dengan noise tinggi seperti pembalikan sentimen aspek non-target dan penambahan aspek berlawanan. Studi ablation juga membuktikan bahwa setiap komponen dari <i>KMGCN</i>—baik <i>self-attention</i>, dynamic decision module, maupun pengetahuan eksternal—berkontribusi besar terhadap kinerja keseluruhan.
	Judul	<i>Knowledge-guided multi-granularity GCN for ABSA</i>	
	Algoritma/Metode	<i>BERT, GCN</i>	
13	Peneliti (tahun)	(Z. Zhang dkk., 2024)	<i>FGD-GCN</i> mengungguli berbagai metode sebelumnya, termasuk model berbasis <i>LSTM</i>, <i>GCN</i>, dan <i>BERT</i>. Model ini mencapai akurasi dan F1-score tertinggi secara konsisten, khususnya pada dataset Twitter dan Laptop. Hasil ablation study juga menunjukkan bahwa setiap komponen model <i>attention</i>, <i>CNN</i>, dan <i>PAM</i> berkontribusi signifikan terhadap peningkatan performa. <i>FGD-GCN</i> secara efektif menangkap interaksi semantik dan sintaksis sekaligus mengurangi dampak kata-kata yang tidak relevan terhadap prediksi sentimen aspek.
	Judul	<i>Aspect-Level Sentiment Analysis Based on Fusion Graph Double Convolutional Neural Networks</i>	
	Algoritma/Metode	<i>BERT, BiLSTM, GCN</i>	
14	Peneliti (tahun)	(Wan dkk., 2024)	Model <i>SIS</i> menunjukkan performa unggul dibandingkan berbagai pendekatan token-level dan span-level pada empat dataset benchmark (Lap14, Res14, Res15, Res16). <i>SIS</i> mencatat <i>F1-score</i> tertinggi di tiga dataset serta presisi tertinggi pada dataset Res14. Ablation study menunjukkan bahwa penghapusan informasi sintaksis menurunkan performa model secara signifikan, menegaskan pentingnya integrasi <i>GCN</i> dan <i>dependency parsing</i>.
	Judul	<i>SIS: A Syntactic Information-based Span-level Model for Aspect Sentiment Triplets Extraction</i>	
	Algoritma/Metode	<i>BERT, GCN</i>	

No	Nama Peneliti/Journal		Hasil Penelitian
			Eksperimen juga menunjukkan bahwa teknik pemangkasan span berbasis POS dan pengaturan jumlah lapisan <i>GCN</i> secara optimal meningkatkan efisiensi dan akurasi.
15	Peneliti (tahun)	(Deng dkk., 2024)	Model <i>CDSA-MixGCN</i> menunjukkan performa terbaik dibandingkan dengan berbagai model state-of-the-art, baik dengan <i>embedding GloVe</i> maupun <i>BERT</i> . Hasil eksperimen menunjukkan akurasi dan F1-score tertinggi secara konsisten di semua dataset. Ablation study menegaskan bahwa penghapusan salah satu komponen seperti <i>Mixhop</i> , <i>attention</i> , atau <i>cross-distance syntactic-aware</i> , menurunkan performa secara signifikan. Secara khusus, integrasi <i>Mixhop</i> dan <i>cross-layer attention</i> sangat efektif dalam menangani kalimat panjang dan struktur sintaksis kompleks.
	Judul	<i>A Mixed Graph Convolutional Network with Cross-Distance Syntactic Aware for ABSA</i>	
	Algoritma/Metode	<i>BERT, GCN</i>	
16	Peneliti (tahun)	(Y. Zhao dkk., 2025)	<i>SSFF-GCN</i> mengungguli berbagai model baseline seperti <i>LSTM</i> , <i>LAN</i> , <i>ASGCN</i> , <i>SKGCN</i> , dan <i>R-GAT</i> , baik dalam akurasi maupun skor F1. Khususnya dengan kombinasi <i>BERT</i> , model mencapai akurasi hingga 87.11% dan F1-score 81.79% pada dataset Restaurant. Studi ablation menunjukkan bahwa setiap komponen (<i>bi-affine attention</i> , <i>attention mechanism</i> , <i>fusion gating</i>) memberikan kontribusi signifikan terhadap performa. Model ini juga menunjukkan ketahanan yang baik terhadap kalimat yang mengandung opini implisit dan struktur kalimat kompleks.
	Judul	<i>Fine-Grained Sentiment Analysis Based on SSFF-GCN Model</i>	
	Algoritma/Metode	<i>GCN, BiLSTM, BERT</i>	
17	Peneliti (tahun)	(Feng dkk., 2023)	

No	Nama Peneliti/Journal		Hasil Penelitian
	Judul	<i>Fusing Syntax and Semantics-Based Graph Convolutional Network for Aspect-Based Sentiment Analysis</i>	Model imenunjukkan peningkatan yang signifikan dibandingkan model berbasis sintaksis dan model <i>BERT-SPC</i> dalam hal akurasi dan <i>macro-F1 score</i> . Secara khusus, <i>FSSGCN+BERT</i> mencapai akurasi 87.79% dan F1 score 82.72% pada dataset Restaurant14.
	Algoritma/Metode	<i>GCN</i>	
18	Peneliti (tahun)	(Kong dkk., 2024)	Model <i>DRD-SE-GCN</i> menghasilkan performa terbaik mencatat akurasi tertinggi hingga 85.14% dan F1-score 78.15%, mengungguli model sebelumnya dengan margin signifikan. Hasil ablation study juga menunjukkan bahwa setiap komponen dari <i>DRD</i> dan <i>SE</i> secara independen memberikan kontribusi yang substansial terhadap peningkatan performa model.
	Judul	<i>Distance-reconstructed Dependency Enhanced ABSA with Sentiment Strength</i>	
	Algoritma/Metode	<i>BiLSTM, GCN</i>	
19	Peneliti (tahun)	(Wu dkk., 2025)	<i>JDDE-GCN</i> secara konsisten mengungguli model baseline pada dua dataset benchmark (Rest15 dan Rest16) dalam tiga tugas utama: <i>target-sentiment detection (TSD)</i> , <i>aspect-sentiment detection (ASD)</i> , dan <i>target-aspect-sentiment detection (TASD)</i> . Dalam tugas <i>TASD</i> , model mencetak F1-score tertinggi dibanding model seperti <i>TAS-BERT</i> dan <i>DOER</i> , dengan peningkatan performa hingga 2% di beberapa metrik. Studi ablation menunjukkan bahwa setiap komponen seperti <i>GCN</i> , <i>edge embedding</i> , <i>POS</i> , dan <i>attention</i> memberikan kontribusi signifikan terhadap akurasi, dengan penghapusan <i>GCN</i> menyebabkan penurunan performa paling drastis.
	Judul	<i>Dual edge-embedding graph convolutional network for unified aspect-based sentiment analysis</i>	
	Algoritma/Metode	<i>BiLSTM, GCN</i>	
20	Peneliti (tahun)	(Wafda dkk., 2025)	Model klasifikasi aspek yang dikembangkan berhasil mencapai akurasi, presisi, <i>recall</i> , dan <i>F1-score</i> sebesar 97%, menunjukkan bahwa <i>IndoBERT</i> sangat efektif dalam mengenali aspek-aspek Kurikulum Merdeka. Untuk klasifikasi sentimen, model juga
	Judul	<i>Aspect-Based Sentiment Analysis On Twitter Tweets About The Merdeka Curriculum Using Indobert</i>	

No	Nama Peneliti/Journal		Hasil Penelitian
	Algoritma/Metode	<i>BERT</i>	menunjukkan performa baik dengan skor 85% untuk keempat metrik evaluasi. Distribusi sentimen menunjukkan bahwa aspek Modul Ajar didominasi sentimen negatif, sedangkan aspek P5, PMM, dan RP lebih banyak mendapat sentimen positif dan netral.

Berdasarkan kajian terhadap penelitian sebelumnya yang telah dilakukan diketahui bahwa model *deep learning* terutama *GCN* memiliki kinerja yang unggul dalam analisis sentimen berbasis aspek. Sementara penelitian analisis sentimen berbasis aspek pada berita saham berbahasa Indonesia sebelumnya telah dilakukan oleh beberapa peneliti, tetapi penelitiannya masih cukup terbatas sehingga memberikan ruang untuk pengembangan lebih lanjut. Berdasarkan hal tersebut, dilakukan penelitian dengan judul “Klasifikasi Sentimen Berbasis Aspek Pada Berita Saham Menggunakan Model *Aspect-Specific Graph Convolutional Network*”.

2.3 Matriks Penelitian

Tabel 2.2 menyajikan matriks penelitian yang membandingkan berbagai studi terkait analisis sentimen berbasis aspek dengan menggunakan pendekatan machine learning dan deep learning. Setiap kolom dalam tabel memberikan informasi mengenai metode yang digunakan, jenis dataset yang digunakan, serta tujuan dari masing-masing penelitian, sehingga memberikan gambaran yang komprehensif terhadap perkembangan dan arah penelitian di bidang analisis sentimen berbasis aspek.

Tabel 2. 2 Matriks Penelitian

No	Peneliti/ Tahun	Judul	Ruang Lingkup										
			Algoritma					Dataset			Tujuan Penelitian		
			<i>LR</i>	<i>LSTM</i>	<i>BiLSTM</i>	<i>BERT</i>	<i>GCN</i>	Berita	Ulasan	Twitter	Implementasi	Optimalisasi	Perbandingan
1.	(Haryono dkk., 2022)	<i>Aspect-Based Sentiment Analysis of Financial Headlines and Microblogs Using Semantic Similarity and Bidirectional Long Short-Term Memory</i>			✓			✓			✓		
2.	(Tyas dkk., 2024)	Analisis Perbandingan Metode Klasifikasi Sentimen Berita Saham: Pendekatan <i>Machine Learning</i> , <i>Deep Learning</i> , <i>Transfer Learning</i> , dan <i>Graph</i>	✓	✓			✓	✓					✓
3.	(Sousa dkk., 2019)	<i>BERT for Stock Market Sentiment Analysis</i>				✓		✓			✓		

4.	(Alifi dkk., 2023a)	<i>Implementation of IndoNLU Pre-Trained Model for Aspect-Based Sentiment Analysis of Indonesian Stock News</i>				✓		✓			✓		
5.	(Aziz dkk., 2024)	<i>Enhanced urduaspectnet: leveraging biaffine attention for superior aspect-based sentiment analysis</i>					✓	✓			✓	✓	
6.	(Hridoy dkk., 2021)	<i>Aspect Based Sentiment Analysis for Bangla Newspaper Headlines</i>	✓			✓		✓			✓		
7.	(Nadeem dkk., 2025)	<i>Resolving ambiguity in natural language for enhancement of aspect-based sentiment analysis of hotel reviews</i>			✓	✓	✓		✓			✓	
8.	(Fu dkk., 2024)	<i>Label-semantics enhanced multi-layer heterogeneous GCN for Aspect Sentiment Quadruplet Extraction</i>				✓	✓		✓			✓	
9.	(Q. Zhao dkk., 2024)	<i>Modeling Structured Dependency Tree with Graph Convolutional Networks for Aspect-Level Sentiment Classification</i>			✓		✓		✓			✓	

10.	(Yi dkk., 2024)	<i>Context-guided and syntactic augmented dual GCN for aspect-based sentiment analysis</i>				✓	✓		✓			✓	
11.	(K. Yang dkk., 2025)	<i>Multi-channel GCN network based on position-aware gating fusion for aspect sentiment triplet extraction</i>				✓	✓		✓			✓	
12.	(Zhu dkk., 2023b)	<i>Knowledge-guided multi-granularity GCN for ABSA</i>				✓	✓		✓			✓	
13.	(Z. Zhang dkk., 2024)	<i>Aspect-Level Sentiment Analysis Based on Fusion Graph Double Convolutional Neural Networks</i>			✓	✓	✓		✓			✓	
14.	(Wan dkk., 2024)	<i>SIS: A Syntactic Information-based Span-level Model for Aspect Sentiment Triplets Extraction</i>				✓	✓		✓			✓	
15.	(Deng dkk., 2024)	<i>A Mixed Graph Convolutional Network with Cross-Distance Syntactic Aware for ABSA</i>				✓	✓		✓			✓	
16.	(Y. Zhao dkk., 2025)	<i>Fine-Grained Sentiment Analysis Based on SSFF-GCN Model</i>			✓	✓	✓		✓			✓	

17.	(Feng dkk., 2023)	<i>Fusing Syntax and Semantics-Based Graph Convolutional Network for Aspect-Based Sentiment Analysis</i>					✓		✓			✓	
18.	(Kong dkk., 2024)	<i>Distance-reconstructed Dependency Enhanced ABSA with Sentiment Strength</i>			✓		✓		✓			✓	
19.	(Wu dkk., 2025)	<i>Dual edge-embedding graph convolutional network for unified aspect-based sentiment analysis</i>			✓		✓		✓			✓	
20.	(Wafda dkk., 2025)	<i>Aspect-Based Sentiment Analysis On Twitter Tweets About The Merdeka Curriculum Using Indobert</i>				✓			✓		✓		

Penggunaan *Graph Convolutional Network (GCN)* dalam penelitian sebelumnya umumnya difokuskan pada upaya optimalisasi metode untuk meningkatkan akurasi, namun penerapannya masih terbatas pada dataset benchmark dan belum banyak diarahkan pada domain spesifik. Di sisi lain, analisis sentimen pada berita saham berbahasa Indonesia selama ini lebih banyak berfokus pada analisis sentimen umum (Tyas dkk., 2024). Berdasarkan hal tersebut, penerapan analisis sentimen berbasis aspek pada domain

spesifik, seperti berita saham, menjadi penting guna mendukung pengembangan sistem yang lebih andal dan efektif dalam melakukan analisis sentimen berbasis aspek.