

## ANALISIS SENTIMEN DAN SOCIAL NETWORK ANALYSIS PADA ISU MAKANAN BERGIZI GRATIS DI X/TWITTER MENGGUNAKAN INDOBERT

Justin Darya Yuswira, Jusia Amanda Ginting

Informatika, Universitas Bunda Mulia Jakarta

Jalan Lodan Raya No. 2, Jakarta, Indonesia

jginting@bundamulia.ac.id

### ABSTRAK

Program Makanan Bergizi Gratis (MBG) jadi salah satu kebijakan yang paling ramai dibahas di media sosial, tapi volume cuitan yang besar bikin pemantauan manual jadi tidak realistis. Masalahnya, opini publik tentang MBG sering bercampur antara dukungan, kritik, dan informasi yang simpang siur, sehingga dibutuhkan cara yang lebih cepat untuk merangkum sentimen dan melihat siapa saja akun yang paling berpengaruh dalam percakapan. Penelitian ini bertujuan menganalisis persepsi publik tentang MBG dengan menggabungkan klasifikasi sentimen berbasis IndoBERT dan *Social Network Analysis* (SNA) pada jaringan *mention*. Data diambil dari percakapan publik berbahasa Indonesia di X/Twitter menggunakan kata kunci terkait MBG, lalu diproses melalui pembersihan teks, normalisasi, dan de-duplikasi. IndoBERT di-*fine-tune* untuk memprediksi sentimen negatif, netral, dan positif, sedangkan SNA membangun graf terarah berbobot dari relasi *@mention* dan menghitung metrik *sentralitas* (*in-degree*, *out-degree*, *betweenness*, *closeness*) yang kemudian digabungkan menjadi skor *overall*. Hasilnya, model sentimen memperoleh *weighted F1-score* 0,7413 pada data uji (N=142) dan distribusi sentimen setelah de-duplikasi menunjukkan kelas positif 41,9%, netral 30,1%, dan negatif 28,0%. Dari sisi jejaring, akun-akun seperti prabowo, dssupriyady, dan beberapa akun institusi/partai muncul sebagai aktor dengan skor pengaruh tertinggi. Temuan ini membantu melihat arah opini sekaligus pola interaksi, sehingga analisis isu MBG bisa lebih utuh.

**Kata kunci :** Analisis sentimen; Social Network Analysis; IndoBERT; X/Twitter; Makanan Bergizi Gratis

### 1. PENDAHULUAN

Perkembangan teknologi digital bikin ruang diskusi publik makin pindah ke platform yang serba *real-time*, dan jejak percakapannya cepat sekali bertambah. Buat isu kebijakan, kondisi ini sebenarnya menarik karena kita bisa melihat reaksi masyarakat tanpa harus menunggu survei berkala [1]. Masalahnya, volume data yang besar bikin pemantauan manual jadi tidak realistis, apalagi kalau topiknya sensitif dan ramai [2]. Kalau dibaca satu persatu, hasilnya mudah tidak konsisten dan bisa bias karena tergantung sampel yang kebetulan terlihat. Karena itu, analisis otomatis dibutuhkan supaya pola opini bisa ditangkap dengan lebih rapi dan terukur [3]. Dalam konteks kebijakan sosial, masukan publik yang terbaca lebih cepat bisa membantu evaluasi program dan perbaikan pelaksanaannya. Tetap saja, kualitas hasil analisis sangat dipengaruhi oleh cara mengelola data dan proses pembersihannya agar tidak menambah bias baru [4].

Salah satu program yang sedang jadi sorotan adalah Makanan Bergizi Gratis (MBG) untuk anak sekolah. Program ini digulirkan untuk mendorong perbaikan gizi sekaligus mendukung proses belajar, sehingga wajar kalau respons publiknya beragam. Sejumlah studi juga menekankan bahwa intervensi makanan bergizi bisa ikut menurunkan risiko masalah gizi seperti *stunting* [5]. Namun keberhasilan program tidak cukup dinilai dari jumlah porsi, karena yang lebih penting adalah dampak di lapangan seperti kebiasaan makan, partisipasi belajar, dan pengalaman penerima manfaat. Di titik ini, suara masyarakat jadi

umpan balik yang penting, apalagi saat program berjalan dan muncul penyesuaian. Percakapan publik di media sosial bisa dipakai sebagai pelengkap survei untuk memantau dukungan, keluhan, dan kekhawatiran terhadap MBG. Supaya tidak sekadar asumsi, percakapan itu perlu dibaca dengan cara yang sistematis. Karena itulah analisis berbasis data teks mulai banyak dipakai untuk membantu evaluasi kebijakan [6].

Tantangan MBG juga besar karena skalanya nasional, sementara kondisi tiap daerah tidak sama. Di lapangan bisa muncul isu kualitas bahan pangan, standar higienis, kapasitas dapur, sampai distribusi yang berbeda-beda antar wilayah [7]. Di media sosial, isu-isu seperti ini menyebar cepat dan sering bercampur dengan informasi yang belum jelas kebenarannya. Kalau tidak dipilah, disinformasi dan ujaran bernada ekstrem bisa mengaburkan evaluasi dan membuat kesimpulan jadi menyesatkan. Selain itu, tidak semua percakapan punya bobot yang sama karena ada akun tertentu yang lebih sering jadi rujukan atau pemantik diskusi. Jadi, pemantauan opini MBG idealnya tidak hanya menghitung banyaknya sentimen, tetapi juga memahami siapa aktor yang berperan besar dalam percakapan. Analisis berbasis data teks dan jejaring bisa dipakai bareng untuk menangkap dua sisi itu. Dengan begitu, evaluasi bisa lebih cepat merespons isu yang berkembang [8].

Analisis sentimen membantu merangkum opini teks ke dalam kategori seperti negatif, netral, dan positif, sehingga percakapan yang besar bisa dibaca dalam bentuk ringkasan yang lebih mudah. Untuk data

bahasa Indonesia yang banyak slang dan konteks, model berbasis *Transformer* seperti IndoBERT cukup cocok karena bisa menangkap makna dari konteks kalimat, bukan hanya hitung kata [9]. Di sisi lain, *Social Network Analysis* (SNA) melihat struktur interaksi antar akun sehingga bisa diketahui aktor yang paling sering disebut, paling aktif menyebut, atau menjadi penghubung antar kelompok. Jika dua pendekatan ini digabung, kita bisa melihat ‘apa’ yang dirasakan publik sekaligus ‘siapa’ yang membentuk arus percakapan. Gabungan ini juga membantu menghindari pembacaan yang hanya berhenti di angka persentase sentimen. Makanya, penelitian ini fokus pada analisis sentimen dan SNA untuk isu MBG, bukan pada desain aplikasi atau antarmukanya [8].

Penelitian ini bertujuan memetakan persepsi publik terkait MBG di X/Twitter melalui dua sisi: arah sentimen dan pola jejaring interaksi. Data dikumpulkan dari 1 September hingga 21 Oktober 2025 dengan kata kunci terkait MBG, menghasilkan 11.853 cuitan yang kemudian di pra-proses (pembersihan teks, normalisasi, dan de-duplikasi). Model IndoBERT di-*fine-tune* untuk klasifikasi sentimen tiga kelas dan dievaluasi menggunakan metrik akurasi, *precision*, *recall*, serta *F1-score* [10]. Selanjutnya, SNA dibangun dari relasi *mention* (@) dalam cuitan untuk membentuk graf terarah berbobot, lalu dihitung metrik *in-degree*, *out-degree*, *betweenness*, dan *closeness* untuk melihat aktor yang menonjol. *Output* analisis diharapkan bisa memberi gambaran cepat: sentimen dominan, isu yang ramai, dan akun yang berpengaruh dalam diskusi. Pada akhirnya, hasil ini bisa jadi bahan tambahan untuk membaca kondisi lapangan dan mendukung evaluasi kebijakan yang lebih responsif [11].

Penelitian-penelitian sebelumnya menunjukkan bahwa analisis sentimen cukup efektif untuk merangkum opini publik, tetapi hasilnya sering terasa “dangkal” kalau hanya berhenti di persentase positif/negatif. Di percakapan MBG, misalnya, satu isu bisa dipicu oleh akun tertentu, lalu menyebar lewat *mention* dan balasan sehingga membentuk kluster diskusi. Di sinilah SNA berguna: bukan hanya melihat apa yang dibicarakan, tetapi juga melihat siapa yang mendorong percakapan dan bagaimana informasinya menyebar. Karena itu, riset ini fokus pada dua hal: membaca arah sentimen, dan memetakan struktur interaksi melalui *mention*.

## 2. TINJAUAN PUSTAKA

### 2.1. Makan Bergizi Gratis (MBG)

Makan Bergizi Gratis (MBG) adalah kebijakan program untuk menyediakan makanan yang bergizi kepada siswa dan kelompok sasaran lain seperti: balita, ibu hamil, dan ibu menyusui untuk memperbaiki gizi dan mendukung perkembangan dan kesiapan anak untuk belajar. Tujuan dari MBG adalah untuk memastikan anak dapat mendapatkan asupan yang

berkualitas dan bergizi agar kesehatan anak secara bertahap meningkat seperti menambah fokus belajar dan mencukupi nutrisi yang dibutuhkan secara bertahap. Serta menunjukkan penggabungan makanan yang sehat dengan edukasi nutrisi dapat memperbaiki perilaku makanan, mengurangi ketimpangan akses pada rumah tangga rentan [12].

### 2.2. Analisis Sentimen

Analisis sentimen adalah cara untuk mengklasifikasikan teks yang berdasarkan opini penulis pada suatu objek, misalnya dari positif, negatif, atau netral [13]. Tujuan dari analisis sentimen adalah untuk mengubah teks menjadi label yang dapat diringkas dan dapat dibandingkan atau di pantau dari waktu ke waktu [14]. Untuk membaca opini publik dan menilai penerimaan layanan. Terdapat tiga pendekatan yang sering di pakai untuk analisis sentimen adalah [15]:

- Pendekatan dengan *lexicon* memakai kamus kata yang mempunyai skor polaritas atau daftar kata dengan label tertentu. Cara kerja dari *lexicon* adalah dimana teks akan dipecah menjadi *token* lalu tiap *token* akan dicocokkan ke kamus lalu skor atau label akan digabungkan
- Machine learning* adalah pendekatan yang menggunakan *machine learning* untuk analisis sentimen sebagai tugas klasifikasi dengan data berlabel, lalu melatih model untuk memetakan teks ke kelas sentimen. Model yang biasanya digunakan adalah dengan *logistic regresion*, SVM
- Deep learning* adalah menggunakan model *pre-train* yang berbasis *transformer* seperti IndoBERT yang sudah belajar pola bahasa Indonesia dengan skala besar. Alur kerja dari IndoBERT adalah tokenisasi, representasi kontekstual, klasifikasi, prediksi label sentimen.

### 2.3. IndoBERT


IndoBERT adalah model yang pra-latih yang berbasis dengan BERT yang dikembangkan khusus untuk bahasa Indonesia, sehingga lebih baik dalam memahami tata bahasa, konteks, dan kosakata (Prabowo & Indra Sanjaya, 2024). Dengan adanya IndoBERT belajar dari teks Indonesia dengan jumlah yang besar sehingga dapat menangkap makna antar kalimat dan penggunaan kata yang sesuai dengan konteks [16].

Untuk penggunaan IndoBERT diadaptasi melalui *fine-tuning* teks diubah menjadi potongan sub-kata, lalu diproses oleh IndoBERT, lalu ditambahkan klasifikasi untuk label. Cara kerjanya dengan latih, validasi, dan pengujian, pengaturan *learning rate* kecil, *early stopping*, dan pelaporan metrik yang peka ketidakseimbangan seperti macro-F1 selain akurasi [17].

## 2.4. Sosial Network Analisis


*Social Network Analysis* (SNA) adalah pendekatan untuk menganalisis hubungan antar entitas sebagai sebuah jaringan, simpul adalah di mana untuk mewakili aktornya dan sisi untuk mewakili hubungan di antara mereka. Penggunaan SNA digunakan untuk memahami pola yang menghubungkan dari *node* ke *node*. SNA di representasikan sebagai graf, kita dapat merangkum posisi aktor dengan karakter jaringan secara keseluruhan. Hasil SNA biasanya dipakai untuk mengidentifikasi aktor kunci, memetakan komunitas, dan menjelaskan interaksi yang tak terlihat jika dianalisis per individu. Dalam SNA terdapat tiga komponen yaitu [18]:

- a. *Degree Centrality* untuk mengukur seberapa banyak koneksi yang dimiliki oleh sebuah *node*, jika semakin banyak maka nilai *degree* akan semakin tinggi. Terdapat dua jenis *degree centrality* yaitu *in-degree* banyak koneksi yang masuk seperti seberapa banyak yang dimention dan *out-degree* banyaknya koneksi yang keluar seperti seberapa sering untuk menyebut orang lain.




Gambar 1. Degree centrality

- b. *Betweenes Centrality* menilai seberapa sering sebuah *node* berada di jalur terpendek antar *node* dengan *node* lain, berperan sebagai penghubung informasi. aktor dengan *betweenes* tinggi lebih dapat mengendalikan aliran informasi antar kelompok. Dalam SNA ini dapat membantu untuk menemukan akun yang menyambungkan informasi



Gambar 2. Betweenes centrality

- c. *Closeness Centrality* mengukur seberapa dekat sebuah *node* terhadap *node* lain secara rata-rata ke seluruh jaringan *node*. Aktor yang punya *closeness* tinggi dapat menjangkau aktor lain, sehingga lebih mudah untuk menyebarkan atau menerima informasi.



Gambar 3. Closeness centrality

## 2.5. Penelitian Terdahulu

Penelitian terdahulu menjadi dasar penting dalam melihat posisi dan kontribusi penelitian ini terhadap pengembangan kajian terkait analisis sentimen dan pemanfaatan teknologi digital dalam pengolahan data berbasis media social. Adapun Penelitian terdahulu yang digunakan dalam artikel ini adalah:

Nursiyono dan Chotimah melakukan kajian terhadap opini masyarakat di Twitter mengenai isu kebijakan PPN sembako dan pendidikan. Penelitian ini memanfaatkan algoritma Naïve Bayes untuk klasifikasi sentimen dengan lima kategori emosi yaitu *fear*, *sadness*, *surprise*, *joy*, dan *anger*, serta menerapkan Social Network Analysis untuk memetakan aktor dan percakapan yang berpengaruh dalam diskursus publik. Hasil penelitian menemukan bahwa sentimen yang paling dominan adalah *anger*, yang menunjukkan respons masyarakat cenderung mengarah pada kemarahan terhadap isu tersebut. Persamaan dengan penelitian saat ini terletak pada pemanfaatan data media sosial serta penggabungan metode analisis sentimen dan pemetaan jejaring sosial. Namun perbedaannya adalah pendekatan klasifikasi yang digunakan dan fokus isu penelitian, di mana penelitian terdahulu lebih menitikberatkan pada analisis emosi berbasis kebijakan fiskal, sedangkan penelitian ini berfokus pada konteks yang berbeda [19].

Hung melakukan analisis terhadap persepsi publik mengenai pandemi COVID-19 menggunakan data Twitter. Penelitian ini menggunakan *Latent Dirichlet Allocation (LDA)* untuk melakukan pemodelan topik dan memetakan lima tema dominan yaitu *health care environment*, *emotional support*, *business economy*, *social change*, dan *psychological stress*. Selain itu, analisis sentimen dilakukan menggunakan VADER yang menghasilkan distribusi sentimen sebesar 48% positif, 20% netral, dan 31% negatif. Persamaan dengan penelitian ini terletak pada pemanfaatan media sosial sebagai sumber data serta penggunaan SNA dan analisis sentimen untuk memahami respons masyarakat. Perbedaannya terdapat pada penggunaan LDA sebagai *unsupervised topic modeling* dan fokus penelitian yang berkaitan dengan pandemi global [20].

### 3. METODE PENELITIAN

Penelitian ini menggunakan data percakapan publik di X/Twitter yang memuat kata kunci terkait “Makan Bergizi Gratis”. Rentang pengambilan data adalah 1 September–21 Oktober 2025 dengan total 11.853 cuitan. Data kemudian disiapkan agar layak dianalisis melalui beberapa tahap pra-proses, lalu dipakai untuk analisis sentimen dan SNA.

Tahap pra-proses meliputi pembersihan teks (URL, tanda baca, emoji, dan karakter tidak penting), *casefolding*, normalisasi kata tidak baku/slang menggunakan kamus, serta de-duplikasi untuk mengurangi cuitan yang sama atau sangat mirip. Tujuannya supaya model lebih fokus ke isi pesan dan tidak terdistraksi oleh noise.

Pengolahan dan pemodelan dilakukan dengan *Python*. Untuk analisis sentimen digunakan pustaka *HuggingFace Transformers* agar proses *fine-tuning* lebih terstruktur (*Trainer*, *TrainingArguments*). Untuk SNA digunakan *NetworkX*, sedangkan ekstraksi *mention* menggunakan regex. Hasil evaluasi dihitung dari *confusion matrix* dan *classification report*, lalu divisualkan agar mudah dibaca.

Tabel 1. Ringkasan parameter fine-tuning IndoBERT

| Paramater               | Nilai                                   |
|-------------------------|-----------------------------------------|
| Model                   | IndoBERT ( <i>fine-tuned</i> , 3 kelas) |
| <i>Learning Rate</i>    | 2e-5                                    |
| Barch Size (train/eval) | 8 / 8                                   |
| <i>Epoch</i> (Utama)    | 3 (Dipilih dari evaluasi loss)          |
| <i>Weight Decay</i>     | 0,02                                    |
| <i>Seed</i>             | 43                                      |

Untuk analisis sentimen, data diberi label tiga kelas (negatif, netral, positif) sesuai pedoman pelabelan. *Dataset* kemudian dibagi dengan skema 70/15/15 untuk data latih, validasi, dan uji. IndoBERT di-fine-tune menggunakan *library Transformers*, dengan evaluasi per *epoch* agar pemilihan model mengacu pada metrik validasi.

Evaluasi analisis sentimen dilakukan memakai akurasi, *precision*, *recall*, dan *F1-score*. Selain itu, *confusion matrix* digunakan untuk melihat pola kesalahan antar kelas, khususnya pada kelas netral yang sering berada di ‘abu-abu’ antara positif dan negatif.

Untuk *Social Network Analysis*, relasi *mention* (@) diekstraksi dari teks cuitan menggunakan regex. Dari relasi tersebut dibentuk graf terarah berbobot: *edge* dari akun pengirim ke akun yang disebut, dan bobot menunjukkan frekuensi *mention*. Metrik *in-degree*, *out-degree*, *betweenness*, dan *closeness* dihitung untuk menyortir akun yang paling sering disebut, paling aktif menyebut, serta aktor penghubung dalam percakapan.

Agar perbandingan antar metrik lebih adil, skor metrik dinormalisasi (min-max) dan digabung menjadi skor keseluruhan (*overall score*). Skor ini dipakai untuk menyusun daftar aktor teratas yang paling menonjol di jejaring percakapan MBG.

### 4. HASIL DAN PEMBAHASAN

#### 4.1. Analisis Sentimen

Data percakapan MBG yang terkumpul dari X/Twitter berjumlah 11.853 cuitan pada rentang 1 September–21 Oktober 2025. Setelah pembersihan teks (hapus URL, emoji, tanda baca, dan karakter tidak penting), normalisasi (termasuk slang), serta de-duplikasi untuk mengurangi cuitan yang berulang, data bersih menjadi 9.814 cuitan. De-duplikasi penting supaya satu kalimat yang sama tidak “menggelembungkan” hasil sentimen dan metrik jejaring.

Tabel 2. Ringkasan jumlah data


| Tahap                      | Jumlah (Cuitan) |
|----------------------------|-----------------|
| Data Awal (crawl)          | 11.853          |
| Stelah Pra Proses + de-dup | 9.814           |

Dalam Analisis sentiment ini, dilakukan pulan *labelling* secara manual yang dapat dilihat pada Tabel 3. Manual Labeling.

Tabel 3. Manual labeling

| Ulasan                                                                                                                                                                                                                                                                             | Label |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------|
| Harusnya keracunan itu dituntut bukan malah minta dirahasiakan Beredar foto surat perjanjian agar penerima manfaat Makan Bergizi Gratis (MBG) merahasiakan informasi jika terjadi kejadian luar biasa seperti dugaan keracunan. Surat yang beredar tersebut bertanggal 10 Septembe | 0     |
| Ya ampun pak @prabowo program MBG nya dihentikan sementara aja dulu sudah banyak berjatuhan korban                                                                                                                                                                                 | 0     |
| Gubernur Sulsel Tinjau Kesiapan Program Makan Bergizi Gratis Bersama KPPG                                                                                                                                                                                                          | 1     |
| Selain Indonesia Negara-Negara Ini Juga Terapkan Program Makan Bergizi Gratis di Sekolah                                                                                                                                                                                           | 1     |
| Program makan bergizi gratis bertujuan agar siswa di Indonesia bisa lepas dari stunting serta mampu menyiapkan Indonesia menuju keemasan                                                                                                                                           | 2     |
| Solo tunjukkan kalau makan bergizi gratis bisa tetap aman. Zero accident jadi bukti keseriusan mereka.                                                                                                                                                                             | 2     |

Model IndoBERT kemudian di-fine-tune dengan data yang telah diberikan *manual labelling* untuk klasifikasi sentimen tiga kelas (negatif, netral, positif). Eksperimen awal dilakukan sampai 8 epoch untuk melihat pola overfitting dari perbandingan *training loss* dan *validation loss*. Dari kurva *loss*, nilai *validation loss* paling rendah ada di epoch ke-3 (0,6537), sehingga pelatihan utama dipilih menggunakan 3 epoch agar model tidak terlalu “menghafal” data latih.




Gambar 4. Kurva training loss dan validation loss per epoch

Evaluasi model dilakukan menggunakan *confusion matrix* dan metrik umum, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Secara singkat, *accuracy* dihitung dari jumlah prediksi benar dibagi seluruh data uji. *Precision* mengukur ketepatan prediksi sebuah kelas ( $TP/(TP+FP)$ ), *recall* mengukur kemampuan menangkap semua data pada kelas tersebut ( $TP/(TP+FN)$ ), sedangkan *F1-score* adalah rata-rata harmonik *precision* dan *recall* ( $2PR/(P+R)$ ). Contoh perhitungan dari data uji ( $N=142$ ):  $accuracy = (44+23+39)/142 = 0,7465$ .

Tabel 4. Classification report pada data uji


| Kelas        | Precision | Recall | F1-Score | Support |
|--------------|-----------|--------|----------|---------|
| Negatif      | 0,8148    | 0,8000 | 0,8073   | 55      |
| Netral       | 0,7188    | 0,5476 | 0,6216   | 42      |
| Positif      | 0,6964    | 0,8667 | 0,7723   | 45      |
| Macro avg    | 0,7433    | 0,7381 | 0,7337   | 142     |
| Weighted avg | 0,7483    | 0,7465 | 0,7413   | 142     |



Gambar 5. Confusion matrix IndoBERT (data uji, N=142)

Berdasarkan *confusion matrix*, kesalahan paling sering terjadi pada kelas netral yang bergeser menjadi positif (13 data). Ini cukup masuk akal karena kalimat netral di X/Twitter sering punya konteks implisit—misalnya bercanda, sindiran halus, atau sekadar mengutip berita—yang mudah terbaca “positif” oleh model. Di sisi lain, performa kelas negatif cukup stabil

( $F1\ 0,8073$ ), sedangkan kelas positif punya recall tinggi ( $0,8667$ ) yang artinya sebagian besar opini positif berhasil tertangkap. Ke depan, kelas netral bisa dibantu dengan pedoman label yang lebih ketat dan menambah contoh data netral yang benar-benar “abu-abu”.



Gambar 6. Distribusi sentimen percakapan MBG (setelah de-duplikasi,  $N=9.814$ )

Distribusi sentimen menunjukkan bahwa percakapan MBG didominasi sentimen positif (41,9%). Namun, porsi netral (30,1%) dan negatif (28,0%) juga cukup besar, yang bisa dibaca sebagai adanya kekhawatiran, kritik, atau diskusi informatif yang belum condong mendukung/menolak. Dengan kata lain, isu MBG tidak hanya ramai, tetapi juga “berlapis”: ada dukungan, ada pertanyaan, dan ada keraguan yang muncul bersamaan.

Secara ringkas, akurasi pada data uji adalah 0,7465 dengan *weighted F1-score* 0,7413. Kelas negatif punya *precision* 0,8148 dan *recall* 0,8000, artinya ketika model memprediksi negatif, sebagian besar tepat, dan sebagian besar data negatif juga tertangkap. Kelas positif memiliki *recall* tinggi (0,8667), sedangkan kelas netral menjadi yang paling menantang (*recall* 0,5476) karena batasnya sering tipis. Polanya terlihat dari cukup banyak data netral yang diprediksi menjadi positif, sehingga perbaikan pada kelas netral menjadi fokus saran penelitian.

Pada distribusi sentimen, dominasi positif tidak otomatis berarti semua penerima program puas, karena banyak cuitan yang berupa dukungan umum atau opini terhadap tokoh. Cuitan netral sering berisi informasi, tanya-jawab, atau kutipan berita, sementara cuitan negatif biasanya terkait kekhawatiran soal pelaksanaan, kualitas, dan transparansi. Karena itu, hasil sentimen sebaiknya dibaca bersama konteks jejaring: akun mana yang memicu percakapan, dan topik apa yang menyebar di tiap kelompok.

#### 4.2. Social Network Analysis

Untuk SNA, relasi *mention* (@) diekstraksi dari teks cuitan menggunakan regex. Setiap akun diperlakukan sebagai *node*, sedangkan *mention* dari akun A ke akun B menjadi edge terarah  $A \rightarrow B$ . Edge diberi bobot (*weight*) berdasarkan frekuensi mention, jadi semakin sering A menyebut B, bobotnya makin besar. Model graf seperti ini membantu melihat


percakapan MBG sebagai jaringan interaksi, bukan hanya kumpulan teks.

Empat metrik utama yang dihitung adalah *in-degree* berbobot, *out-degree* berbobot, *betweenness centrality*, dan *closeness centrality*. *In-degree* berbobot pada akun *i* dapat dipahami sebagai jumlah bobot semua *edge* yang masuk ke *i* ( $\sum w_{\{j \rightarrow i\}}$ ), sementara *out-degree* berbobot adalah jumlah bobot *edge* yang keluar dari *i* ( $\sum w_{\{i \rightarrow k\}}$ ). *Betweenness* mengukur seberapa sering sebuah akun berada di jalur terpendek antar akun lain, sehingga cocok untuk mendeteksi akun “jembatan”. *Closeness* mengukur kedekatan rata-rata sebuah akun ke akun lain; pada graf berbobot, jarak dihitung sebagai  $1/\text{weight}$  supaya *mention* yang sering dianggap lebih dekat.

Supaya hasil antar metrik bisa dibandingkan, setiap skor metrik dinormalisasi dengan min-max:  $\text{norm}(x) = (x - \min) / (\max - \min)$ . Setelah itu, skor gabungan (*overall*) dihitung dengan menjumlahkan empat nilai normalisasi:  $\text{overall} = n_{\text{in}} + n_{\text{out}} + n_{\text{bet}} + n_{\text{clo}}$ . Dengan cara ini, akun yang tinggi di lebih dari satu metrik akan cenderung naik ke peringkat atas, bukan hanya menang di satu metrik saja. Hasil dari SNA dapat dilihat pada Tabel 5. Top-10 aktor berdasarkan *overall score*

Tabel 5. Top-10 aktor berdasarkan overall score

| Peringkat | Aktor          | Overall |
|-----------|----------------|---------|
| 1         | prabowo        | 3.0000  |
| 2         | dssupriyady    | 1.4933  |
| 3         | victoragiular  | 0.3217  |
| 4         | dpr_ri         | 0.2732  |
| 5         | divhumas_polri | 0.2074  |
| 6         | sigromilir01   | 0.1992  |
| 7         | anak_ogi       | 0.1807  |
| 8         | gerindra       | 0.1802  |
| 9         | kemensetnegri  | 0.1661  |
| 10        | marbot_udien   | 0.1640  |



Gambar 7. Visualisasi top-10 aktor (*overall score*)

Setelah menerapkan filter pengecualian akun (kompastv, kalimayafashion, txtdrimedia, tempodotco, kompascom, cnnindonesia, grok, detikcom, detikjabar\_detik\_edu, arsipaja), peringkat aktor pada SNA menjadi lebih merepresentasikan pusat percakapan organik (bukan didominasi akun

media/aggregator/otomatis). Dari peringkat tersebut terlihat bahwa percakapan MBG tetap banyak berpusat pada akun tokoh/pemerintahan (misalnya prabowo) serta akun yang aktif berinteraksi dan berperan sebagai penghubung diskusi (misalnya dssupriyady). Munculnya akun institusi seperti divhumas\_polri atau dpr\_ri juga menunjukkan bahwa isu MBG tidak berdiri sendiri, melainkan ikut terseret ke tema keamanan, politik, dan respons lembaga. Temuan SNA ini dapat dipakai sebagai pintu masuk untuk menelusuri narasi, memeriksa sumber informasi, serta menentukan akun yang paling relevan untuk dipantau ketika isu MBG berkembang—dengan catatan bahwa akun media/akun otomatis dalam daftar filter sengaja dikeluarkan agar metrik centrality tidak bias oleh aktivitas pemberitaan. Jika digabung, analisis sentimen memberi gambaran arah opini, sedangkan SNA membantu menjelaskan “siapa” yang menggerakkan percakapan dan bagaimana keterhubungannya. Kombinasi keduanya membuat pembacaan isu MBG jadi lebih utuh, terutama saat percakapan bergerak cepat dan banyak akun saling menyebut.

## 5. KESIMPULAN DAN SARAN

Berdasarkan hasil pengujian, IndoBERT yang di-*fine-tune* mampu mengklasifikasikan sentimen MBG menjadi negatif, netral, dan positif dengan *weighted F1-score* 0,7413 pada data uji ( $N=142$ ). Pada data percakapan yang sudah dibersihkan dan dihapus duplikasinya ( $N=9.814$ ), sentimen positif menjadi yang paling dominan (41,9%), tetapi porsi netral dan negatif tetap besar sehingga isu MBG terlihat masih mengundang diskusi dan kritik. Dari sisi jejaring, pemetaan *mention* menunjukkan adanya aktor-aktor yang menonjol dan berperan penting dalam alur percakapan, yang terukur melalui gabungan metrik *degree*, *betweenness*, dan *closeness*.

Untuk pengembangan ke depan, performa kelas netral perlu diperkuat karena sifatnya memang “abu-abu” dan sering rancu dengan positif/negatif. Strateginya bisa dengan memperjelas pedoman label, menambah contoh data netral yang lebih beragam, dan mencoba augmentasi data untuk slang/sarkasme. Di sisi SNA, relasi bisa diperluas tidak hanya *mention*, tetapi juga *reply/quote* agar struktur jaringan lebih kaya, serta menambahkan analisis komunitas (misalnya modularity) untuk melihat kluster narasi yang terbentuk.

## DAFTAR PUSTAKA

- [1] R. Hidayat and R. Ramadhan, “Peran Media Sosial Dalam Mengkonstruksi Opini Publik Terkait Kebijakan Pemerintah: Studi Kasus Wacana Publik Tahun 2025,” *J. Commun. Res.*, vol. 3, no. 2, pp. 64–75, 2025, doi: <https://doi.org/10.47650/core.v3i2.2223>.
- [2] P. A. Edvra, N. Ahmad, and U. G. Mada, “Tipologi Jaringan Wacana dan Komunikator Publik dalam Berita Omicron Baru di Media Online,” *J. Ris. Komun.*, vol. 6, no. 1, pp. 58–79,

- 2023, doi: <https://doi.org/10.38194/jurkom.v6i1.698>.
- [3] N. Putu, G. Naraswati, D. C. Rosmilda, D. Desinta, P. D. Statistika, and P. S. Stis, "Analisis Sentimen Publik dari Twitter Tentang Kebijakan Penanganan Covid-19 di Indonesia dengan Naive Bayes Classification," *J. Sist. Inf.*, vol. 10, no. 10, pp. 228–238, 2021, doi: <https://doi.org/10.32520/stmsi.v10i1.1179>.
- [4] T. Islam and D. Goldwasser, "Uncovering Latent Arguments in Social Media Messaging by Employing LLMs-in-the-Loop Strategy," *Assoc. Comput. Linguist.*, vol. Findings o, pp. 7412–7444, 2025, doi: 10.18653/v1/2025.findings-naacl.413.
- [5] KPPN Mana, "Implementasi Program Makan Bergizi Gratis Pada Wilayah Semaku," KPPN Mana. [Online]. Available: <https://djpb.kemenkeu.go.id/kppn/mana/id/data-publikasi/artikel/3240-implementasi-program-makan-bergizi-gratis-pada-wilayah-semaku.html>
- [6] R. S. D.I., "Pemerintah Salurkan Makan Bergizi Gratis (MBG), Ini Sasaran Utama Penerimaannya Artikel ini telah tayang di situs Media Keuangan | MK+ dengan judul 'Pemerintah Salurkan Makan Bergizi Gratis (MBG), Ini Sasaran Utama Penerimaannya - Media Keuangan' Lihat seleng," Manajemen Situs Kemenkeu. [Online]. Available: <https://mediakeuangan.kemenkeu.go.id/article/how/pemerintah-salurkan-makan-bergizi-gratis-mbg-ini-sasaran-utama-penerimaannya>
- [7] A. Muh, F. High, A. Syahreza, N. Ruzadi, and M. R. Said, "Analisis Kebijakan Makan Bergizi Gratis Prabowo-Gibran dan Dampaknya dalam Bidang Pendidikan," *J. Cendikia Ilm.*, vol. 4, no. 5, pp. 655–664, 2025, doi: <https://doi.org/10.56799/jceki.v4i5.9695>.
- [8] M. Basit and H. Ramadani, "Analisis Implementasi Program Makan Bergizi Gratis Terhadap Perkembangan Ekonomi," *J. Econ. Dev. Res.*, vol. 1, no. 2, pp. 49–54, 2025, doi: <https://doi.org/10.71094/joeder.v1i2.105>.
- [9] R. A. Munir and A. Voutama, "Analisis Sentimen Cuitan di Media Sosial X Tentang Program Makan Bergizi Gratis," *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 3, pp. 589–595, 2025, doi: <https://doi.org/10.23960/jitet.v13i3.6912>.
- [10] R. Y. Rafael and F. Adikara, "Pengimplmentasian Algoritma Long Short-Term Memory Untuk Mendeteksi Ujaran Kebencian Pada Aplikasi Twitter," *J. Ilm. Penelit. dan Pembelajaran Inform.*, vol. 8, no. 2, pp. 551–560, 2023, doi: <https://doi.org/10.29100/jipi.v8i2.3490>.
- [11] M. W. Arif and Kustiyono, "Analisis Sentimen Kebijakan Makan Bergizi Gratis di Media Sosial Menggunakan Natural Language Processing Berbasis Python TextBlob di Indonesia Teknik Informatika , Universitas Ngudi Waluyo , Indonesia Sentiment Analysis of Free Nutritious Meal Policy on S," *J. Pendidik. dan Teknol. Indones.*, vol. 5, no. 9, pp. 2463–2471, 2025, doi: <https://doi.org/10.52436/1.jpti.931>.
- [12] SIP Law Firm, "Perencanaan DAK Nonfisik Sub Jenis Pangan bagi Program Makan Bergizi Gratis berdasarkan Perbadan 1/2025," SIP Law Firm. [Online]. Available: <https://siplawfirm.id/makan-bergizi-gratis/?lang=id>
- [13] S. Christianto and J. A. Ginting, "Social Network Analysis Peringatan Darurat Ruu Pemilihan Kepala Daerah," *J. Mhs. Tek. Inform.*, vol. 9, no. 3, pp. 5366–5373, 2025, doi: <https://doi.org/10.36040/jati.v9i3.13676>.
- [14] A. Kho and F. F. Tampinongkol, "Analisis Sentimen Pengguna Aplikasi STEAM dengan Algoritma Naive Bayes," *J. Multidiscip. Res. Dev.*, vol. 7, no. 6, pp. 4620–4627, 2025, doi: <https://doi.org/10.38035/rj.v7i6.1803>.
- [15] B. Hakim, F. J. Kaunang, A. P. Thenata, and Ranny, "Klasifikasi Engine Failure Berdasarkan Bunyi Mobil Menggunakan," *J. Inf. Syst. Informatics Eng.*, vol. 9, no. 1, pp. 188–196, 2025, doi: <https://doi.org/10.35145/joisie.v9i1.4936>.
- [16] Y. R. Kaesmetan and W. W. Kalengkongan, "Klasifikasi Sentimen Publik Terkait Stunting Di Indonesia Menggunakan BERT Dan SVM Classification of Public Sentiment Related to Stunting in Indonesia Using BERT and SVM," *J. Bus. Audit Inf. Syst.*, vol. 8, no. 2, pp. 11–23, 2025, doi: <http://dx.doi.org/10.30813/jbase.v8i2.8960>.
- [17] M. A. Firmansyah, A. Saeppani, and I. Fadil, "Analisis Sentimen Publik Program Makan Bergizi Gratis Menggunakan Support Vector Machine," *JPNM J. Pustaka Nusantara. Multidisiplin*, vol. 3, no. 4, Dec. 2025, doi: 10.59945/jpnm.v3i4.805.
- [18] B. O. Fikri, D. S. D. Lestari, F. A. Waimin, G. N. Bakry, and F. A. A. Prastowo, "Analisis Jaringan dan Aktor #Teddyout di Media Sosial Twitter Menggunakan Social Network Analysis (SNA)," *J. Ilm. Wahana Pendidik.*, vol. 10, no. September, pp. 215–232, 2024, doi: <https://doi.org/10.5281/zenodo.13854920>.
- [19] J. A. Nursiyono and C. Chotimah, "Analisis Sentimen Netizen Twitter terhadap Pemberitaan PPN Sembako dan Jasa Pendidikan dengan Pendekatan Social Network Analysis dan Naive Bayes Classifier," *J. Ilm. Teor. dan Apl. Stat.*, vol. 14, no. 1, pp. 52–58, 2021, doi: <https://doi.org/10.36456/jstat.vol14.no1.a3868>.
- [20] M. Hung et al., "Social Network Analysis of COVID-19 Sentiments : Application of Artificial Intelligence," *J. Med. Internet Res.*, vol. 22, pp. 1–13, 2020, doi: 10.2196/22590.