JSiI | Jurnal Sistem Informasi
Vol. 13 No. 1 | March 2026, P. 115-125

p-ISSN: 2406-7768
e-ISSN: 2581-2181

ANALISIS POLARISASI OPINI BBM MENGGUNAKAN GCN DAN PMI

Chalifa Chazar [1], Dea Amelia Azzahra [*2], Asep Nana Hermana [3], Marisa Premitasari [4]

[1,2,3,4]*Jurusan Informatika Fakultas Teknologi Industri Institut Teknologi Nasional Bandung*
Jalan PHH Mustapha No. 23 – Kota Bandung

[1]chalifa@itenas.ac.id

[*2] dea.amelia@mhs.itenas.ac.id

[3]asep_nana@itenas.ac.id

[4]marisa@itenas.ac.id

Abstract

This study analyzes the polarization of public opinion regarding the removal of fuel subsidies in Indonesia using a graph-based sentiment classification approach that integrates Pointwise Mutual Information (PMI) and Graph Convolutional Networks (GCN). Sentiment analysis of social media data presents challenges due to the short and noisy nature of texts, which often limits the performance of conventional classification methods in capturing contextual and semantic relationships. Additionally, many existing approaches primarily rely on vector-based text representations and do not explicitly capture semantic relationships between words within a graph structure. To address this limitation, this study proposes a graph-based representation that incorporates PMI to strengthen semantic relationships between words in the construction of a GCN model. A dataset consisting of 557 tweets related to the fuel subsidy issue was collected and preprocessed before being transformed into a graph representation. In this graph representation, document-word relationships were weighted using TF-IDF, while word-word relationships were weighted using PMI to capture co-occurrence-based semantic associations. Two experimental scenarios were evaluated: a baseline GCN model without PMI and a PMI-enhanced GCN model. Both models were trained using a 70:15:15 train-validation-test split with identical hyperparameter settings. The experimental results show that the baseline GCN achieved an accuracy of 65%, while the integration of PMI improved the accuracy to 73%. These findings indicate that incorporating PMI enriches the semantic relationships within the graph representation and improves the effectiveness of GCN in sentiment classification tasks. The proposed approach contributes to the development of graph-based sentiment analysis methods and provides insights into public opinion polarization related to government policy issues on social media.

Keywords— Graph Convolutional Networks, Pointwise Mutual Information, Sentiment Analysis, Public Opinion, Social Media, Fuel Subsidy Policy.

I. PENDAHULUAN

Media sosial kini menjadi ruang utama bagi masyarakat untuk menyampaikan pendapat politik dan memberikan tanggapan terhadap kebijakan pemerintah di era digital. Penyebaran informasi yang sangat cepat mengakibatkan munculnya berbagai masalah strategis yang menimbulkan perdebatan di kalangan masyarakat. Salah satu isu yang menjadi perhatian publik adalah kebijakan penghapusan subsidi bahan bakar minyak (BBM), yang menyebabkan polarisasi opini di media sosial selama tahun 2024 [1]. Untuk mengetahui respons masyarakat terhadap perubahan kebijakan tersebut, analisis sentimen menjadi pendekatan penting yang dapat digunakan untuk mengklasifikasikan kecenderungan opini publik ke dalam kategori positif atau negatif [2].

Metode klasifikasi sentimen konvensional seperti Naive Bayes, SVM, dan LSTM sudah banyak diterapkan, tetapi metode ini lebih fokus pada isi teks tanpa mempertimbangkan keterkaitan antara elemen dalam data teks [3]. Namun, dalam teks terdapat hubungan yang kompleks antarkata dan dokumen yang tidak selalu bisa digambarkan dengan baik oleh model yang berbasis vektor atau urutan.

Untuk mengatasi keterbatasan tersebut, metode yang berbasis graf mulai diterapkan secara luas dalam analisis teks. *Graph Convolutional Networks* (GCN) adalah salah satu metode yang dapat memanfaatkan struktur graf untuk menggambarkan hubungan antarkata dan antardokumen dalam suatu korpus teks [4]. Dengan menggambarkan teks sebagai graf yang terdiri dari node dan edge, GCN mampu menangkap hubungan semantik antara elemen teks dibandingkan dengan metode sekuensial. Namun, GCN masih memiliki keterbatasan dalam memahami hubungan semantik yang lebih kompleks, karena proses pengumpulan informasi dalam model ini biasanya hanya memperhitungkan node tetangga terdekat dalam graf.

Untuk memperkuat kemampuan representasi semantik dalam graf, sejumlah penelitian menerapkan metode pembobotan antarkata. Salah satu pendekatan yang dapat

Received: Jan 15th, 2026 | Published: March 30th, 2026

p-ISSN: 2406-7768
e-ISSN: 2581-2181

digunakan adalah *Pointwise Mutual Information* (PMI), yang mengukur kekuatan asosiasi antara dua kata berdasarkan frekuensi kemunculan bersama dalam suatu kumpulan teks. PMI dapat menggambarkan hubungan makna antarkata dengan lebih baik, sehingga efektif diterapkan sebagai pembobotan relasi dalam konstruksi graf dan dapat meningkatkan kemampuan dalam klasifikasi sentimen [5]

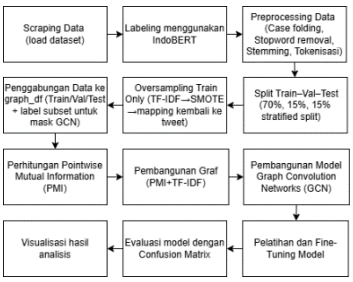
Seiring dengan berkembangnya penelitian di bidang *Natural Language Processing* (NLP), pendekatan berbasis graf semakin banyak diterapkan untuk berbagai tugas klasifikasi teks. *Graph Neural Networks* (GNN) menjadi salah satu metode yang dapat memanfaatkan struktur graf untuk menangkap hubungan kompleks antara kata, dokumen, dan konteks keseluruhan dalam suatu kumpulan teks [6]. Selain itu, penelitian terbaru juga menunjukkan bahwa model berbasis graf terus mengalami perkembangan dengan berbagai variasi struktur untuk meningkatkan kemampuan representasi hubungan dalam teks. Salah satu pendekatan yang dikembangkan adalah *Relational Graph Convolution Networks* (RGCN), yang memungkinkan pemodelan berbagai jenis hubungan antarnode dalam graf, sehingga dapat memperkuat kemampuan analisis sentimen yang berbasis graf [7]. Penelitian lain juga menunjukkan bahwa penerapan pembobotan semantik seperti PMI dalam penyusunan graf pada model GCN dapat memperkaya representasi hubungan antarkata serta meningkatkan kinerja klasifikasi sentimen dalam data teks [8]

Meskipun berbagai pendekatan berbasis graf telah dikembangkan untuk analisis sentimen, sebagian besar penelitian masih berfokus pada pengembangan struktur model atau pembentukan graf secara umum. Penggunaan pembobotan semantik PMI dalam model GCN untuk menganalisis sentimen terkait isu kebijakan publik masih relatif terbatas, khususnya dalam konteks analisis opini masyarakat terhadap kebijakan pemerintah di Indonesia. Selain itu, fenomena polarisasi opini publik mengenai kebijakan penghapusan subsidi BBM di media sosial juga belum banyak diteliti dengan menggunakan pendekatan analisis sentimen berbasis graf.

Selain itu, data opini politik di media sosial sering kali menunjukkan ketidakseimbangan dalam distribusi kelas yang dapat membuat model klasifikasi cenderung bias pada kelas mayoritas, terutama dalam metode yang menggunakan graf seperti GCN. Oleh karena itu, tujuan dari penelitian ini adalah untuk menganalisis polarisasi opini publik terkait kebijakan penghapusan subsidi BBM di media sosial, dengan menggunakan pendekatan GCN yang diperkuat dengan pemberian bobot semantik PMI untuk meningkatkan kualitas representasi graf dan performa klasifikasi sentimen.

II. METODOLOGI PENELITIAN

Penelitian ini dilakukan menggunakan bahasa pemrograman Python pada lingkungan Google Colab dengan bantuan beberapa pustaka, antara lain *pandas, numpy, nltk, scikit-learn, imbalanced-learn, transformers, torch,* dan *torch-geometric.* Tahapan penelitian meliputi pemuatan data, praproses teks, pembagian data, *oversampling,* pembentukan graf berbasis PMI dan TF-IDF, pelatihan model GCN, serta evaluasi kinerja. Alur metodologi penelitian disajikan secara visual pada Gambar 1.



Gambar 1. Diagram Blok Metodologi Penelitian

Gambar 1 menunjukkan bahwa metodologi penelitian disusun secara bertahap dan terintegrasi, di mana setiap proses saling berkaitan dan membentuk *pipeline* yang sistematis untuk mendukung klasifikasi sentimen berbasis graf.

A. Dataset dan Pemuatan Data

Dataset diperoleh dari berkas ”data_opini.xlsx” yang berisi *tweet* terkait isu penghapusan subsidi bahan bakar minyak (BBM). Dataset terdiri dari 557 *tweet* yang diklasifikasikan ke dalam dua kelas sentimen, yaitu positif dan negatif. Penelitian ini hanya menggunakan dua kolom utama, yaitu *”full text”* sebagai isi opini dan *”LABELING”* sebagai label sentimen, karena keduanya merupakan variabel yang relevan untuk proses klasifikasi.

Kelas netral tidak disertakan karena jumlahnya sangat terbatas dan berpotensi mengganggu stabilitas model. Seluruh baris dengan nilai kosong dihapus, kemudian indeks data diperbarui sebelum memasuki tahap praproses selanjutnya.

B. Polarisasi

Polarisasi adalah keadaan di mana pandangan dalam suatu kelompok masyarakat saling bertentangan, yang mengarah pada pemisahan yang jelas antara kelompok dengan sudut pandang yang berbeda. Dalam konteks politik, polarisasi terjadi ketika perbedaan pandangan antarkelompok semakin kuat dan cenderung menjadi ekstrem, sehingga membuat konsensus sulit dicapai dan berpotensi menyebabkan konflik serta ketidakstabilan sosial. Salah satu penyebab meningkatnya polarisasi adalah pengaruh media massa dan *platform* media sosial.

Media sosial melalui mekanisme pemilahan informasi sering kali menciptakan ruang informasi yang homogen, di mana pengguna lebih banyak terpapar pada pandangan yang sejalan dengan preferensi mereka [9]. Kondisi ini dapat memperkuat pembentukan *echo chamber* yang memperbesar perbedaan pandangan di antara masyarakat. Di sisi lain, penyajian informasi yang seimbang dan edukasi literasi digital dapat membantu mengurangi dampak polarisasi dengan meningkatkan kemampuan berpikir kritis masyarakat [10].

Received: Jan 15th, 2026 | Published: March 30th, 2026

p-ISSN: 2406-7768
e-ISSN: 2581-2181

Dalam penelitian ini, polarisasi opini direpresentasikan melalui kecenderungan sikap positif dan negatif terhadap isu penghapusan subsidi BBM di platform media sosial. Metode ini diterapkan sebagai cara untuk menerapkan konsep polarisasi opini dalam analisis sentimen.

C. Preprocessing Text

Preprocessing adalah tahapan untuk membersihkan data *tweet* yang telah dikumpulkan sebelumnya [11]. Hal ini dilakukan untuk mengurangi *noise* dan menyiapkan data agar siap dipetakan ke dalam struktur graf. Tahapan yang digunakan mengikuti *pipeline* sebagai berikut:

1. *Case Folding,* yaitu mengubah seluruh karakter pada kolom *"full_text"* menjadi huruf kecil
2. Pembersihan teks *(cleaning)*, dengan menghapus URL, *mention,* tanda pagar, simbol non-alfabet, dan spasi berlebih.
3. Normalisasi data, di mana kolom singkatan*_normalized* dan *slang_normalized* disamakan dengan hasil.
4. Penghapusan *stopword,* menggunakan daftar *stopword* Bahasa Indonesia dari NLTK untuk mengurangi kata tidak bermakna.
5. Tokenisasi kata, menghasilkan token tingkat kata yang digunakan dalam perhitungan PMI dan pembentukan graf, sementara tokenisasi *subword* IndoBERT hanya digunakan sebagai informasi pendukung.

D. Pembagian Data *Train,* Validasi, dan Test

Dataset dibagi menjadi tiga subset menggunakan fungsi *"train_test_split"* dengan stratifikasi berdasarkan label sentimen. Pembagian data dilakukan dengan proporsi 70% sebagai data *train*, 15% sebagai data validasi, dan 15% sebagai data test.

Proses pembagian dilakukan dalam dua tahap. Tahap pertama memisahkan data *train* dan data sementara dengan rasio 70% : 30%. Tahap kedua membagi data sementara menjadi data validasi dan data uji dengan rasio 15% : 15%. Stratifikasi diterapkan pada setiap tahap untuk menjaga proporsi kelas pada masing-masing subset.

E. Oversampling dengan SMOTE

Synthetic Minority Oversampling Technique (SMOTE) adalah metode yang banyak digunakan untuk mengatasi ketidakseimbangan antarkelas [12]. Teknik ini menghasilkan sampel sintetis dari kelas minoritas berdasarkan kedekatan fitur antardata.

Pada penelitian ini, *oversampling* hanya diterapkan pada subset pelatihan guna mencegah bias dalam evaluasi. Metode SMOTE diterapkan pada fitur TF-IDF dari data pelatihan untuk menghasilkan sampel sintetis pada kelas minoritas.

Karena SMOTE beroperasi dalam ruang fitur numerik, proses ini tidak mengubah teks asli secara langsung. Setelah *oversampling* selesai, indeks dari sampel sintetis digunakan untuk menghubungkan kembali dokumen teks asli dalam subset pelatihan. Dengan demikian, setiap sampel yang dihasilkan dari *oversampling* tetap dikaitkan dengan dokumen teks yang sesuai dalam *dataset,* sehingga konsistensi antara fitur yang direpresentasikan dan data teks tetap terjaga.

Metode ini memastikan bahwa keseimbangan kelas dicapai pada tahap representasi fitur tanpa memodifikasi isi teks secara langsung, sehingga potensi bias konseptual dalam hubungan antara fitur numerik dan data teks dapat diminimalkan.

F. Pembentukan Graph Corpus

Data pelatihan hasil *oversampling,* data validasi, dan data uji kemudian digabungkan dalam satu struktur data bernama *"graph_df"* dengan penambahan kolom penanda subset *(train, val, test).* Penggabungan ini bertujuan untuk membangun satu struktur graf terpadu yang mencakup seluruh data antara dokumen dan kata dalam korpus.

Meskipun seluruh dokumen digabungkan dalam satu graf, pelatihan model hanya dilakukan pada node dokumen yang terdapat dalam subset pelatihan dengan menggunakan *train mask.* Node validasi dan pengujian tidak terlibat dalam proses pembaruan parameter model. Metode ini mengikuti skema *semi-supervised node classification* pada GCN.

Selain itu, label dari dokumen pada subset validasi dan uji tidak digunakan selama proses pelatihan model. Dengan demikian, meskipun struktur graf dibangun berdasarkan seluruh kumpulan data, proses pembelajaran model tetap terfokus pada data pelatihan, sehingga potensi data *leakage* dapat dihindari.

G. Perhitungan Pointwise Mutual Information (PMI)

Pointwise Mutual Information (PMI) adalah metrik yang didasarkan korpus, yang berfungsi untuk menilai seberapa kuat hubungan antara sepasang kata dengan melihat frekuensi kemunculan mereka yang bersamaan dalam korpus.

Perhitungan PMI dilakukan pada kolom token dalam *graph_df* menggunakan jendela ko-okurensi sepanjang tiga token. Pemilihan ukuran jendela ini didasarkan pada karakteristik teks pendek seperti *tweet,* di mana hubungan semantik antarkata biasanya muncul dalam konteks yang relatif dekat. *Window* yang terlalu kecil dapat menyebabkan hubungan semantik tidak terdeteksi secara optimal, sedangkan *window* yang terlalu besar dapat menghasilkan asosiasi yang kurang relevan. Metode ini banyak diterapkan dalam konstruksi graf teks untuk menjaga relevansi hubungan semantik antarkata pada korpus teks pendek.

Secara matematis, PMI dirumuskan sebagai berikut:

$$\mathrm{PMI}(x,y) = \log_2 \left(\frac{P(x,y)}{P(x).P(y)}\right)$$

Nilai $P(x, y)$ merepresentasikan probabilitas kemunculan bersama kata x dan y, sedangkan $P(x)$ dan $P(y)$ menyatakan probabilitas kemunculan masing-masing kata secara individual.

H. Pembentukan Graf PMI dan TF-IDF

Received: Jan 15th, 2026 | Published: March 30th, 2026

p-ISSN: 2406-7768
e-ISSN: 2581-2181

Graf teks dibangun dengan dua jenis node, yaitu node dokumen dan node kata. Hubungan *word-word* dibentuk dari pasangan kata dengan nilai PMI positif, sedangkan hubungan *document-word* dibangun menggunakan bobot TF-IDF untuk merepresentasikan keterkaitan kata dalam bentuk dokumen.

Node dokumen merepresentasikan satu opini pengguna, sedangkan node kata merepresentasikan token penting dalam korpus. Keterkaitan antarkata yang memiliki bobot PMI menunjukkan konektivitas semantik berdasarkan frekuensi kemunculan bersama, sedangkan hubungan antara dokumen dan kata dengan bobot TF-IDF menggambarkan tingkat kepentingan kata tersebut dalam dokumen.

Dengan konstruksi graf ini, model GCN mampu mendistribusikan informasi melalui struktur graf untuk menangkap hubungan semantik secara menyeluruh yang tidak dapat diperoleh secara optimal menggunakan representasi teks berbasis vektor.

I. Model Graph Convolutional Networks (GCN)

Model yang digunakan terdiri dari dua lapisan *Graph Convolutional Networks* (GCN) dengan fungsi aktivasi ReLU dan mekanisme *dropout.* Arsitektur ini diterapkan pada dua skenario, yaitu GCN *baseline* tanpa PMI dan GCN dengan graf berbobot PMI, sehingga kinerja kedua pendekatan dapat dibandingkan secara langsung.

Secara matematis, GCN dirumuskan sebagai berikut:

$$H^{(l+1)} = \sigma\left(D^{\frac{1}{2}}\,\bar{A}D^{\frac{1}{2}}\,H^{(l)}\,W^{(l)}\right)$$

Persamaan tersebut menunjukkan bahwa representasi node diperbarui dengan menggabungkan informasi dari node itu sendiri dan node tetangga melalui matriks *adjacency* yang telah dinormalisasikan, normalisasi derajat digunakan untuk menjaga stabilitas pembelajaran, sedangkan fungsi aktivasi ReLU memungkinkan model menangkap hubungan non-linear pada struktur graf.

J. Fine-tuning, dan Early Stopping

Pelatihan model dilakukan menggunakan dua *optimizer*, yaitu Adam dan AdamW, dengan berbagai konfigurasi *fine-tuning.* Parameter yang disesuaikan meliputi *learning rate, dropout,* dan dimensi lapisan tersembunyi *(hidden dimension)* untuk mengevaluasi pengaruhnya terhadap kinerja model.

Selama proses pelatihan, model dievaluasi menggunakan data validasi untuk memantau perkembangan kinerja. Mekanisme *early stopping* diterapkan dengan cara menghentikan pelatihan apabila tidak terjadi peningkatan pada nilai *validation loss* dalam beberapa *epoch* berturut-turut untuk mencegah *overfitting.* Model terbaik dipilih berdasarkan hasil kinerja pada data validasi dan kemudian digunakan pada tahap evaluasi menggunakan data uji.

K. Evaluasi dan Visualisasi

Model terbaik kemudian dievaluasi pada data uji dengan menghitung *accuracy*, *precision, recall,* dan F1-*score,* serta ditampilkan dalam bentuk *classification report* untuk setiap kelas sentimen. *Confusion matrix* digunakan untuk menggambarkan pola kesalahan klasifikasi yang terjadi pada model. Selain itu, visualisasi pendukung seperti distribusi label pada setiap subset data serta statistik graf, termasuk derajat node dan distribusi bobot *edge*, disajikan untuk memberikan gambaran struktur graf yang dipelajari oleh model.

III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengujian dan analisis kinerja model GCN dalam klasifikasi sentimen opini publik terkait isu penghapusan subsidi BBM. Analisis difokuskan pada pengaruh penggunaan PMI, penerapan *oversampling* menggunakan SMOTE, dan pemilihan *optimizer* terhadap performa model. Hasil yang disajikan meliputi distribusi *dataset,* karakteristik graf yang dibentuk, hasil pengujian model baseline dan model dengan PMI, serta evaluasi menggunakan *confusion matrix* dan metrik klasifikasi.

A. Distribusi Dataset dan Hasil Oversampling

Hasil analisis menunjukkan bahwa pada subset pelatihan terdapat ketidakseimbangan kelas antara jumlah kelas positif dan negatif, di mana kelas negatif mendominasi jumlah sampel. Ketidakseimbangan ini berpotensi menyebabkan model cenderung bias terhadap kelas mayoritas selama proses pelatihan.

Untuk mengatasi masalah tersebut, digunakan teknik *oversampling* dengan metode SMOTE berbasis representasi TF-IDF pada subset pelatihan, sedangkan data validasi dan data uji tetap dipertahankan pada distribusi aslinya agar evaluasi model mencerminkan kondisi distribusi data yang sebenarnya.

Ringkasan distribusi label *dataset* disajikan pada Tabel I.

Tabel I. Distribusi Label Data

Subset	Positif	Negatif	Total
Train (sebelum SMOTE)	117	272	389
Train (sesudah SMOTE)	272	272	544
Validasi	25	59	84
Test	26	58	84

Berdasarkan Tabel I, dapat dilihat bahwa penerapan SMOTE berhasil menyeimbangkan distribusi kelas pada data pelatihan, tanpa mengubah distribusi data pada subset validasi dan pengujian. Metode ini memungkinkan model untuk mempelajari representasi kelas dengan lebih seimbang selama proses pelatihan, serta mempertahankan objektivitas evaluasi pada data uji.

B. Karakteristik Graf Hasil Konstruksi PMI TF-IDF

Graf teks yang dibentuk terdiri dari dua kategori node, yaitu node dokumen dan node kata. Hubungan antarnode ini direpresentasikan melalui dua jenis *edge*, yaitu hubungan

Received: Jan 15th, 2026 | Published: March 30th, 2026

p-ISSN: 2406-7768
e-ISSN: 2581-2181

dokumen-kata yang menggunakan bobot TF-IDF serta hubungan antarkata yang menggunakan bobot PMI positif.

Struktur graf yang dihasilkan menunjukkan tingkat konektivitas yang tinggi karena setiap dokumen terhubung dengan sejumlah kata, serta terdapat tambahan relasi antarkata yang muncul dalam konteks serupa. Analisis distribusi derajat node menunjukkan bahwa sejumlah node kata memiliki koneksi yang lebih besar dibandingkan dengan node lainnya, sehingga berfungsi sebagai penghubung penting dalam proses penyebaran informasi pada graf.

Penambahan relasi antarkata yang berbobot PMI juga meningkatkan kepadatan graf dibandingkan dengan graf *baseline* yang hanya menggunakan hubungan antara dokumen dan kata. Struktur graf yang lebih padat ini memungkinkan model GCN memanfaatkan hubungan semantik antarkata secara lebih luas, sehingga representasi dokumen yang diperoleh menjadi lebih informatif.

C. Hasil Eksperimen GCN Tanpa PMI (Baseline)

Eksperimen *baseline* dilakukan menggunakan model GCN tanpa penambahan bobot PMI. Pada skenario ini, graf hanya dibangun menggunakan hubungan dokumen-kata berbobot TF-IDF, sedangkan ketidakseimbangan kelas pada data pelatihan diatasi menggunakan SMOTE.

Berdasarkan hasil eksperimen, menunjukkan bahwa model GCN+SMOTE tanpa penggunaan *optimizer* khusus menghasilkan akurasi pengujian sebesar 45%. Selanjutnya dilakukan proses *fine-tuning* menggunakan *optimizer* AdamW dengan konfigurasi parameter yang sama, yaitu *hidden layer* sebesar 64, *dropout* sebesar 0.1, dan *learning rate* sebesar 1e-4). Konfigurasi ini berhasil meningkatan akurasi pengujian menjadi 59%.

Pada tahap berikutnya, *optimizer* Adam diuji menggunakan konfigurasi parameter yang identik. Hasil eksperimen menunjukkan bahwa penggunaan Adam menghasilkan akurasi pengujian tertinggi pada skenario *baseline*, yaitu sebesar 65%.

Ringkasan hasil eksperimen *baseline* disajikan pada Tabel II.

Tabel II. Hasil *Fine-tuning* Model GCN Tanpa PMI

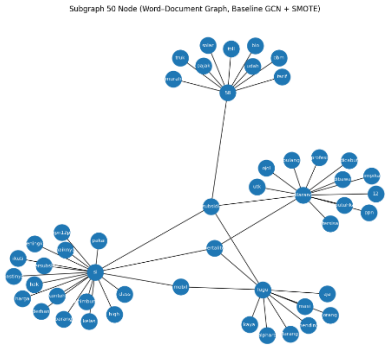
Optimizer	Hidden	Dropout	LR	Best Epoch	Accuracy Test
Tanpa Optimizer	64	0.1	1e-4	9	45%
AdamW	64	0.1	1e-4	36	59%
Adam	64	0.1	1e-4	1	65%

Berdasarkan Tabel II, dalam tahap eksplorasi parameter, beberapa kombinasi nilai *learning rate, dropout,* dan ukuran *hidden layer* diuji secara bertahap pada skenario *baseline*. Dari total 18 kali percobaan yang dilakukan, konfigurasi tersebut memberikan hasil yang paling stabil dan konsisten pada data validasi serta menghasilkan akurasi pengujian tertinggi. Oleh karena itu, konfigurasi ini ditetapkan sebagai parameter final untuk evaluasi kinerja model.

Penggunaan *Optimizer* mempengaruhi proses konvergensi model. *Optimazer* Adam mencapai akurasi pengujian tertinggi sebesar 65%, yang lebih tinggi dibandingkan AdamW yang menghasilkan 59%, dan model tanpa penggunaan optimazer yang hanya mencapai 45%. Hasil ini menunjukkan bahwa Adam dapat mempercepat proses konvergensi dan memberikan stabilitas yang lebih baik dalam pembelajaran pada model GCN *baseline.*

Seluruh model dilatih hingga maksimum 200 *epoch* dengan mekalisme *early stopping.* Perbedaan nilai *best epoch* menunjukkan variasi dalam kecepatan konvergensi antara berbagai *optimizer,* di mana Adam mencapai performa optimal dalam waktu yang lebih cepat dibandingkan dengan AdamW.

Visualisasi struktur graf pada skenario *baseline* GCN terbaik dengan SMOTE ditampilkan pada Gambar 2.



Gambar 2. Subgraf 50 Node Pertama pada *Baseline* GCN dan SMOTE

Berdasarkan Gambar 2, graf pada skenario *baseline* menunjukkan struktur jaringan yang terdiri dari node kata serta node dokumen yang saling terhubung melalui relasi berbobot TF-IDF. Dalam graf ini, node dokumen berfungsi sebagai titik pusat yang menghubungkan beberapa node kata, sehingga setiap dokumen digambarkan oleh kumpulan kata yang membentuknya.

Struktur graf menunjukkan bahwa sejumlah node kata memiliki jumlah koneksi *(degree)* yang lebih tinggi dibandingkan node lainnya. Node dengan *degree* tinggi ini berfungsi sebagai penghubung utama karena muncul dalam beberapa dokumen dengan konteks serupa. Pola ini menunjukkan bahwa distribusi konektivitas dalam graf tidak seimbang dan sebagian node memiliki peran yang lebih signifikan dalam propagansi informasi.

Namun, karena graf *baseline* hanya merepresentasikan hubungan antara dokumen dan kata tanpa mempertimbangkan hubungan antarkata, konektivitas graf tetap terbatas pada konteks lokal dalam dokumen. Kondisi ini menunjukkan bahwa hubungan semantik antarkata dalam korpus belum sepenuhnya digunakan oleh model GCN.

D. Hasil Eksperimen GCN dengan PMI

Pada percobaan utama, model GCN dilatih menggunakan graf berbobot PMI dengan data pelatihan yang telah

Received: Jan 15th, 2026 | Published: March 30th, 2026

p-ISSN: 2406-7768
e-ISSN: 2581-2181

diseimbangkan melalui metode SMOTE, sementara data validasi dan data uji tetap menggunakan distribusi asli. Pendekatan ini bertujuan untuk mengevaluasi pengaruh penambahan relasi semantik antarkata terhadap kinerja klasifikasi sentimen.

Hasil dari percobaan menunjukkan bahwa integrasi PMI memberikan peningkatan dalam kinerja jika dibandingkan dengan skenario *baseline* tanpa PMI. Model GCN + PMI + SMOTE tanpa *fine-tuning optimizer* menghasilkan akurasi pengujian sebesar 66%. Ketika dilakukan *fine-tuning* menggunakan *optimizer* AdamW dengan konfigurasi parameter yang sama (*hidden layer* 64, *dropout* 0.1, dan *learning rate* 1e-4) akurasi meningkat menjadi 67%.

Pada konfigurasi parameter yang sama diperoleh dari tahap eksplorasi parameter pada eksperimen *baseline,* penggunaan *optimizer* Adam menghasilkan performa terbaik pada skenario GCN dengan PMI, dengan akurasi pengujian mencapai 73%. Ringkasan hasil *fine-tuning* model GCN dengan PMI dan SMOTE disajikan pada Tabel III.

Tabel III. Hasil *Fine-tuning* Model GCN dengan PMI dan SMOTE

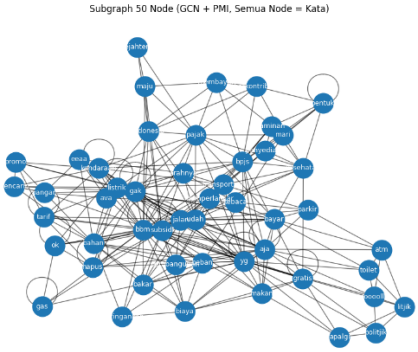
Optimizer	Hidden	Dropout	LR	Best Epoch	Accuracy Test
Tanpa Optimizer	64	0.1	1e-4	200	66%
AdamW	64	0.1	1e-4	1	67%
Adam	64	0.1	1e-4	197	73%

Berdasarkan Tabel III, penggunaan PMI pada konstruksi graf menunjukkan peningkatan akurasi jika dibandingkan dengan model *baseline.* Model GCN + PMI + SMOTE dengan *optimizer* Adam mencapai akurasi pengujian sebesar 73%, yang lebih tinggi dibandingkan model *baseline* yang memperoleh 65%. Peningkatan sebesar 8% ini menunjukkan bahwa penambahan relasi semantik antarkata melalui bobot PMI mampu memperkaya representasi graf sehingga model GCN dapat menggunakan informasi kontekstual antartoken dengan lebih efektif.

Perbedaan nilai *best epoch* menunjukkan variasi kecepatan dan karakteristik konvergensi antar *optimizer*, meskipun seluruh model dilatih hingga maksimum 200 *epoch* dengan mekanisme *early stopping.* Model dengan *optimizer* Adam mencapai performa terbaik pada *epoch* ke-197, sedangkan AdamW menunjukkan konvergensi yang sangat cepat namun menghasilkan akurasi yang lebih rendah. Hal ini menunjukkan bahwa kestabilan proses optimasi memiliki pengaruh terhadap kemampuan model dalam memahami struktur graf berbobot PMI.

Meskipun peningkatan akurasi terlihat konsisten pada skenario dengan PMI, interpretasi dari peningkatan tersebut juga perlu mempertimbangkan karakteristik struktur graf yang dihasilkan. Penambahan koneksi antarkata dengan menggunakan bobot PMI memperkuat konektivitas graf, sehingga model GCN dapat memanfaatkan hubungan semantik antartoken dengan lebih efektif dalam proses pembelajaran.

Visualisasi struktur graf pada scenario GCN dengan PMI dan SMOTE ditampilkan pada Gambar 3.



Gambar 3. Subgraf 50 Node Pertama pada GCN dengan PMI dan SMOTE

Berdasarkan Gambar 3, graf pada skenario GCN dengan PMI menunjukkan struktur jaringan yang lebih padat dibandingkan dengan graf *baseline*. Seluruh node dalam graf merepresentasikan sebuah kata, sedangkan hubungan antarnode dibentuk berdasarkan bobot PMI yang menunjukkan kekuatan asosiasi antara kemunculan bersama antarkata dalam korpus.

Struktur graf menunjukkan bahwa banyak node yang memiliki koneksi langsung dengan beberapa node lainnya, sehingga meningkatkan kepadatan koneksi graf *(graph connectivity)* dalam jaringan. Analisis distribusi derajat *(degree distribution)* menunjukkan bahwa sejumlah node kata memiliki lebih banyak koneksi dibandingkan simpul lainnya, yang menandakan bahwa kata-kata tersebut berfungsi sebagai penghubung penting di dalam jaringan semantik.

Peningkatan konektivitas ini memungkinkan informasi semantik untuk menyebar melalui lebih banyak rute dalam graf. Dengan cara ini, model GCN tidak hanya menggunakan hubungan kata dalam suatu dokumen, tetapi juga hubungan kontekstual antarkata di seluruh korpus. Kondisi ini memperkaya representasi graf dan berkontribusi pada peningkatan kinerja klasifikasi sentimen yang ditunjukkan oleh kenaikan akurasi model dari 65% pada *baseline* menjadi 73% pada model dengan PMI.

E. Analisis Perbandingan Model (GCN Tanpa PMI dan GCN + PMI)

Perbandingan pada bagian ini difokuskan pada nilai akurasi pengujian tertinggi yang diperoleh dari masing-masing pendekatan, yaitu model GCN tanpa PMI dan model GCN dengan PMI, setelah melalui proses oversampling menggunakan SMOTE dan pengujian beberapa *optimizer.*

Pada skenario GCN tanpa PMI, akurasi pengujian tertinggi sebesar 65% diperoleh oleh model GCN + SMOTE dengan *optimizer* Adam. Sementara itu, pada skenario GCN dengan PMI, akurasi pengujian tertinggi mencapai 73%, yang diperoleh dari kombinasi GCN + PMI + SMOTE dengan *optimizer* Adam. Ringkasan perbandingan akurasi terbaik dari kedua pendekatan disajikan pada Tabel IV.

Received: Jan 15th, 2026 | Published: March 30th, 2026

p-ISSN: 2406-7768
e-ISSN: 2581-2181

Tabel IV. Perbandingan Akurasi Terbaik GCN Tanpa PMI dan GCN dengan PMI

Model	Oversampling	Optimizer Terbaik	Akurasi Test
GCN (Baseline)	SMOTE	Adam	65%
GCN+PMI	SMOTE	Adam	73%

Berdasarkan Tabel IV, model GCN dengan PMI menghasilkan akurasi pengujian yang lebih tinggi dibandingkan model GCN *baseline.* Peningkatan akurasi sebesar 8% menunjukkan bahwa penambahan relasi antarkata menggunakan bobot PMI memperkaya struktur graf dengan hubungan semantik tambahan. Hal ini meningkatkan konektivitas antarkata dalam graf sehingga model GCN dapat memanfaatkan hubungan kontekstual antartoken secara lebih efektif dalam proses klasifikasi sentimen.

F. Analisis Confusion Matrix dan Metrik Evaluasi

Evaluasi kinerja model dilakukan menggunakan *confusion matrix* dan metrik evaluasi klasifikasi pada data uji. Analisis difokuskan pada model terbaik dan skenario *baseline* serta model terbaik GCN dengan PMI dan SMOTE, sehingga perbandingan yang disajikan merepresentasikan performa optimal dari masing-masing pendekatan. Ringkasan hasil evaluasi model terbaik ditampilkan pada Tabel V.

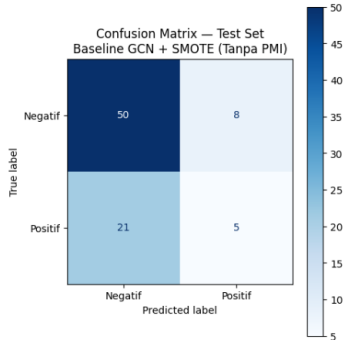
Tabel V. Hasil Evaluasi Model Terbaik pada Data Uji

Model	Optimizer	Accuracy	Precision	Recall	F1-Score
GCN+ SMOTE (Baseline)	Adam	0.65	0.60	0.65	0.61
GCN+PMI +SMOTE	Adam	0.73	0.72	0.73	0.71

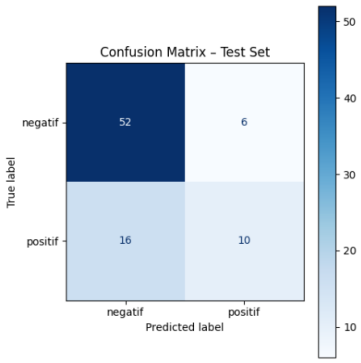
Berdasarkan Tabel V, model GCN dengan PMI dan SMOTE menghasilkan nilai akurasi dan F1-*Score* yang lebih tinggi dibandingkan model *baseline.* Akurasi meningkat dari 0.65 menjadi 0.73, sedangkan F1-*score* meningkat dari 0.61 menjadi 0.71, yang menunjukkan bahwa integrasi PMI mampu memperkaya representasi graf sehingga proses pembelajaran GCN menjadi lebih efektif dalam membedakan kelas sentimen pada data uji.

Selain itu, nilai *precision* dan *recall* pada model GCN dengan PMI menunjukkan peningkatan kemampuan model dalam mengenali kedua kelas sentimen secara lebih seimbang. Pada model *baseline,* performa klasifikasi masih dipengaruhi oleh dominasi kelas tertentu, sehingga banyak data dari kelas minoritas yang sering salah ketika diklasifikasikan. Dengan adanya hubungan antarkata melalui bobot PMI, struktur graf menjadi lebih terhubung, memungkinkan model GCN untuk memanfaatkan hubungan semantik antartoken secara lebih luas dalam proses klasifikasi.

Visualisasi *confusion matrix* untuk masing-masing model terbaik ditampilkan pada Gambar 4 dan Gambar 5. Gambar 4 menunjukkan hasil klasifikasi pada model *baseline* GCN + SMOTE dengan *optimizer* Adam, sedangkan Gambar 5 menampilkan hasil klasifikasi pada model GCN + PMI + SMOTE dengan *optimizer* Adam.



Gambar 4. *Confusion Matrix* Model GCN + SMOTE (*Baseline,* Adam)



Gambar 5. *Confusion Matrix* Model GCN + PMI + SMOTE (Adam)

Berdasarkan Gambar 4, model *baseline* mampu mengklasifikasikan 50 data negatif dengan benar, namun terdapat 8 kesalahan klasifikasi negatif sebagai positif. Pada kelas positif, model hanya mampu mengklasifikasikan 5 data dengan benar, sedangkan 21 data positif diprediksi sebagai negatif. Pola ini menunjukkan bahwa model *baseline* cenderung lebih responsif terhadap kelas negatif, sehingga kemampuan model dalam mengenali kelas positif masih terbatas.

Pada Gambar 5, penerapan PMI pada konstruksi graf menunjukkan perbaikan dalam pola klasifikasi. Model ini mampu mengklasifikasikan 52 data negatif dengan benar dan 10 data positif dengan benar. Selain itu, terdapat 6 data negatif yang salah diprediksi sebagai positif dan 16 data positif yang salah diprediksi sebagai negatif. Jumlah kesalahan dalam kategori positif juga menurun dari 21 pada model *baseline* menjadi 16 pada model dengan PMI, yang menunjukkan adanya peningkatan kemampuan model dalam mengenali kelas positif.

Perubahan dalam pola kesalahan ini menunjukkan bahwa penambahan hubungan antarkata dengan menggunakan bobot

Received: Jan 15th, 2026 | Published: March 30th, 2026

p-ISSN: 2406-7768
e-ISSN: 2581-2181

PMI meningkatkan konektivitas graf sehingga informasi semantik antartoken dapat dimanfaatkan dengan lebih efektif oleh model GCN. Meskipun demikian, jumlah kesalahan dalam kategori positif masih relatif tinggi, yang menunjukkan bahwa distribusi token dalam korpus masih lebih didominasi oleh pola kata yang merepresentasikan sentimen negatif.

G. Pengaruh PMI, SMOTE, dan Optimizer Terhadap Kinerja Model

Berdasarkan hasil eksperimen, penerapan PMI dalam struktur graf menunjukkan pengaruh paling signifikan terhadap perbaikan kinerja model. Hal ini ditunjukkan oleh peningkatan akurasi dari 65% pada model GCN *baseline* menjadi 73% pada model GCN + PMI + SMOTE. Penambahan bobot PMI memperkaya hubungan semantik antarkata, sehingga meningkatkan konektivitas graf dan memungkinkan model untuk menggunakan informasi kontekstual antartoken dengan lebih efektif.

Penerapan SMOTE juga membantu dalam menyeimbangkan distribusi kelas pada data pelatihan, sehingga proses pembelajaran menjadi lebih konsisten, yang terlihat dari penurunan kesalahan klasifikasi pada kelas positif. Sebaliknya, pengaruh pemilihan *optimizer* tergolong lebih rendah jika dibandingkan dengan penerapan PMI dan SMOTE. Secara keseluruhan, kombinasi GCN + PMI + SMOTE dengan *optimizer* Adam menunjukkan performa terbaik dalam klasifikasi sentimen opini publik.

IV. KESIMPULAN

Hasil penelitian menunjukkan bahwa model GCN *baseline* dengan SMOTE memperoleh akurasi pengujian sebesar 65%, sedangkan model GCN + PMI + SMOTE dengan *optimizer* Adam mencapai akurasi sebesar 73%. Peningkatan ini menunjukkan bahwa integrasi PMI dalam konstruksi graf dapat memperkaya hubungan semantik antarkata, sehingga representasi graf menjadi lebih informatif dan mendukung proses klasifikasi sentimen secara lebih efektif. Hasil ini juga didukung oleh hasil visualisasi graf dan *confusion matrix* pada Gambar 4 dan Gambar 5, yang menunjukkan bahwa model dengan PMI menghasilkan distribusi prediksi antarkelas yang lebih seimbang dibandingkan model tanpa PMI.

Secara teoretis, penelitian ini menunjukkan bahwa dengan menambahkan bobot semantik berbasis PMI pada graf teks dapat meningkatkan kualitas representasi hubungan antarkata dalam model GCN, sehingga informasi kontekstual dalam korpus dapat digunakan secara lebih optimal. Secara praktis, pendekatan GCN berbasis graf dengan integrasi PMI dapat diterapkan untuk mengevaluasi polarisasi opini masyarakat mengenai kebijakan pemerintah di *platform* media sosial, terutama dalam memahami kecenderungan sentimen masyarakat terhadap isu penghapusan subsidi BBM.

Penelitian ini memiliki beberapa keterbatasan, terutama pada jumlah *dataset* yang relatif terbatas serta distribusi kelas yang menunjukkan dominasi dari sentimen tertentu dalam korpus. Selain itu, konstruksi graf dalam penelitian ini hanya menggunakan hubungan PMI dan TF-IDF, sehingga eksplorasi metode pembobotan semantik atau variasi arsitektur GCN lainnya masih dapat dikembangkan pada penelitian selanjutnya untuk meningkatkan performa model.

V. SARAN

Penelitian selanjutnya disarankan menggunakan dataset dengan jumlah yang lebih besar dan cakupan isu yang lebih beragam agar model mampu menangkap hubungan semantik yang lebih kompleks serta meningkatkan kemampuan generalisasi model. Pengembangan metode konstruksi graf juga dapat dilakukan dengan mengeksplorasi variasi ukuran jendela ko-okurensi PMI atau mengkobinasikannya dengan teknik pembobotan semantik lainnya untuk memperkaya representasi hubungan antarkata dalam graf teks.

REFERENSI

[1] Zulham, A. Lubis, D. Priyono, Fauzan, S. Julina, and A. Deryansyah, "ANALISIS FRAMING MEDIA DALAM BERITA KONTROVERSIAL: STUDI KASUS PADA KASUS-KASUS POLITIK ATAU SOSIAL," Jurnal Review Pendidikan dan Pengajaran, vol. 7, no. 3, pp. 9118–9126, 2024, doi: 10.31004/jrpp.v7i3.30952.

[2] H. Sujadi, S. Fajar, and C. Roni, "ANALISIS SENTIMEN PENGGUNA MEDIA SOSIAL TWITTER TERHADAP WABAH COVID-19 DENGAN METODE NAIVE BAYES CLASSIFIER DAN SUPPORT VECTOR MACHINE," INFOTECH journal, vol. 8, no. 1, pp. 22–27, Jun. 2022, doi: 10.31949/infotech.v8i1.1883.

[3] Y. Romadhoni and K. Holle, "Analisis Sentimen Terhadap PERMENDIKBUD No.30 pada Media Sosial Twitter Menggunakan Metode Naive Bayes dan LSTM," Jurnal Informatika: Jurnal Pengembangan IT (JPIT), vol. 7, no. 2, pp. 118–124, Apr. 2022.

[4] R. Ardiansyah, N. Inayah, and M. Liebenlito, "Analisis Sentimen Publik Terhadap Penangkapan Ikan Ilegal oleh Kapal Vietnam di Twitter Menggunakan Metode GRAFT," The Indonesian Journal of Computer Science, vol. 14, no. 2, Apr. 2025, doi: 10.33022/ijcs.v14i2.4650.

[5] S. Muhsini, "ANALYSIS AND IMPLEMENTATION OF CROSS-LINGUAL SEMANTIC SIMILARITY WORDS USING POINTWISE MUTUAL INFORMATION METHOD," Jurnal Penelitian Pendidikan, vol. 18, no. 1, pp. 18–24, 2018, doi: 10.17509/jpp.v18i1.11056.

[6] K. Wang, Y. Ding, and S. C. Han, "Graph neural networks for text classification: a survey," Artif. Intell. Rev., vol. 57, no. 8, pp. 1–38, Jul. 2024, doi: 10.1007/s10462-024-10808-0.

Received: Jan 15th, 2026 | Published: March 30th, 2026

p-ISSN: 2406-7768
e-ISSN: 2581-2181

[7] M. Ameripour and V. Seydi, "Sentiment Analysis with Graph Convolutional Networks using directed PMI," Research Square preprint, Jun. 2024, doi: 10.21203/rs.3.rs-4564482/v1.

[8] A. Khosravi, Z. Rahmati, and A. Vefghi, "Relational Graph Convolutional Networks for Sentiment Analysis," arXiv preprint arXiv:2404.13079, Apr. 2024, doi: 10.48550/arXiv.2404.13079.

[9] R. Faturahman, N. Azahra, A. Triana Perdika, F. Mursidul Akmal, N. Rizqia Kamila, and P. Khoirotun, "Polarisasi Sebagai Bentuk Efek Negatif Dalam Pembentukan Opini Publik Pada Pemilihan Presiden 2019," INTERAKSI PERADABAN: Jurnal Komunikasi dan Penyiaran Islam, vol. 4, no. 1, pp. 99–115, 2024, doi: 10.15408/interaksi.v4i1.38849.

[10] S. Hidayat Daeli et al., "POLARISASI POLITIK DI MEDIA SOSIAL : TELAAH FILSAFAT PERSATUAN INDONESIA DI ERA DIGITAL," Triwikrama: Jurnal Ilmu Sosial, vol. 5, no. 10, pp. 1–5, 2023.

[11] D. Arisandi, T. Sutrisno, and I. Kurniawan, "KLASIFIKASI OPINI MASYARAKAT DI TWITTER TENTANG KEBOCORAN DATA YANG TERJADI DI INDONESIA MENGGUNAKAN ALGORITMA SVM," Jurnal Informatika Kaputama (JIK), vol. 7, no. 1, pp. 84–90, Jan. 2023, doi: 10.59697/jik.v7i1.10.

[12] S. Maula Chamzah, M. Lestandy, N. Kasan, and A. Nugraha, "Penerapan Synthetic Minority Oversampling Technique (SMOTE) untuk Imbalance Class pada Data Text Menggunakan KNN," Syntax: Jurnal Informatika, vol. 11, no. 02, pp. 56–67, 2022.

Received: Jan 15th, 2026 | Published: March 30th, 2026