JIKI Volume 2 Nomor 1 Tahun 2026 Halaman 1 – 10
Journal of Integrated Knowledge and Innovation
https://jiki.web.id/index.php/jiki/index

Analisis Sentimen Publik Pada Platform X Terhadap Kebijakan Makan Bergizi Gratis Menggunakan Fine-Tuning Indobert Dan Fasttext

Intan Nurzari ✉ [1], R. Joko Musridho[2] , David Ibnu Harris[3], Regina Sesilia[4], M. Abdi Ahzani[5], M. Hasbullah[6], Irfan Alfalah, Arjunaidi[7]
Program Studi Teknik Informatika, Universitas Pahlawan Tuanku Tambusai
intannurzari27@gmail.com

Abstrak

Penelitian ini menganalisis sentimen publik pada platform media sosial X terhadap kebijakan Makan Bergizi Gratis menggunakan pendekatan klasifikasi hibrida yang menggabungkan FastText dan IndoBERT. Analisis sentimen diperlukan untuk memahami respons masyarakat terhadap program yang memiliki alokasi anggaran besar serta menghadapi berbagai tantangan implementasi. Data penelitian diperoleh dari 761 cuitan yang dikumpulkan selama periode April–Juni 2026 menggunakan Tweet Harvest. Setelah proses pembersihan data dan penghapusan duplikat, diperoleh 512 cuitan yang kemudian diberi label secara manual ke dalam tiga kategori sentimen, yaitu positif, netral, dan negatif. Dataset dibagi menjadi data latih (80%) dan data uji (20%) dengan teknik stratifikasi. Penelitian membandingkan model IndoBERT murni dengan model hibrida FastText–IndoBERT. Hasil menunjukkan bahwa model usulan memperoleh akurasi 88% dan F1-score terbobot 0,88, lebih tinggi dibandingkan model dasar yang mencapai akurasi 84% dan F1-score 0,84. Peningkatan kinerja terutama terlihat pada kelas sentimen minoritas. Analisis sentimen menunjukkan bahwa opini negatif mendominasi pembahasan publik terkait kebijakan ini, yang umumnya berkaitan dengan kekhawatiran terhadap penggunaan anggaran dan pelaksanaan program.

Kata Kunci: analisis sentimen, Makan Bergizi Gratis, IndoBERT, FastText.

Abstract

This study analyzes public sentiment on the X social media platform regarding the Free Nutritious Meals policy using a hybrid classification approach that combines FastText and IndoBERT. Sentiment analysis is important for understanding public responses to a government program involving substantial budget allocation and implementation challenges. A total of 761 tweets were collected between April and June 2026 using Tweet Harvest. After data cleaning and duplicate removal, 512 tweets were retained and manually labeled into three sentiment categories: positive, neutral, and negative. The dataset was divided into 80% training data and 20% testing data using a stratified sampling technique. The study compares a baseline IndoBERT model with the proposed FastText–IndoBERT hybrid model. The results show that the proposed model achieved an accuracy of 88% and a weighted F1-score of 0.88, outperforming the baseline model, which obtained an accuracy of 84% and a weighted F1-score of 0.84. Performance improvements were particularly evident in minority sentiment classes. The findings also indicate that negative sentiment dominates public discussions of the policy, mainly reflecting concerns about budget allocation and program implementation.

Keywords**:** *sentiment analysis, Free Nutritious Meals, IndoBERT, FastText.*

* Corresponding author :
Email : intannurzari27@gmail.com

PENDAHULUAN

Program Makan Bergizi Gratis (MBG) merupakan inisiatif strategis pemerintah Indonesia untuk meningkatkan kualitas gizi pada kelompok prioritas, yakni anak sekolah, ibu hamil, dan balita (Hadinata, 2026). Kebijakan yang berjalan bertahap sejak awal 2025 ini memproyeksikan jangkauan hingga 82,9 juta penerima manfaat demi mempercepat penurunan angka stunting nasional menuju target 14%. Implementasi kebijakan ini membutuhkan komitmen fiskal masif dengan alokasi APBN 2025 mencapai Rp100 hingga Rp450 triliun per tahun, yang memicu perdebatan publik terkait kekhawatiran stabilitas ekonomi makro serta wacana penggunaan dana Bantuan Operasional Sekolah (Rohman & Agung, 2025). Kendala teknis di lapangan, seperti kasus keracunan massal yang sempat menjadi sorotan media, turut memicu polarisasi opini di masyarakat. Kondisi ini menjadikan pemahaman komprehensif mengenai respons publik sebagai kebutuhan esensial bagi pemerintah untuk mengevaluasi efektivitas program secara berkelanjutan (Ahmad et al., 2025).

Di era interaksi digital, platform media sosial X bertransformasi menjadi arena utama bagi masyarakat dalam menyuarakan aspirasi dan kritik terhadap kebijakan pemerintah. Dengan jumlah pengguna aktif di Indonesia yang melampaui 22,9–25,2 juta akun, platform ini menjadi instrumen efektif untuk mengukur opini publik secara real-time terhadap isu kebijakan seperti MBG (Kemp, 2025). Akan tetapi, ekstraksi informasi dari data media sosial dihadapkan pada tantangan linguistik yang kompleks karena sifat teksnya yang tidak terstruktur (Xu et al., 2022). Pengguna cenderung mengekspresikan pandangan menggunakan bahasa informal, singkatan, serta variasi ejaan yang mengandung kesalahan pengetikan, sehingga nuansa kritik implisit dan penggunaan bahasa gaul kerap membuat model klasifikasi teks kesulitan mengenali makna semantik secara akurat (Sheng et al., 2023).

Topik analisis sentimen terhadap kebijakan MBG telah menarik perhatian sejumlah peneliti dalam satu tahun terakhir, dengan IndoBERT menjadi model yang paling banyak diadopsi. Haikal & Erfina (2026) menerapkan IndoBERT pada 361 cuitan dengan pelabelan otomatis oleh model pseudo label dan hanya memperoleh akurasi 60,27%, dengan kelas netral sebagai kategori paling sering tertukar dengan kelas negatif. Pada skala data yang jauh lebih besar, Setiadi & Sulistyo (2025) mengusulkan pelabelan hybrid yang menggabungkan pendekatan lexicon-based dengan IndoBERT, kemudian mengklasifikasikan 12.389 cuitan menggunakan Random Forest yang dioptimalkan dengan SMOTE sehingga mencapai F1-score hingga 0,9383; meski demikian, model tersebut masih kerap salah mengenali cuitan bernada sarkastis sebagai sentimen negatif. Rohman & Agung (2025) membandingkan IndoBERT dengan SVM dan Random Forest pada 54.105 cuitan yang dilabeli secara otomatis menggunakan model pretrained pihak ketiga, dan menemukan IndoBERT unggul dengan akurasi 87,60%, sementara Random Forest gagal mengenali sebagian besar cuitan berkategori negatif (recall hanya 0,18). Yuswira & Ginting (2026) menjadi satu-satunya studi yang menggunakan pelabelan manual sebagai ground truth, dipadukan dengan Social Network Analysis untuk memetakan aktor berpengaruh; namun performa model pada data uji manual yang relatif kecil (N=142) hanya mencapai Weighted F1-score 0,7413, dengan kelas netral kembali menjadi titik terlemah (recall 0,5476). Sejalan dengan hal tersebut, Tyas et al., (2025) memanfaatkan pelabelan berbasis kamus sentimen (lexicon-based) sebelum melatih IndoBERT dan memperoleh akurasi 85% dengan precision tertinggi pada kelas positif, namun precision kelas netral tetap menjadi yang terendah (0,78).

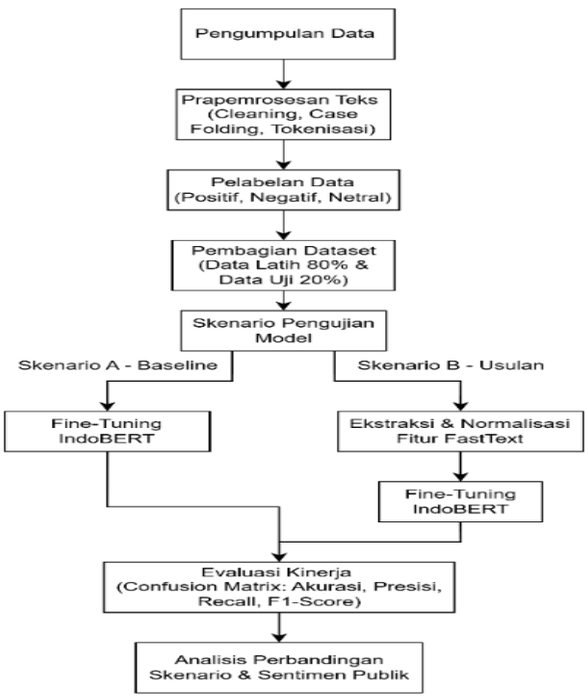
Sintesis dari kelima studi terdahulu tersebut menunjukkan dua kesenjangan metodologis yang konsisten. Pertama, ground truth pada mayoritas studi (Haikal & Erfina, 2026; Rohman & Agung, 2025; Setiadi & Sulistyo, 2025; Tyas et al., 2025; Yuswira & Ginting, 2026), dihasilkan melalui pelabelan otomatis, baik berbasis leksikon maupun pseudo-label dari model bahasa lain, yang berisiko menurunkan reliabilitas evaluasi karena ketidakmampuan pendekatan tersebut menangkap nuansa sarkasme dan kritik implisit yang lazim pada teks media sosial. Kedua, kelas sentimen netral maupun positif secara konsisten menjadi kategori dengan performa klasifikasi terendah di seluruh studi, yang mengindikasikan bahwa representasi fitur pada model IndoBERT murni belum cukup tangguh dalam menangani variasi ejaan, singkatan, dan kata tidak baku yang mendominasi kelas-kelas minoritas tersebut. Sayangnya, belum ada studi MBG terdahulu yang mengeksplorasi penggabungan representasi subkata (subword) dengan representasi kontekstual IndoBERT untuk secara spesifik mengatasi permasalahan kata di luar kosakata standar (out-of-vocabulary), maupun yang menerapkan mekanisme pembobotan kelas (class weighting) secara langsung pada proses fine-tuning IndoBERT untuk menangani ketimpangan distribusi data.

Sebagai jawaban atas kesenjangan tersebut, penelitian ini menawarkan kebaruan melalui pendekatan hibrida yang mengintegrasikan ekstraksi fitur FastText dengan model klasifikasi IndoBERT, dilengkapi mekanisme pembobotan kelas dan didukung oleh pelabelan manual untuk menjaga reliabilitas ground truth (Yuswira & Ginting, 2026). FastText dipilih karena bekerja pada level karakter subkata sehingga tangguh dalam menangani anomali ejaan dan kata tidak baku yang lazim dijumpai pada teks platform X (Thara & Poornachandran, 2022). Representasi fitur tersebut kemudian digabungkan dengan representasi kontekstual dua arah dari IndoBERT, sehingga model yang dihasilkan diharapkan tidak hanya memahami konteks semantik kalimat secara menyeluruh, tetapi juga lebih sensitif terhadap variasi morfologis kata, khususnya pada kelas sentimen minoritas yang selama ini menjadi titik lemah model-model terdahulu.

Implementasi komputasional dalam penelitian ini dieksekusi melalui beberapa tahapan sistematis, diawali dengan pengumpulan data opini publik menggunakan teknik crawling pada platform X dengan kata kunci spesifik terkait program MBG. Dataset mentah tersebut selanjutnya melalui tahapan prapemrosesan teks yang ekstensif, seperti pembersihan, penyeragaman huruf, dan tokenisasi, guna mereduksi elemen bising pada data (Duong & Thi, 2021). Tujuan utama penelitian ini adalah membandingkan performa arsitektur hibrida usulan dengan model dasar IndoBERT murni untuk mengukur tingkat efektivitasnya dalam mengklasifikasikan sentimen publik, dengan kinerja kedua model dievaluasi secara kuantitatif melalui matriks konfusi menggunakan metrik akurasi, presisi, recall, dan F1-score. Luaran penelitian ini ditujukan untuk menyajikan wawasan empiris bagi para pengambil kebijakan terkait penerimaan publik terhadap program MBG, sekaligus mengevaluasi keandalan pendekatan hibrida FastText dan IndoBERT dalam menangani karakteristik teks media sosial berbahasa Indonesia yang tidak terstruktur.

METODE

Penelitian ini menggunakan pendekatan kuantitatif komputasional yang berfokus pada klasifikasi teks berlabel sentimen. Alur penelitian dirancang secara sistematis mulai dari tahapan pengumpulan data, prapemrosesan teks, pelabelan, pembagian dataset, skenario pengujian model, hingga evaluasi kinerja akhir. Alur kerja metodologi yang diusulkan merujuk pada integrasi ekstraksi fitur kata dengan model bahasa kontekstual. Rincian alur kerja metodologi tersebut direpresentasikan pada Gambar 1.



Gambar.1 Alur Penelitian Analisis Sentimen

Pengumpulan dan Pelabelan data

Data dikumpulkan dari platform media sosial X pada rentang waktu 1 April 2026 hingga 8 Juni 2026 menggunakan teknik penambangan teks. Proses ini dijalankan melalui pustaka berbasis Python bernama Tweet Harvest dengan menggunakan kata kunci pencarian terkait kebijakan Makan Bergizi Gratis. Mengingat adanya kebijakan pembatasan akses data dari platform X, pengumpulan dilakukan secara bertahap hingga memperoleh jumlah sampel yang merepresentasikan opini publik. Data mentah yang terkumpul kemudian disaring untuk menyingkirkan cuitan yang tidak relevan. Teks yang telah bersih selanjutnya dilabeli secara manual ke dalam tiga kategori polaritas sentimen yaitu positif, netral, dan negatif. Untuk mengantisipasi karakteristik data media sosial yang rentan mengalami ketimpangan distribusi antarkelas, dataset berlabel ini dipersiapkan untuk ditangani secara khusus pada tahap pelatihan model (Wodarski et al., 2023).

Prapemrosesan Teks dan Pembagian Dataset

Teks mentah yang telah dikumpulkan harus melalui serangkaian tahap prapemrosesan untuk menghilangkan elemen bising sebelum dimasukkan ke dalam arsitektur pemodelan (Palomino, 2022). Tahapan ini diawali dengan proses cleaning untuk membersihkan teks dari tautan situs web, penyebutan nama pengguna, tagar, dan tanda baca. Setelah itu, dilakukan proses case folding untuk menyeragamkan huruf dengan mengubah seluruh huruf kapital menjadi karakter kecil. Tahap prapemrosesan diakhiri dengan proses tokenisasi yaitu pemecahan kalimat menjadi unit kata yang independen. Teks bersih yang telah diberi label sentimen kemudian

dibagi menggunakan rasio 80% sebagai data latih dan 20% sebagai data uji. Pembagian dataset ini menerapkan teknik stratifikasi untuk memastikan proporsi kelas sentimen tetap seimbang saat melatih maupun mengevaluasi model.

Skenario Pengujian Model

Penelitian ini merancang dua skenario pengujian komparatif guna mengevaluasi tingkat efektivitas arsitektur usulan. Skenario pertama bertindak sebagai model dasar yang menggunakan arsitektur IndoBERT murni tanpa penambahan fitur eksternal. Proses penyetelan model dasar ini langsung diterapkan pada data latih untuk melihat kemampuan asli model berbahasa Indonesia tersebut dalam memproses teks media sosial.

Skenario kedua merupakan arsitektur usulan yang mengintegrasikan vektor fitur FastText sebesar 300 dimensi dengan lapisan model IndoBERT berukuran 768 dimensi. Untuk mencegah penurunan akurasi akibat dimensi fitur yang terlalu besar, ukuran fitur FastText direduksi secara drastis menjadi 50 dimensi menggunakan transformasi lapisan linear. Penggabungan fitur tersebut kemudian diselaraskan menggunakan fungsi aktivasi GELU dan normalisasi lapisan guna menjaga stabilitas pemodelan (Lee, 2023). Algoritma pembobotan kelas juga turut diimplementasikan pada skenario ini. Pendekatan ini berfungsi untuk memberikan nilai hukuman yang lebih besar kepada model apabila melakukan kesalahan prediksi pada kelas minoritas selama tahapan pelatihan berlangsung.

Evaluasi Kinerja

Kinerja klasifikasi dari kedua skenario tersebut dievaluasi secara terukur melalui perhitungan matriks konfusi. Tolok ukur utama yang digunakan untuk membandingkan performa model meliputi nilai Akurasi, Presisi, Recall, dan F1-score. Perhitungan matematis dari keempat metrik tersebut dirumuskan berturut-turut pada persamaan 1 hingga persamaan 4.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = \frac{2\ x\ (Precision\ x\ Recall)}{Precision + Recall} \quad (4)$$

Setiap variabel di dalam rumus evaluasi tersebut merepresentasikan hasil tebakan model terhadap data uji. Variabel TP mewakili data positif yang berhasil diprediksi secara benar. Variabel TN menunjukkan data negatif yang juga berhasil ditebak dengan benar. Variabel FP merupakan bentuk kesalahan prediksi di mana data negatif salah dikenali sebagai data positif. Variabel FN menunjukkan kesalahan fatal di mana data positif justru diklasifikasikan sebagai data negatif. Mempertimbangkan distribusi kelas yang tidak seimbang di dalam dataset, rata-rata bobot dari metrik F1-score dijadikan sebagai acuan evaluasi utama. Model yang sukses mencetak skor evaluasi tertinggi pada fase validasi akan diamankan secara otomatis melalui mekanisme penguncian memori model.

HASIL DAN PEMBAHASAN

Bab ini menguraikan hasil eksperimen secara komprehensif berdasarkan metodologi yang telah dirancang. Pembahasan mencakup hasil dari setiap tahapan mulai dari perolehan data, prapemrosesan, hingga evaluasi komparatif antara model dasar dengan arsitektur usulan untuk menjawab pertanyaan penelitian.

Hasil Pengumpulan Data

Proses penarikan data dari platform X menghasilkan 761 cuitan mentah terkait kebijakan Makan Bergizi Gratis. Seluruh rangkaian proses pengambilan data hingga prapemrosesan teks dilakukan pada lingkungan komputasi awan menggunakan Google Colab. Pemanfaatan platform ini dipilih karena ketersediaan resource perangkat keras yang memadai untuk menangani pemrosesan data teks berskala besar secara efisien. Setelah melalui proses pembersihan teks dari berbagai elemen bising dan cuitan duplikat, jumlah data menyusut secara signifikan. Sisa data sebanyak 512 baris teks bersih ini didominasi oleh sentimen negatif yang mencerminkan tingginya kekhawatiran publik terhadap anggaran dan mekanisme pelaksanaan program tersebut. Dataset bersih tersebut kemudian dibagi menjadi data latih sebesar 80% dan data uji sebesar 20%. Proses stratifikasi berhasil menjaga keseimbangan proporsi kelas sentimen di kedua bagian data. Rincian distribusi jumlah data latih dan data uji untuk setiap kelas polaritas sentimen dapat dilihat secara lengkap pada Tabel 1.

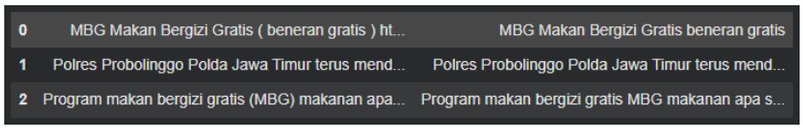
Tabel 1. Distribusi Dataset Sentimen

Kelas Sentimen	Data Latih (80%)	Data Uji (20%)	Total
Negati (Label 2)	245	61	306
Positif (Label 0)	82	21	103

Netral (Label 1)	82	21	103
Total Keseluruhan	409	103	512

Prapemrosesan Data

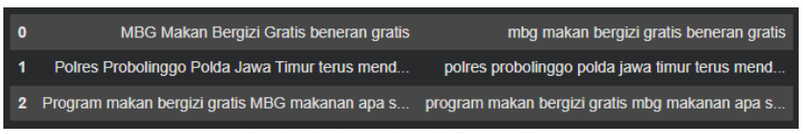
Pada tahap prapemrosesan data, dilakukan serangkaian langkah untuk memastikan data teks siap digunakan dalam analisis. Tahap pertama adalah cleaning yang bertujuan membersihkan teks dari elemen tidak relevan seperti tautan, tanda baca, serta karakter khusus. Hasil tahap cleaning diperlihatkan pada Gambar 2.



0	MBG Makan Bergizi Gratis (beneran gratis) ht...	MBG Makan Bergizi Gratis beneran gratis
1	Polres Probolinggo Polda Jawa Timur terus mend...	Polres Probolinggo Polda Jawa Timur terus mend...
2	Program makan bergizi gratis (MBG) makanan apa...	Program makan bergizi gratis MBG makanan apa s...

Gambar 1. Sampel Hasil *Cleaning*

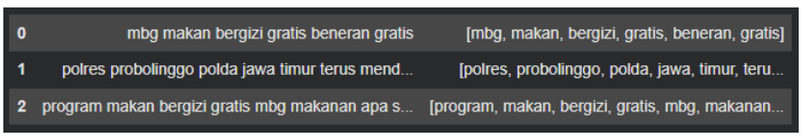
Tahap selanjutnya adalah case folding yang menyeragamkan seluruh huruf menjadi karakter kecil. Proses ini penting untuk meminimalkan variasi penulisan sehingga model dapat memproses data secara konsisten. Hasil tahap case folding diperlihatkan pada Gambar 3.



0	MBG Makan Bergizi Gratis beneran gratis	mbg makan bergizi gratis beneran gratis
1	Polres Probolinggo Polda Jawa Timur terus mend...	polres probolinggo polda jawa timur terus mend...
2	Program makan bergizi gratis MBG makanan apa s...	program makan bergizi gratis mbg makanan apa s...

Gambar 2. Sampel Hasil *Case Folding*

Setelah teks seragam, dilakukan tahap tokenizing untuk memecah kalimat menjadi unit kata yang independen. Hasil tahap tokenizing diperlihatkan pada Gambar 4.



0	mbg makan bergizi gratis beneran gratis	[mbg, makan, bergizi, gratis, beneran, gratis]
1	polres probolinggo polda jawa timur terus mend...	[polres, probolinggo, polda, jawa, timur, teru...
2	program makan bergizi gratis mbg makanan apa s...	[program, makan, bergizi, gratis, mbg, makanan...

Gambar 3. Sampel Hasil *Tokenizing*

Pelabelan Data

Proses pelabelan dilakukan secara manual untuk memastikan presisi klasifikasi sentimen pada setiap cuitan. Pendekatan manual ini dipilih mengingat dataset yang digunakan memiliki karakteristik linguistik yang kompleks, di mana pengguna media sosial sering kali menyampaikan opini melalui gaya bahasa sarkastis, sindiran, atau ungkapan bernada ambigu. Penggunaan metode pelabelan otomatis berbasis kamus kata (lexicon-based) berisiko menyebabkan kesalahan klasifikasi pada kalimat-kalimat tersebut karena keterbatasan algoritma dalam memahami konteks emosi yang tersirat.

Dengan melakukan pelabelan secara manual, setiap cuitan diperiksa secara mendalam untuk menangkap niat asli penulis, sehingga kualitas dataset berlabel menjadi lebih reliabel dan objektif. Dataset bersih yang berjumlah 512 baris dikategorikan ke dalam tiga kelas sentimen yaitu negatif, netral, dan positif. Distribusi hasil pelabelan menunjukkan adanya ketimpangan jumlah data antarkelas, di mana sentimen negatif mendominasi opini publik dibandingkan dua kategori lainnya. Rincian distribusi final dataset yang telah dilabeli tersebut disajikan secara lengkap pada Tabel 1.

Hasil Pelatihan dan Evaluasi Model

Tahap implementasi komputasional dilaksanakan dalam dua skenario pengujian yang berjalan secara terpisah namun menggunakan dataset yang sama, yakni Skenario A untuk model arsitektur usulan (FastText + IndoBERT) dan Skenario B untuk model dasar (IndoBERT murni). Seluruh proses eksperimen dijalankan pada lingkungan Google Colaboratory dengan akselerator GPU CUDA guna memastikan efisiensi komputasi dalam menangani operasi pelatihan model bahasa berskala besar.

Hasil Pelatihan Arsitektur Usulan (FastText + IndoBERT)

Implementasi arsitektur usulan diawali dengan persiapan data melalui pemuatan dataset berlabel ke dalam lingkungan komputasi yang kemudian dibagi menggunakan rasio 80:20 secara terstrategifikasi, menghasilkan 409 data latih dan 103 data uji dengan proporsi kelas sentimen yang seimbang di setiap partisi. Selanjutnya, model FastText berbahasa Indonesia dengan representasi vektor 300 dimensi dimuat ke dalam memori sistem untuk menjalankan proses ekstraksi fitur pada seluruh teks dalam dataset. Sebuah fungsi ekstraksi kustom dikembangkan untuk mengubah setiap kalimat menjadi representasi vektor numerik,

sedangkan teks yang tidak valid dikembalikan sebagai vektor nol sepanjang 300 dimensi agar konsistensi dimensi input model tetap terjaga.

```
222  jenderal maruli gak perlu repot-repot urusin s...
451  Menteri Keuangan (Menkeu) RI Purbaya Yudhi Sad...
226  Satgas MBG Bangkalan Soroti Puluhan Dapur Prog...
417  Presiden Prabowo Subianto menerima surat dari ...
225  @seulrenation23 Bad omens ke delay karna chefn...

                                        fasttext_vector
222  [0.024527803, -0.012961012, 0.04017953, 0.0867...
451  [-0.005356034, 0.0032735586, 0.022381252, 0.09...
226  [-0.0037303811, 0.016110893, 0.0035069843, 0.0...
417  [0.0014141331, 0.0055524837, 0.015253865, 0.08...
225  [0.009051246, -0.022917515, -0.0004995565, 0.0...
```

Gambar 4. Sampel Hasil Konversi Teks Menjadi Vektor

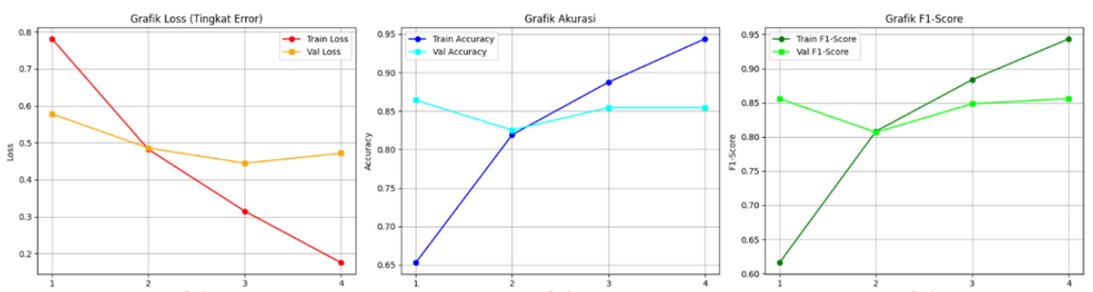
Setelah fitur vektor berhasil diekstraksi seperti pada Gambar 5, tokenizer IndoBERT dimuat dari repositori Hugging Face dengan parameter pemotongan maksimal 128 token yang merepresentasikan batas standar panjang karakter pada teks platform X. Sebuah kelas dataset kustom kemudian dikembangkan untuk menyatukan fitur vektor FastText 300 dimensi dengan hasil tokenisasi IndoBERT, sehingga setiap sampel data menghasilkan empat keluaran, yaitu input_ids, attention_mask, fasttext_vector, dan label. DataLoader dibuat dengan ukuran batch sebesar 16 disertai mekanisme pengacakan pada data latih guna memastikan generalisasi model yang optimal.

Arsitektur model usulan dibangun dari tiga komponen yang bekerja secara terintegasi. Komponen pertama adalah tulang punggung IndoBERT yang menghasilkan representasi kontekstual berukuran 768 dimensi. Komponen kedua adalah lapisan reduksi linear yang mengompresi vektor FastText dari 300 dimensi menjadi 50 dimensi guna mencegah permasalahan curse of dimensionality sekaligus mengurangi risiko overfitting. Komponen ketiga adalah lapisan klasifikasi akhir berukuran 818 dimensi (768 + 50) yang memetakan representasi gabungan tersebut ke dalam tiga kelas sentimen. Lapisan aktivasi ReLU dan Dropout dengan probabilitas 0,3 turut ditambahkan untuk memperkuat kapabilitas generalisasi model selama proses pelatihan berlangsung.

Proses pelatihan awal dilaksanakan selama empat epoch dengan learning rate sebesar 2e-5 menggunakan optimizer AdamW dan fungsi kehilangan CrossEntropyLoss. Hasil pelatihan awal menunjukkan tren penurunan nilai loss secara konsisten disertai peningkatan akurasi dan F1-score pada setiap epoch, sebagaimana tersaji pada Tabel 2.

Tabel 2. Hasil Evaluasi Per Epoch Model Usulan Percobaan Awal

Epoch	Train Loss	Val Loss	Train Acc	Val Acc	Train F1	Val F1
1	0,7810	0,5778	0,6628	0,8641	0,6159	0,8560
2	0,4820	0,4857	0,8191	0,8252	0,8082	0,8067
3	0,3149	0,4446	0,8875	0,8544	0,8838	0,8485
4	0,1754	0,4717	0,9438	0,8544	0,9435	0,8560



Gambar 5. Grafik *Loss*, Akurasi, dan *F1-Score* per *epoch* model usulan percobaan awal

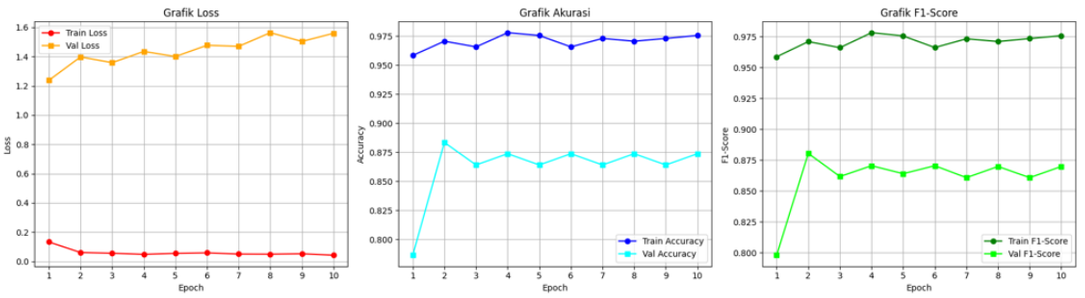
Mempertimbangkan adanya potensi peningkatan kinerja lebih lanjut, khususnya pada kelas minoritas yang distribusinya tidak seimbang, dilakukan percobaan lanjutan dengan menerapkan mekanisme pembobotan kelas (class weighting). Bobot yang ditetapkan adalah 1,66 untuk kelas positif (label 0), 1,66 untuk kelas netral (label 1), dan 0,56 untuk kelas negatif (label 2), yang mencerminkan nilai pembobotan terbalik dari proporsi distribusi masing-masing kelas dalam dataset. Mekanisme ini berfungsi memberikan nilai penalti yang lebih besar kepada model apabila melakukan kesalahan prediksi pada kelas minoritas selama pelatihan berlangsung. Percobaan lanjutan ini dieksekusi dalam dua tahap: tahap pertama selama empat epoch yang menghasilkan Val F1 terbaik sebesar 0,8895, kemudian diperluas menjadi sepuluh epoch untuk mengoptimalkan kinerja model secara penuh sebagaimana ditampilkan pada Tabel 3 dan Tabel 4.

Tabel 3. Hasil Evaluasi Per Epoch Model Usulan dengan Pembobotan Kelas (4 Epoch)

Epoch	Train Loss	Val Loss	Train Acc	Val Acc	Train F1	Val F1
1	1,0021	0,8831	0,5232	0,7184	0,5469	0,7158
2	0,6756	0,6423	0,7384	0,8932	0,7462	0,8895
3	0,4597	0,6989	0,8557	0,8641	0,8589	0,8589
4	0,2768	0,6370	0,9071	0,8058	0,9091	0,8198

Tabel 4. Hasil Evaluasi Per Epoch Model Usulan dengan Pembobotan Kelas (10 Epoch)

Epoch	Train Loss	Val Loss	Train Acc	Val Acc	Train F1	Val F1
1	0,1331	1,2381	0,9584	0,7864	0,9587	0,7981
2	0,0610	1,3977	0,9707	0,8835	0,9710	0,8805
3	0,0550	1,3584	0,9658	0,8641	0,9661	0,8618
4	0,0485	1,4383	0,9780	0,8738	0,9782	0,8706
5	0,0551	1,4003	0,9756	0,8641	0,9756	0,8641
6	0,0586	1,4775	0,9658	0,8738	0,9662	0,8705
7	0,0504	1,4702	0,9731	0,8641	0,9733	0,8609
8	0,0496	1,5634	0,9707	0,8738	0,9711	0,8699
9	0,0524	1,5040	0,9731	0,8641	0,9735	0,8609
10	0,0426	1,6592	0,9756	0,8738	0,9758	0,8699

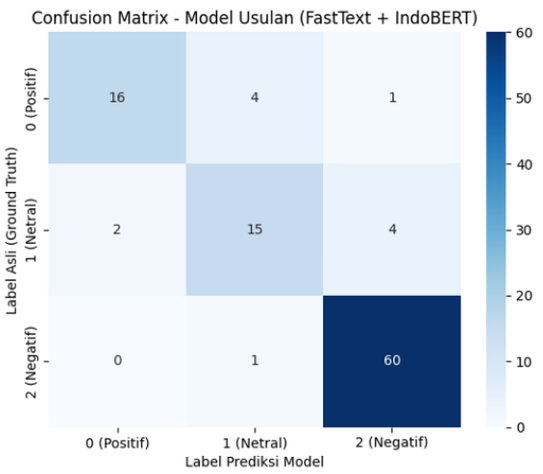


Gambar 6. Grafik Loss, Akurasi, dan F1-Score per Epoch Model Usulan 10 Epoch

Pada eksperimen sepuluh epoch, model berhasil mencapai kinerja validasi terbaiknya pada epoch kedua dengan Val F1 sebesar 0,8805, dan mekanisme penguncian model otomatis (model checkpoint) langsung menyimpan bobot model pada kondisi optimal tersebut. Bobot terbaik inilah yang kemudian digunakan untuk menjalankan evaluasi akhir secara menyeluruh pada 103 sampel data uji, meliputi perhitungan classification report per kelas sentimen serta visualisasi matriks konfusi. Hasil evaluasi akhir model usulan pada data uji tersaji pada Tabel 5.

Tabel 5. Classification Report Model Usulan (FastText + IndoBERT)

Kelas Sentimen	Precision	Recall	F1-score	Support
Negati (Label 2)	0,92	0,98	0,95	61
Positif (Label 0)	0,89	0,76	0,82	21
Netral (Label 1)	0,75	0,71	0,73	21
Accuracy		0,88	103	
Macro Average	0,85	0,82	0,83	103
Weighted Avg	0,88	0,88	0,88	103



Gambar 7. *Confusion Matrix* Model Usulan (FastText + IndoBERT)

Matriks konfusi model usulan dalam Gambar 8 memperlihatkan bahwa dari 21 sampel sentimen positif, sebanyak 16 sampel berhasil diklasifikasikan dengan benar, sementara 4 sampel salah diklasifikasikan sebagai sentimen netral dan 1 sampel sebagai sentimen negatif. Dari 21 sampel sentimen netral, sebanyak 15 sampel berhasil diprediksi dengan benar, dengan 2 sampel terprediksi sebagai positif dan 4 sampel terprediksi sebagai negatif. Dari 61 sampel sentimen negatif, 60 sampel berhasil terprediksi benar dan hanya 1 sampel yang salah diprediksi sebagai sentimen netral. Secara keseluruhan, model usulan mencapai akurasi sebesar 88% dengan F1-score terbobot sebesar 0,88.

Hasil Pelatihan Model Dasar IndoBERT Murni

Skenario kedua mengimplementasikan IndoBERT murni tanpa integrasi fitur FastText sebagai acuan pembanding (baseline). Model ini menggunakan arsitektur BertForSequenceClassification dari pustaka transformers dengan tiga label keluaran, sehingga lapisan klasifikasi dikelola sepenuhnya oleh mekanisme internal IndoBERT tanpa penambahan komponen eksternal apa pun.

Persiapan data pada skenario ini menggunakan dataset yang identik dengan skenario pertama, namun kelas dataset kustom yang dikembangkan hanya menghasilkan tiga atribut, yaitu input_ids, attention_mask, dan label, tanpa menyertakan vektor FastText. DataLoader dibuat dengan ukuran batch yang sama sebesar 16. Hyperparameter pelatihan pun disamakan secara ketat dengan skenario pertama, yakni empat epoch, learning rate 2e-5, dan optimizer AdamW, agar perbandingan antara kedua model bersifat adil dan terukur.

Proses pelatihan model dasar berlangsung selama empat epoch dan menghasilkan rekam jejak metrik evaluasi per epoch sebagaimana tercantum pada Tabel 6. Tren pelatihan memperlihatkan penurunan loss dan peningkatan akurasi yang serupa dengan skenario pertama, namun dengan langit-langit kinerja (performance ceiling) yang lebih rendah, terutama pada data validasi.

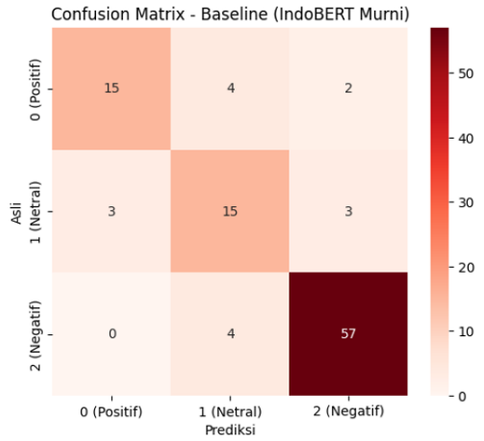
Tabel 6. Classification Report Model Usulan (FastText + IndoBERT)

Epoch	Train Loss	Val Loss	Train Acc	Val Acc	Train F1	Val F1
1	0,7538	0,5570	0,6822	0,8252	0,6365	0,7984
2	0,4333	0,4724	0,8264	0,8447	0,8127	0,8402
3	0,2906	0,4108	0,9046	0,8641	0,9015	0,8606
4	0,1511	0,4704	0,9511	0,8447	0,9508	0,8447

Evaluasi akhir model dasar kemudian dilakukan pada 103 sampel data uji menggunakan bobot model dari epoch terakhir. Laporan klasifikasi per kelas dan matriks konfusi dihitung untuk menjadi dasar perbandingan langsung terhadap arsitektur usulan, sebagaimana ditampilkan pada Tabel 7.

Tabel 7. Classification Report Model Dasar IndoBERT Murni

Kelas Sentimen	Precision	Recall	F1-score	Support
Negati (Label 2)	0,92	0,93	0,93	61
Positif (Label 0)	0,83	0,71	0,77	21
Netral (Label 1)	0,65	0,71	0,68	21
Accuracy		0,84	103	
Macro Average	0,80	0,79	0,79	103
Weighted Avg	0,85	0,84	0,84	103



Gambar 8. *Confusion Matrix* Model Dasar IndoBERT Murni

Matriks konfusi model dasar dalam Gambar 9 menunjukkan bahwa dari 21 sampel sentimen positif, sebanyak 15 sampel berhasil diklasifikasikan dengan benar, sementara 4 sampel salah diprediksi sebagai netral dan 2 sampel sebagai negatif. Dari 21 sampel sentimen netral, 15 sampel terprediksi benar, 3 sampel terprediksi sebagai positif, dan 3 sampel terprediksi sebagai negatif. Dari 61 sampel sentimen negatif, 57 sampel berhasil diprediksi benar dan 4 sampel salah diprediksi sebagai netral. Secara keseluruhan, model dasar mencapai akurasi sebesar 84% dengan F1-score terbobot sebesar 0,84.

Perbandingan Kinerja Kedua Model

Perbandingan hasil evaluasi akhir antara arsitektur usulan dan model dasar memperlihatkan perbedaan kinerja yang konsisten di seluruh metrik pengujian sebagaimana dirangkum pada Tabel N.

Tabel 8. Perbandingan Kinerja Akhir Model Usulan dan Model Dasar

Metrik Evaluasi	IndoBERT Murni	FastText + IndoBERT	Selisih
Akurasi	0,84	0,88	+0,04
Precision (Weighted)	0,85	0,88	+0,03
Recall (Weighted)	0,84	0,88	+0,04
F1-score (Weighted)	0,84	0,88	+0,04
F1 Kelas Positif	0,77	0,82	+0,05
F1 Kelas Netral	0,68	0,73	+0,05
F1 Kelas Negatif	0,93	0,95	+0,02

Arsitektur usulan yang mengintegrasikan FastText dengan IndoBERT secara konsisten mengungguli model dasar di seluruh metrik evaluasi. Peningkatan yang paling signifikan terjadi pada kelas minoritas, yaitu sentimen positif dan netral, yang masing-masing mengalami kenaikan F1-score sebesar 5 poin persentase. Hal ini mengonfirmasi bahwa representasi subkata dari FastText memberikan kontribusi nyata dalam menangani variasi ejaan dan kata tidak baku yang lazim ditemukan pada teks media sosial berbahasa Indonesia, sehingga model mampu mengenali pola semantik yang sebelumnya sulit ditangkap oleh IndoBERT murni. Penerapan mekanisme pembobotan kelas turut berperan dalam memperbaiki sensitivitas model terhadap kelas data yang distribusinya lebih sedikit selama proses pelatihan. Peningkatan akurasi keseluruhan sebesar 4 poin persentase, dari 84% pada model dasar menjadi 88% pada arsitektur usulan, membuktikan efektivitas pendekatan hibrida FastText dan IndoBERT dalam klasifikasi sentimen teks media sosial berbahasa Indonesia yang bersifat tidak terstruktur.

SIMPULAN

Penelitian ini berhasil membuktikan bahwa pendekatan hibrida yang mengintegrasikan ekstraksi fitur FastText dengan model bahasa IndoBERT mampu menghasilkan kinerja klasifikasi sentimen yang lebih unggul dibandingkan penggunaan IndoBERT murni pada data teks media sosial berbahasa Indonesia. Model arsitektur usulan mencapai akurasi sebesar 88% dengan F1-score terbobot 0,88, melampaui model dasar IndoBERT murni yang hanya memperoleh akurasi 84% dengan F1-score terbobot 0,84. Peningkatan paling signifikan terjadi pada kelas sentimen minoritas, yaitu kelas positif dan netral, yang masing-masing mengalami kenaikan F1-score sebesar 5 poin persentase. Hal ini mengonfirmasi bahwa kemampuan FastText dalam merepresentasikan fitur subkata secara efektif mengatasi tantangan variasi ejaan dan penggunaan kata tidak baku yang lazim ditemukan pada teks platform X, sementara mekanisme pembobotan kelas berperan penting dalam memperbaiki sensitivitas model terhadap ketimpangan distribusi data.

Analisis terhadap 512 cuitan yang dikumpulkan pada periode April hingga Juni 2026 menunjukkan bahwa sentimen negatif mendominasi opini publik terhadap kebijakan Makan Bergizi Gratis, yang mencerminkan tingginya kekhawatiran masyarakat terhadap aspek anggaran dan mekanisme pelaksanaan program. Temuan ini dapat menjadi masukan empiris bagi para pengambil kebijakan untuk mengidentifikasi dimensi program yang perlu diperkuat komunikasinya kepada publik, khususnya terkait transparansi pengelolaan anggaran dan jaminan keamanan pangan dalam pelaksanaan program.

Untuk penelitian selanjutnya, disarankan agar eksplorasi dilakukan terhadap teknik augmentasi data guna mengatasi ketimpangan distribusi kelas yang lebih ekstrem, serta pengujian arsitektur serupa pada dataset yang lebih besar untuk menguji skalabilitas model. Pengembangan lebih lanjut dapat mempertimbangkan integrasi

DAFTAR PUSTAKA

Ahmad, F. F., Abdillah, M., Agustino, W., & Herliska, R. (2025). Akuntabilitas Kebijakan Makan Bergizi Gratis Terhadap Aduan Keracunan Makanan melalui Media Sosial. 9(2). https://doi.org/https://doi.org/10.31002/jpalg.v9i2.3010

Duong, H. T., & Thi, T. N. (2021). A review : preprocessing techniques and data augmentation for sentiment analysis. Computational Social Networks, 1–16. https://doi.org/10.1186/s40649-020-00080-x

Hadinata, M. (2026). Free Nutritious Meal Policy in Indonesia under President Prabowo. 65–78. https://doi.org/https://doi.org/10.21787/jbp.18.2026.2896

Haikal, M., & Erfina, A. (2026). Analisis Sentimen Warganet terhadap Program Makan Bergizi Gratis (MBG) Menggunakan Model Indobert. 5(3). https://doi.org/https://doi.org/10.58344/locus.v5i3.5253

Kemp, S. (2025). Datareportal. https://datareportal.com/reports/digital-2025-indonesia?

Lee, M. (2023). Mathematical Analysis and Performance Evaluation of the GELU Activation Function in Deep Learning. https://doi.org/10.1155/2023/4229924

Palomino, M. A. (2022). Evaluating the Effectiveness of Text Pre-Processing in Sentiment Analysis. https://doi.org/https://doi.org/10.3390/app12178765

Rohman, S., & Agung, I. W. P. (2025). Komparasi Algoritma Indobert, Svm, Dan Random Forest Dalam Analisis Sentimen Program Makan Bergizi Gratis. 9(6), 9464–9471. https://doi.org/https://doi.org/10.36040/jati.v9i6.15611

Setiadi, E., & Sulistyo, D. A. (2025). Analisis Sentimen Kebijakan Makan Bergizi Gratis Menggunakan IndoBERT dan Machine Learning. 15(3), 507–513. https://doi.org/https://doi.org/10.37859/jf.v15i3.10546

Sheng, L., Fan, Y., Liu, J., & Liu, D. (2023). An Improved Direct Predictive Torque Control for Torque Ripple and Copper Loss Reduction in SRM Drive. https://doi.org/https://doi.org/10.3390/app13095319

Thara, S., & Poornachandran, P. (2022). Social media text analytics of Malayalam – English code - mixed using deep learning. Journal of Big Data. https://doi.org/10.1186/s40537-022-00594-3

Tyas, F. A., Fajriyah, R. F., & Nuraningsih, F. (2025). Analisis Prediktif Respons Pengguna X Terhadap Implementasi Program Makan Bergizi Gratis Menggunakan Algoritma IndoBERT. 1–12. https://jurnal.umj.ac.id/index.php/semnaslit/article/view/29591/13033

Wodarski, P., Gruszka, G., Chmura, M., Ples, M., Gzik, M., & Jurkoj´c, J. (2023). Influence of Induced Environment Oscillations on Limits of Stability in Healthy Adults. https://doi.org/https://doi.org/10.3390/app131810331

Xu, Q. A., Chang, V., & Jayne, C. (2022). A systematic review of social media-based sentiment analysis : Emerging trends and challenges. Decision Analytics Journal, 3(May), 100073. https://doi.org/10.1016/j.dajour.2022.100073

Yuswira, J. D., & Ginting, J. A. (2026). Analisis Sentimen Dan Social Network Analysis Pada Isu Makanan Bergizi Gratis Di X/Twitter Menggunakan Indobert. 10(1), 1259–1265. https://doi.org/https://doi.org/10.36040/jati.v10i1.16948