



Analisis Sentimen Program Makan Bergizi Gratis pada Media Sosial X Menggunakan Metode Naïve Bayes

Friska Andriani^{1*}, Wilda Rina Hasibuan²

^{1*,2}Program Studi Sistem Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia

Email: ^{1*}friskaandriani04@gmail.com, ²wildarina@umsu.ac.id

Abstrk

Program Makan Bergizi Gratis (MBG) yang dimulai pada 6 Januari 2025 memicu beragam tanggapan publik di media sosial X sehingga diperlukan cara yang efisien untuk memantau opini masyarakat. Penelitian ini bertujuan menganalisis kecenderungan sentimen publik terhadap program MBG dan mengukur kinerja algoritma Multinomial Naïve Bayes berbasis Natural Language Processing (NLP). Data berupa 9.792 tweet berbahasa Indonesia periode 6 Januari–6 Oktober 2025 dari dataset publik Kaggle. Tahapan penelitian meliputi text preprocessing (case folding, cleaning, tokenizing, stopword removal, dan stemming), pelabelan sentimen berbasis leksikon, pembobotan TF-IDF, pembagian data latih dan uji 80:20 secara berstrata, klasifikasi, dan evaluasi menggunakan confusion matrix. Pelabelan menghasilkan sentimen positif 53,0%, netral 39,7%, dan negatif 7,3%, dengan proporsi positif tertinggi pada awal periode. Model mencapai akurasi 79,02%, presisi 79,71%, recall 79,02%, dan F1-score 77,06% (rata-rata berbobot). Namun, F1-score rata-rata makro hanya 60,25% karena recall kelas negatif rendah (10,56%) akibat ketidakseimbangan kelas, dan sebagian besar tweet negatif diprediksi sebagai netral. Hasil klasifikasi diintegrasikan ke dalam dashboard web "SiAnSen MBG" yang lolos pengujian black box. Karena label dihasilkan otomatis oleh leksikon tanpa validasi manusia, akurasi mencerminkan kesesuaian model dengan aturan pelabelan sehingga temuan perlu ditafsirkan secara hati-hati.

Kata Kunci: analisis sentimen, makan bergizi gratis, Naïve Bayes, natural language processing, media sosial X.

PENDAHULUAN

Media sosial telah menjadi kanal utama bagi masyarakat untuk menyampaikan opini dan reaksi terhadap kebijakan pemerintah (Sulistyo dan Setiadi, 2025). Platform X (sebelumnya Twitter) menghasilkan teks dalam jumlah besar yang tidak terstruktur dan sarat bahasa informal sehingga penelaahan secara manual tidak efektif. Analisis sentimen membantu mengklasifikasikan opini menjadi kategori positif, negatif, dan netral secara otomatis (Bisono dan Zulherry, 2025; Wankhade dkk., 2022). Natural Language Processing (NLP), yaitu cabang kecerdasan buatan yang mempelajari interaksi komputer dengan bahasa manusia (Mubarak dan Tanjung, 2024), menyiapkan teks mentah agar dapat diolah algoritma pembelajaran mesin.

Program Makan Bergizi Gratis (MBG) dimulai serentak pada 6 Januari 2025 dengan sasaran balita, anak sekolah, santri, ibu hamil, dan ibu menyusui (Bisnis.com, 2025). Skala program yang besar memunculkan respons publik yang beragam. Pemberitaan tentang kasus keracunan pangan yang berulang di sejumlah daerah, misalnya, menimbulkan sorotan terhadap tata kelola keamanan pangan program (Sagita, 2025). Kondisi ini menuntut cara yang efisien untuk memantau opini publik secara berkelanjutan.

Sejumlah penelitian telah menerapkan Naïve Bayes pada wacana program makan gratis di X. Pada masa kampanye 2024, Nursinggah dkk. (2024), Sitanggang dkk. (2024), serta Saputra dan Hasan (2024) menganalisis opini terhadap program makan siang gratis. Setelah program berjalan, Siregar dkk. (2025) mengklasifikasikan tweet ke tiga kelas dan memperoleh akurasi 65% dengan sentimen negatif dominan, sedangkan Tsabitah dkk. (2025) melaporkan akurasi 89,93% pada 656 ulasan dengan 89,9% bernada positif. Laia dkk. (2025) memperoleh akurasi 86,46% pada 3.600 tweet dua kelas yang dilabeli dengan IndoBERT. Sakina dkk. (2025) memperoleh akurasi rata-rata 79,61% untuk Naïve Bayes, lebih tinggi daripada KNN (72,27%), pada 6.322 tweet setelah kelas netral dihapus. Sulistyo dan Setiadi (2025) menemukan 68,6% dari 12.389 tweet bernada negatif dengan pelabelan hibrida leksikon–IndoBERT, sedangkan Hidayat dan Ratnaningsih (2025) membandingkan Random Forest dan Naïve Bayes. Rentang


akurasi (65%–89,93%) dan dominasi sentimen yang berbeda-beda menunjukkan bahwa hasil sangat dipengaruhi oleh periode data, jumlah kelas, dan cara pelabelan.

Sepengetahuan penulis, masih terbatas kajian yang secara bersamaan (i) menelaah dinamika sentimen bulanan selama sepuluh bulan pertama pelaksanaan MBG, (ii) melaporkan kinerja per kelas sehingga kegagalan pada kelas minoritas tidak tertutup oleh rata-rata berbobot, dan (iii) menyajikan hasilnya pada dashboard web untuk pemantauan. Kebaruan artikel ini terletak pada kombinasi ketiga aspek tersebut pada 9.792 tweet periode 6 Januari–6 Oktober 2025. Permasalahan yang dijawab adalah bagaimana kecenderungan sentimen publik terhadap MBG di X, seberapa baik Naïve Bayes berbasis NLP mengklasifikasikannya ke kelas positif, negatif, dan netral, serta bagaimana hasilnya dapat disajikan secara interaktif. Tujuan penelitian ini adalah (1) menganalisis kecenderungan sentimen publik terhadap program MBG, (2) menerapkan Naïve Bayes berbasis NLP untuk klasifikasi sentimen, dan (3) mengukur kinerjanya menggunakan akurasi, presisi, recall, dan F1-score.

METODE

Desain Penelitian

Penelitian ini merupakan penelitian kuantitatif terapan yang mengikuti alur Knowledge Discovery in Databases, yaitu data selection, preprocessing, transformation, data mining, dan evaluation. Seluruh pengolahan data menggunakan Python 3 pada Google Colaboratory dengan pustaka pandas, scikit-learn, NLTK, Sastrawi, matplotlib, dan seaborn. Hasilnya kemudian diintegrasikan ke sistem web (Gambar 1).



Gambar 1. Alur penelitian

Sumber dan Karakteristik Data

Data yang digunakan adalah data sekunder berupa dataset publik "MBG 06 Januari – 06 Oktober 2025" di Kaggle yang disusun oleh Ravhi Haris Wibowo (Wibowo, 2025). Dataset ini dikumpulkan menggunakan Tweet Harvest dan memuat 9.792 tweet berbahasa Indonesia dengan 15 atribut, antara lain id_str, created_at, full_text, favorite_count, retweet_count, dan lang. Penelitian ini tidak melakukan pengambilan data (scraping) sendiri. Atribut full_text menjadi objek analisis, sedangkan created_at digunakan untuk analisis tren bulanan. Pemeriksaan awal tidak menemukan nilai kosong maupun duplikasi pada full_text sehingga seluruh baris digunakan. Analisis dilakukan pada tingkat agregat dan identitas akun tidak dianalisis maupun dilaporkan. Contoh data disajikan pada Tabel 1.

Tabel 1. Contoh data tweet

No	Isi tweet
1	Dengan MBG UMKM besar suara agar anak-anak mendapatkan manfaat seutuhnya #UMKMDukungMBG
2	Kalau Program MBG Gagal Artinya Proyeksi Bonus Demografi Juga Ikut Gagal!
3	Menteri Pendidikan Dasar dan Menengah (Mendikdasmen) Abdul Mu'ti berkata program Makan Bergizi Gratis (MBG) adalah bagian dari upaya memperkuat pendidikan karakter
4	Respons Siswa SMA di Semarang soal Program Makan Bergizi Gratis: Enak Porsinya Juga Cukup
5	Program Makan Bergizi Gratis Ibu Hamil Dimulai 20 Januari 2025

Text Preprocessing (NLP)

Teks mentah diproses melalui lima tahap berurutan (Tabel 2) yang lazim dipakai pada analisis sentimen tweet berbahasa Indonesia (Laia dkk., 2025). Seluruh tahap dibungkus dalam satu fungsi yang diterapkan pada setiap tweet, dan hasilnya disimpan pada kolom teks_bersih.

Tabel 2. Tahapan text preprocessing

Tahap	Proses	Contoh
Case folding	Mengubah seluruh huruf menjadi huruf kecil	"MBG" → "mbg"
Cleaning	Menghapus URL, mention, hashtag, angka, dan tanda baca dengan ekspresi reguler	–
Tokenizing	Memecah teks menjadi token kata	–
Stopword removal	Menghapus kata henti Bahasa Indonesia (NLTK) yang diperkaya kosakata informal	"yang", "dan", "di", "yg", "gak", "udah", "tp"
Stemming	Mengembalikan kata ke bentuk dasar dengan Sastrawi	"membantu", "terbantu", "bantuan" → "bantu"

Pelabelan Sentimen

Dataset belum memiliki label sehingga pelabelan dilakukan otomatis dengan pendekatan berbasis leksikon, yaitu mencocokkan teks dengan kamus kata positif dan kamus kata negatif Bahasa Indonesia yang disusun sesuai konteks program MBG. Skor positif dan skor negatif dihitung dari jumlah entri kamus yang muncul pada teks tweet (huruf kecil). Tweet berlabel Positif jika skor positif lebih besar daripada skor negatif, Negatif jika sebaliknya, dan Netral jika kedua skor sama besar, termasuk tweet yang tidak memuat kata sentimen pada kamus. Label kategorikal digunakan langsung sebagai variabel target sehingga tidak diperlukan encoding tambahan.

Pembobotan TF-IDF dan Pembagian Data

Teks hasil praproses diubah menjadi vektor numerik dengan TF-IDF (Persamaan 1) menggunakan $\text{max_features} = 1.000$, $\text{ngram_range} = (1,2)$, $\text{min_df} = 2$, dan $\text{sublinear_tf} = \text{True}$ ($\text{tf}' = 1 + \log \text{tf}$). Parameter N adalah jumlah dokumen dan $\text{df}(t)$ adalah jumlah dokumen yang memuat term t . Implementasi scikit-learn memakai varian IDF dengan smoothing dan normalisasi L2 secara bawaan.

$$w(t,d) = \text{tf}'(t,d) \times \log (N / \text{df}(t)) \quad (1)$$

Matriks TF-IDF dibagi menjadi data latihan 80% dan data uji 20% menggunakan `train_test_split` dengan `stratify = label` dan `random_state = 42` agar proporsi kelas terjaga dan hasil dapat direproduksi.

Klasifikasi Naïve Bayes

Klasifikasi menggunakan Multinomial Naïve Bayes dengan $\alpha = 1,0$ (Laplace smoothing). Berdasarkan Teorema Bayes, peluang kelas c untuk dokumen d dinyatakan pada Persamaan (2). Dengan asumsi independensi antarfitur, kelas prediksi adalah kelas dengan skor log-posterior tertinggi (Persamaan 3). N_{tc} adalah jumlah bobot term t pada kelas c , N_c adalah total bobot seluruh term pada kelas c , dan $|V|$ adalah ukuran kosakata (1.000 fitur).

$$P(c|d) = P(d|c) \times P(c) / P(d) \quad (2)$$

$$\hat{c} = \text{argmax}_c [\log P(c) + \sum_t x_t \log P(t|c)], P(t|c) = (N_{tc} + \alpha) / (N_c + \alpha|V|) \quad (3)$$

Evaluasi Kinerja

Kinerja dievaluasi pada data uji menggunakan confusion matrix serta metrik akurasi, presisi, recall, dan F1-score (Kusuma dan Cahyono, 2023):

$$\text{Akurasi} = (TP + TN) / (TP + TN + FP + FN) \quad (4)$$

$$\text{Presisi} = \text{TP} / (\text{TP} + \text{FP}) \quad (5)$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (6)$$

$$\text{F1-score} = 2 \times (\text{Presisi} \times \text{Recall}) / (\text{Presisi} + \text{Recall}) \quad (7)$$

Untuk tiga kelas, presisi, recall, dan F1-score dihitung per kelas (one-vs-rest) lalu dirata-ratakan secara berbobot berdasarkan jumlah data setiap kelas. Rata-rata makro juga dilaporkan untuk menilai keseimbangan antarkelas. Model yang telah dilatih juga memprediksi ulang seluruh dataset beserta skor keyakinan (probabilitas tertinggi) hanya untuk keperluan tampilan pada dashboard, bukan untuk pengukuran kinerja.

Pengembangan dan Pengujian Sistem Web

Hasil pengolahan diekspor ke berkas CSV dan JSON, lalu diimpor ke sistem web "SiAnSen MBG" yang dibangun dengan PHP 8.1, MySQL 8.0 (XAMPP), Tailwind CSS, Chart.js, dan SweetAlert2. Basis data terdiri atas tabel tweets, hasil_klasifikasi, user, dan import_log. Fungsi sistem diuji dengan black box testing pada 14 skenario.

HASIL DAN PEMBAHASAN

Karakteristik Data dan Hasil Praproses

Seluruh 9.792 tweet lolos pemeriksaan kualitas awal. Setelah praproses dan pembobotan TF-IDF, diperoleh matriks fitur berukuran 9.792 dokumen $\times$ 1.000 fitur yang menjadi masukan model. Tabel 1 menunjukkan bahwa data memuat opini pengguna, kutipan pernyataan pejabat, dan judul berita, yang berpengaruh pada interpretasi kelas netral di bawah.


Distribusi Sentimen

Pelabelan leksikon menghasilkan 5.191 tweet positif (53,0%), 3.891 netral (39,7%), dan 710 negatif (7,3%) (Tabel 3, Gambar 2). Rasio positif terhadap negatif sekitar 7,3 : 1, menandakan ketidakseimbangan kelas yang nyata. Kelas netral pada pendekatan ini mencakup tweet informatif seperti kutipan pernyataan pejabat dan judul berita serta tweet tanpa kata sentimen pada kamus. Karena itu, kelas ini tidak dapat ditafsirkan sebagai sikap "menunggu" publik.

Tabel 3. Distribusi label sentimen dan pembagian data

Kelas	Jumlah	Persentase	Data latih	Data uji
Positif	5.191	53,0%	4.152	1.039
Netral	3.891	39,7%	3.113	778
Negatif	710	7,3%	568	142
Total	9.792	100%	7.833	1.959


Analisis Sentimen Program Makan Bergizi Gratis (MBG) di Media Sosial X



Gambar 2. Distribusi sentimen program MBG

Tren Sentimen Bulanan

Gambar 3 menunjukkan bahwa proporsi sentimen positif tertinggi terjadi pada Januari 2025, lalu turun pada bulan-bulan berikutnya seiring meningkatnya proporsi netral. Sentimen negatif tetap berjumlah kecil sepanjang periode. Jumlah tweet Oktober 2025 rendah karena dataset hanya mencakup hingga 6 Oktober. Tingginya proporsi positif di awal periode dapat dikaitkan dengan banyaknya konten peluncuran dan dukungan, tetapi penelitian ini tidak menguji hubungan sebab-akibat.



Gambar 3. Tren sentimen program MBG per bulan (Januari–Oktober 2025)

Kinerja Klasifikasi


Model Naïve Bayes memperoleh akurasi 79,02%, presisi 79,71%, recall 79,02%, dan F1-score 77,06% (rata-rata berbobot). Sebagai pembandingan, memprediksi seluruh data uji sebagai kelas mayoritas (positif) hanya menghasilkan akurasi 53,04% (1.039/1.959), sehingga model meningkatkan akurasi sekitar 26 poin persentase. Namun, kinerja antarkelas sangat timpang (Tabel 4, Gambar 4).

Tabel 4. Kinerja model per kelas pada data uji (%)

Kelas	Presisi	Recall	F1-score	Jumlah data uji
Positif	83,52	87,78	85,59	1.039
Netral	73,06	79,82	76,29	778
Negatif	88,24	10,56	18,87	142
Rata-rata makro	81,61	59,39	60,25	1.959
Rata-rata berbobot	79,71	79,02	77,06	1.959

Catatan: nilai per kelas dihitung dari confusion matrix pada Gambar 4.

**Confusion Matrix – Model Naïve Bayes
 Analisis Sentimen MBG**



Gambar 4. Confusion matrix model Naïve Bayes

Dari 142 tweet negatif, hanya 15 yang diprediksi benar, 103 diprediksi netral, dan 24 diprediksi positif. Model hanya memprediksi kelas negatif sebanyak 17 kali (15 di antaranya benar) sehingga presisinya tinggi tetapi recall-nya rendah. Kelas negatif hanya 7,2% dari data uji, tetapi menyumbang 127 dari 411 kesalahan (30,9%). Kekeliruan terbanyak lainnya terjadi antara kelas positif dan netral (126 dan 156 tweet).

Pembahasan

Nilai rata-rata berbobot tampak baik karena didominasi kelas positif dan netral. F1-score makro sebesar 60,25% dan recall negatif 10,56% menunjukkan bahwa model belum andal mendeteksi opini negatif, padahal opini kritis paling relevan untuk evaluasi kebijakan. Pola serupa dilaporkan Tsabitah dkk. (2025), yang mencatat akurasi kelas negatif dan netral masih perlu ditingkatkan pada data yang didominasi

sentimen positif. Beberapa faktor dapat menjelaskan hasil ini. Pertama, prior kelas dan jumlah data latih negatif yang kecil (568 tweet) membuat Naïve Bayes cenderung memilih kelas mayoritas. Kedua, ekspresi negatif sering implisit, berupa sarkasme atau frasa bernegasi. Kamus negatif memuat frasa seperti "tidak layak" dan "tidak adil", dan jika kata "tidak" termasuk daftar stopword, frasa tersebut kehilangan sinyal polaritasnya pada tahap praproses. Ketiga, label dibentuk dari teks asli, sedangkan model dilatih pada teks hasil stemming dengan hanya 1.000 fitur sehingga model tidak dapat sepenuhnya mereproduksi aturan leksikon. Penyeimbangan data seperti SMOTE telah digunakan pada studi MBG lain (Sulistyo dan Setiadi, 2025), dan penanganan ketidakseimbangan kelas terbukti penting pada analisis sentimen (Habbat dkk., 2023). Pendekatan tersebut layak diuji pada penelitian lanjutan.

Dominasi sentimen positif (53,0%) sejalan dengan temuan Tsabitah dkk. (2025) dan Sakina dkk. (2025) yang mendapati opini positif lebih banyak daripada negatif. Hasil ini berbeda dengan Siregar dkk. (2025) dan Sulistyo dan Setiadi (2025) yang menemukan sentimen negatif dominan (Tabel 5). Perbedaan ini menegaskan bahwa distribusi sentimen bergantung pada periode pengumpulan data, kata kunci, komposisi akun dan konten, serta metode pelabelan, sehingga angka 53,0% tidak boleh dibaca sebagai proporsi dukungan seluruh masyarakat.

Tabel 5. Perbandingan dengan penelitian terdahulu tentang sentimen program makan gratis

Penelitian	Data	Kelas	Metode dan pelabelan	Hasil utama
Siregar dkk. (2025)	Tweet (Twitter API)	3	Naïve Bayes, TF-IDF	Akurasi 65%, F1 62%; negatif dominan
Tsabitah dkk. (2025)	656 ulasan (Kaggle)	3	Naïve Bayes, TF-IDF	Akurasi 89,93%, F1 86,42%; positif 89,9%
Laia dkk. (2025)	3.600 tweet	2	Naïve Bayes; label IndoBERT	Akurasi 86,46%, F1 90,77%
Sakina dkk. (2025)	9.723 tweet (6.322 setelah netral dihapus)	2	Naïve Bayes vs KNN	Naïve Bayes: akurasi 79,61%, F1 77,33%; KNN: akurasi 72,27%
Sulistyo dan Setiadi (2025)	12.389 tweet	3	Random Forest, XGBoost, Ensemble; label hibrida; SMOTE	F1 0,9363 (uji); negatif 68,6%
Penelitian ini	9.792 tweet	3	Naïve Bayes; label leksikon	Akurasi 79,02%, F1 berbobot 77,06%, F1 makro 60,25%; positif 53,0%

Perbandingan pada Tabel 5 tidak sepenuhnya setara karena jumlah kelas, data, dan cara pelabelan berbeda. Misalnya, akurasi Sakina dkk. (2025) dihitung pada dua kelas setelah kelas netral dihapus, sedangkan penelitian ini mempertahankan tiga kelas. Untuk menjaga keterbandingan, Tabel 5 memuat hanya studi yang metadata dan angka utamanya dapat diverifikasi pada abstrak publikasi.

Implementasi Sistem "SiAnSen MBG"

Sistem memiliki halaman landing, login, dashboard, dataset tweet (pencarian kata kunci, filter bahasa, dan pagination), preprocessing (alur dan contoh sebelum–sesudah), hasil sentimen (filter kategori dan skor keyakinan), evaluasi model (metrik keseluruhan dan per kelas, confusion matrix, dan grafik perbandingan), serta impor data (CSV, JSON, dan gambar grafik) (Gambar 5). Pengujian black box terhadap 14 skenario, yaitu login benar, salah, dan kosong, logout, dashboard, pencarian, filter, pagination, impor CSV dan JSON valid maupun berformat salah, akses tanpa login, dan grafik evaluasi, seluruhnya sesuai harapan. Perancangan yang berangkat dari analisis kebutuhan dan arsitektur yang terstruktur merupakan prinsip penting dalam pengembangan sistem informasi (Rinaldi, 2024). Pengujian ini hanya menilai kesesuaian fungsi, bukan kegunaan (usability) maupun kinerja pada beban besar, dan pembaruan data masih dilakukan manual melalui impor berkas.



Gambar 5. Tampilan dashboard sistem "SiAnSen MBG"

Keterbatasan

Pertama, label dihasilkan otomatis oleh leksikon tanpa validasi anotator manusia sehingga akurasi mengukur kesesuaian model dengan aturan leksikon, bukan dengan sentimen sebenarnya. Kualitas kamus dan ketidakmampuan menangkap sarkasme turut memengaruhi label. Kedua, data berasal dari satu dataset sekunder pada satu platform dan tidak mengendalikan akun institusi, konten berita, atau akun otomatis, serta pengguna X tidak mewakili seluruh masyarakat. Ketiga, evaluasi memakai satu kali pembagian data tanpa validasi silang, tanpa penyetelan parameter selain nilai bawaan, dan tanpa pembandingan algoritma lain. Keempat, penelitian ini tidak menganalisis isi tweet negatif (misalnya topik atau aspek yang dikritik). Kelima, sistem belum memproses data secara real-time.

KESIMPULAN

Penelitian ini menganalisis 9.792 tweet tentang program MBG periode 6 Januari–6 Oktober 2025. Berdasarkan pelabelan leksikon, sentimen didominasi positif (53,0%), diikuti netral (39,7%) dan negatif (7,3%), dengan proporsi positif tertinggi pada awal periode. Naïve Bayes berbasis NLP (TF-IDF, $\alpha = 1,0$) menghasilkan akurasi 79,02%, presisi 79,71%, recall 79,02%, dan F1-score berbobot 77,06%. Namun, F1-score makro hanya 60,25% dan recall kelas negatif 10,56%, sehingga model cukup efektif untuk kelas mayoritas tetapi belum andal mendeteksi opini negatif. Hasil terintegrasi ke dalam dashboard web "SiAnSen MBG" yang lulus pengujian black box. Karena label bersifat otomatis dan belum divalidasi manusia, kesimpulan tentang sentimen publik bersifat indikatif.

Saran untuk penelitian selanjutnya adalah (1) memvalidasi label melalui anotasi manual pada sampel atau pendekatan hibrida leksikon–IndoBERT, (2) menangani ketidakseimbangan kelas dengan SMOTE, undersampling, atau pembobotan kelas serta melaporkan metrik makro, (3) menangani negasi dan menormalkan kata tidak baku pada praproses, (4) menganalisis topik atau aspek pada tweet negatif, (5) memperluas data ke platform lain dan bahasa daerah, dan (6) membangun API (misalnya Flask atau FastAPI) agar pembaruan data berjalan otomatis.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Ravhi Haris Wibowo atas penyediaan dataset publik di Kaggle dan kepada Program Studi Sistem Informasi FIKTI Universitas Muhammadiyah Sumatera Utara atas dukungan akademik.

DAFTAR PUSTAKA

- Bisnis.com. (2025, 6 Januari). *Simak, 6 fakta program Makan Bergizi Gratis yang dimulai hari ini*. <https://ekonomi.bisnis.com/read/20250106/12/1829041/simak-6-fakta-program-makan-bergizi-gratis-yang-dimulai-hari-ini>
- Bisono, A. T., & Zulherry, A. (2025). Analisis sentimen game Genshin Impact untuk mengetahui reaksi dan harapan pemain menggunakan metode Naïve Bayes. *Sudo Jurnal Teknik Informatika*, 4(2), 183–193. <https://doi.org/10.56211/sudo.v4i2.1131>
- Habbat, N., Nouri, H., Anoun, H., & Hassouni, L. (2023). Sentiment analysis of imbalanced datasets using BERT and ensemble stacking for deep learning. *Engineering Applications of Artificial Intelligence*, 126, 106999. <https://doi.org/10.1016/j.engappai.2023.106999>
- Hidayat, R., & Ratnaningsih, D. J. (2025). Analisis sentimen program makanan bergizi gratis menggunakan algoritma Random Forest dan Naive Bayes. *Journal of Computing and Informatics Research*, 5(1), 395–400. <https://doi.org/10.47065/comforch.v5i1.2355>
- Kusuma, I. H., & Cahyono, N. (2023). Analisis sentimen masyarakat terhadap penggunaan e-commerce menggunakan algoritma K-Nearest Neighbor. *Jurnal Informatika: Jurnal Pengembangan IT*, 8(3), 302–307. <https://doi.org/10.30591/jpit.v8i3.5734>
- Laia, M. M., Hasan, F. N., & Kuntoro, A. Y. (2025). Analisis sentimen program makan gratis pada platform X menggunakan algoritma Naïve Bayes. *Jurnal Ilmiah Informatika*, 13(2), 258–264. <https://doi.org/10.33884/jif.v13i02.10427>
- Mubarok, M. I., & Tanjung, M. A. P. (2024). Implementasi natural language processing dalam perancangan aplikasi chatbot pada FIKTI UMSU. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(6), 11992–12001. <https://doi.org/10.36040/jati.v8i6.11713>
- Nursinggah, L., Ruuhwan, R., & Mufizar, T. (2024). Analisis sentimen pengguna aplikasi X terhadap program makan siang gratis dengan metode Naïve Bayes classifier. *Jurnal Informatika dan Teknik Elektro Terapan*, 12(3). <https://doi.org/10.23960/jitet.v12i3.4336>
- Rinaldi, R. (2024). Penerapan TOGAF ADM dalam pengembangan smart campus: Tinjauan literatur tentang enterprise architecture. *Indonesian Journal of Multidisciplinary Scientific Studies*, 2(2), 160–166. <https://doi.org/10.33151/ijomss.v2i2.207>
- Sagita, N. S. K. (2025, 26 September). Sengkarut masalah di balik ribuan anak keracunan makanan bergizi gratis. *detikHealth*. <https://health.detik.com/berita-detikhealth/d-8131091/sengkarut-masalah-di-balik-ribuan-anak-keracunan-makanan-bergizi-gratis>
- Sakina, N., Wajidi, F., & Rasyid, M. R. (2025). Evaluasi algoritma KNN dan Naive Bayes untuk analisis sentimen kebijakan Program Makan Bergizi Gratis. *Jambura Journal of Informatics*, 7(2), 83–97. <https://doi.org/10.37905/jji.v1i2.34418>
- Saputra, R., & Hasan, F. N. (2024). Analisis sentimen terhadap program makan siang & susu gratis menggunakan algoritma Naive Bayes. *Jurnal Teknologi dan Sistem Informasi Bisnis*, 6(3), 411–419. <https://doi.org/10.47233/jteksis.v6i3.1378>
- Siregar, R. A. B., Manik, A. R., Syahri, A., Akbar, M. B., Arnita, & Ramadhani, F. (2025). Penerapan Naïve Bayes untuk analisis sentimen netizen terhadap program makan siang gratis pada media sosial X. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(4), 5621–5628. <https://doi.org/10.36040/jati.v9i4.13870>
- Sitanggang, A., Umaidah, Y., & Adam, R. I. (2024). Analisis sentimen masyarakat terhadap program makan siang gratis pada media sosial X menggunakan algoritma Naïve Bayes. *Jurnal Informatika dan Teknik Elektro Terapan*, 12(3), 2755–2762. <https://doi.org/10.23960/jitet.v12i3.4902>
- Sulistyo, D. A., & Setiadi, E. (2025). Analisis sentimen kebijakan makan bergizi gratis menggunakan IndoBERT dan machine learning. *Jurnal FASILKOM*, 15(3). <https://doi.org/10.37859/jf.v15i3.10546>
- Tsabitah, L., Karima, D. A., Munaspin, Z. D. P., Titiana, N. M., & Fathoni. (2025). Analisis sentimen program makan siang gratis dalam mendukung SDGs menggunakan Naïve Bayes. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(4), 6288–6294. <https://doi.org/10.36040/jati.v9i4.14060>
- Wankhade, M., Rao, A. C. S., & Kulkarni, C. (2022). A survey on sentiment analysis methods, applications, and challenges. *Artificial Intelligence Review*, 55(7), 5731–5780. <https://doi.org/10.1007/s10462-022-10144-1>
- Wibowo, R. H. (2025). *MBG 06 Januari – 06 Oktober 2025* [Data set]. Kaggle. <https://www.kaggle.com/datasets/ravhihz/mbg-06-januari-06-oktober-2025>