



Comparing Naive Bayes and Support Vector Machine for Sentiment Analysis of Government Policy on Free Nutritious Meals

Komparasi Naive Bayes dan Support Vector Machine untuk Analisis Sentimen Kebijakan Pemerintah Mengenai Makan Bergizi Gratis

Sri Mulyani^{1*}, Siti Mutmainah², Hilyatul Mustafidah³

^{1,2,3}Program Studi Ilmu Komputer, Fakultas Teknik dan Ilmu Komputer,
Universitas Muhammadiyah Bima, Indonesia

Email: ¹srimulyaniruslin25@mail.com,

²siti.mutmainah.id19@gmail.com, ³hilyatulfida15@gmail.com

Received Jun 08th 2026; Revised Jul 02nd 2026; Accepted Aug 10th 2026; Available Online Aug 15th 2026

Corresponding Author: Sri Mulyani

Copyright © 2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstrak

The Indonesian government's Free Nutritious Meals (MBG) policy has sparked widespread public debate on the TikTok platform. This study aims to classify public sentiment toward the MBG policy into positive and negative classes by comparing Multinomial Naive Bayes and Support Vector Machine (SVM) algorithms using Count Vectorizer feature extraction. A dataset of 4,000 comments was collected through Apify from four official national news accounts. Initial labeling was performed automatically using the InSet Lexicon and manually validated by human annotators as a gold standard to reduce bias in interpreting informal words. The labeling results showed a predominance of positive sentiment at 89.60% and negative sentiment at 10.40%. Testing with an 80:20 data-splitting ratio demonstrated that the linear-kernel SVM achieved the highest accuracy of 99.12%, while Naive Bayes achieved 91.62%. Cross-scenario testing showed that Naive Bayes was more vulnerable to performance degradation, with its lowest accuracy reaching 72.70% under the undersampling and three-class scenarios, whereas SVM remained stable above 95%. WordCloud analysis indicated that positive sentiment was dominated by optimism toward the government, while negative sentiment highlighted concerns regarding budget corruption. The main limitations include difficulties in understanding contextual meanings, informal language, and sarcasm. Overall, the findings demonstrate that SVM is more effective and stable for sentiment classification of imbalanced TikTok text, maintaining consistent performance across various testing scenarios.

Keywords: Accuracy, Count Vectorizer, Free Nutritious Meals, Naive Bayes, Support Vector Machine

Abstrak

Kebijakan Program Makan Bergizi Gratis (MBG) pemerintah memicu perdebatan publik di platform TikTok. Penelitian ini bertujuan mengklasifikasikan sentimen opini publik terhadap kebijakan MBG ke dalam kelas positif dan negatif dengan membandingkan algoritma *Multinomial Naive Bayes* dan *Support Vector Machine* (SVM) menggunakan ekstraksi fitur *CountVectorizer*. Dataset sebanyak 4.000 komentar dikumpulkan melalui Apify dari empat akun berita resmi nasional. Pelabelan awal dilakukan secara otomatis menggunakan *InSet Lexicon* dan divalidasi secara manual oleh anotator manusia sebagai *gold standard* untuk mengurangi bias makna kata informal. Hasil pelabelan menunjukkan dominasi sentimen positif sebesar 89,60% dan negatif sebesar 10,40%. Pengujian dengan rasio *split data* 80:20 menunjukkan bahwa SVM *kernel* linear menghasilkan akurasi tertinggi sebesar 99,12%, sedangkan *Naive Bayes* mencapai 91,62%. Pengujian lintas skenario menunjukkan *Naive Bayes* lebih rentan terhadap penurunan kinerja, dengan akurasi terendah 72,70% pada skenario *undersampling* dan tiga kelas, sementara SVM tetap stabil di atas 95%. Analisis *WordCloud* menunjukkan sentimen positif didominasi optimisme terhadap pemerintah, sedangkan sentimen negatif menyoroti risiko korupsi anggaran. Keterbatasan penelitian meliputi kesulitan model memahami konteks kalimat, kata informal, dan sarkasme. Hasil penelitian menunjukkan bahwa SVM lebih efektif dan stabil untuk klasifikasi sentimen teks TikTok yang tidak seimbang, memberikan kinerja konsisten pada berbagai skenario pengujian.

Kata Kunci: Accuracy, Count Vectorizer, Makan Bergizi Gratis, Naive Bayes, Support Vector Machine

1. PENDAHULUAN

Kebijakan Program Bantuan Makan Bergizi Gratis (MBG) yang diusung oleh pemerintah Indonesia memicu dinamika opini pro dan kontra yang sangat masif di tengah masyarakat. Sebagian masyarakat menyambutnya sebagai langkah positif dalam pemenuhan gizi anak-anak sekolah dan kelompok rentan, namun tidak sedikit pula yang meragukan efektivitas dan kesiapan implementasi program tersebut, terutama dari sisi anggaran dan distribusi [1]. Kekhawatiran publik mengenai ketepatan regulasi dan potensi pemangkasan sektor prioritas lain menjadi isu hangat yang banyak diperdebatkan melalui kolom komentar di media sosial [2]. Selain itu, program MBG ini dinilai strategis sebagai intervensi nyata untuk menekan angka prevalensi stunting nasional. Berdasarkan hasil Survei Status Gizi Indonesia (SSGI) 2022, prevalensi stunting mencapai 21,6%, sehingga memerlukan langkah taktis berkelanjutan [3]. Di era digital, media sosial seperti TikTok telah menjadi saluran utama bagi jutaan netizen Indonesia untuk menyuarakan pendapatnya secara *real-time* [1]. Berdasarkan data statistik, TikTok di Indonesia memiliki jangkauan yang sangat masif hingga menyentuh 126,83 juta pengguna. Hal ini menjadikan Indonesia sebagai negara dengan jumlah pengguna TikTok terbesar kedua di dunia [4].

Tantangan utama dalam melakukan pengolahan data opini dari media sosial adalah karakteristik teks ulasan yang berdimensi tinggi, tidak baku, dan memiliki tingkat ketidakseimbangan kelas (*class imbalance*) yang ekstrem [5]. Oleh karena itu, diperlukan pendekatan analisis berbasis komputasi data sains dan *text mining* untuk memetakan polaritas sentimen publik secara objektif. Teknik ini banyak diterapkan pada data media sosial yang jumlahnya besar sehingga sulit dianalisis secara manual [6]. Penelitian terdahulu menunjukkan bahwa algoritma probabilistik klasik seperti *Naïve Bayes* memiliki efisiensi tinggi serta mudah diimplementasikan dalam klasifikasi teks ulasan media sosial [7]. Namun, karakteristik teks ulasan media sosial yang memiliki dimensi fitur tinggi memerlukan metode klasifikasi yang lebih andal. Oleh karena itu, penelitian ini mengintegrasikan *Support Vector Machine* (SVM) sebagai algoritma komparasi karena keunggulannya dalam menangani data berdimensi tinggi (*high-dimensional space*) melalui pencarian batas pemisah (*hyperplane*) optimal guna meminimalkan kesalahan klasifikasi pada sebaran teks opini yang kompleks [8].


Penelitian ini bertujuan untuk melakukan analisis komparasi paralel antara algoritma *Multinomial Naïve Bayes* dan SVM dengan memanfaatkan teknik ekstraksi fitur *CountVectorizer*. Kebijakan pemerintah yang dievaluasi dalam penelitian ini merujuk pada landasan hukum Peraturan Presiden (Perpres) Nomor 139 Tahun 2024 tentang Badan Gizi Nasional (BGN). Mengingat *dataset* mentah dari hasil *scraping* belum memiliki label, pendekatan berbasis leksikon (*lexicon-based*) diterapkan untuk otomatisasi pelabelan awal (*ground truth*) guna mengatasi keterbatasan pelabelan manual [9]. Implementasi model klasifikasi sentimen ini dikembangkan merujuk pada metodologi pemodelan terstruktur [10]. Eksperimen ini juga mengadopsi pendekatan komparasi algoritma [11]. Evaluasi model dilakukan untuk menguji stabilitas performa sistem melintasi berbagai variasi komposisi rasio pembagian data berdasarkan metodologi pengujian *split data* [12].

Beberapa penelitian terdahulu telah menerapkan teknik *data mining* untuk mengukur sentimen publik terhadap program Makan Bergizi Gratis (MBG). Metode SVM telah diterapkan pada platform Twitter [13] penelitian ini unggul karena menggunakan data *real-time*, namun memiliki kekurangan dalam menangani ekspresi sarkasme ulasan informal. Analisis multidimensional sentimen masyarakat terhadap MBG juga telah dilakukan pada media sosial X [1] kelebihanannya mampu memetakan topik makro, namun kekurangannya belum menyertakan perbandingan algoritma klasifikasi. Selanjutnya, studi komparasi paralel antara *Naïve Bayes* dan SVM telah dilakukan pada data X [5] [14] kedua studi ini sangat baik dalam menyajikan visualisasi perbandingan metrik kinerja secara paralel, tetapi memiliki keterbatasan karena membiarkan *dataset* berada dalam kondisi ketidakseimbangan kelas (*class imbalance*) ekstrem. Sementara itu, algoritma *Naïve Bayes* juga telah diterapkan untuk mengukur opini program makan siang gratis [15] penelitian tersebut memiliki keunggulan pada tahapan *preprocessing* teks yang terstruktur, tetapi memiliki kekurangan karena mengabaikan analisis performa pada kategori sentimen netral.

Posisi penelitian ini hadir secara spesifik untuk menutup celah (*gap*) dari kelima studi terdahulu tersebut dengan membawa kebaruan berupa analisis intervensi penyeimbangan data *Undersampling* lintas rasio pembagian data serta perluasan skenario pengujian biner dan multi-kelas (3 kelas) secara langsung pada data komentar TikTok pasca-polemik standarisasi Unit Satuan Pelayanan Pemenuhan Gizi. Evaluasi performa model diukur secara komprehensif menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* [16] berbasis *Confusion Matrix* [17]. Secara eksplisit, penelitian ini merumuskan tiga fokus permasalahan utama, yaitu: pertama, menilai efektivitas performa klasifikasi komparasi paralel antara algoritma *Multinomial Naïve Bayes* dan SVM berbasis *Count Vectorizer*; kedua, mengukur pengaruh intervensi teknik *Undersampling* terhadap stabilitas metrik kinerja melintasi variasi rasio pembagian data pada skenario biner dan multi-kelas; serta ketiga, memetakan kecenderungan tren topik kata kunci yang paling dominan muncul pada polaritas opini netizen melalui visualisasi *WordCloud*.

2. BAHAN DAN METODE

Metodologi dalam penelitian eksperimen komputasional ini disusun secara sistematis melalui beberapa tahapan utama. Guna menjamin validitas dan reproduksibilitas eksperimen, seluruh tahapan pemodelan komputasi *text mining* dalam penelitian ini diimplementasikan menggunakan bahasa pemrograman Python yang dieksekusi melalui platform Google Colab Cloud Environment. Infrastruktur pengujian didukung alokasi spesifikasi perangkat keras (*hardware*) berbasis *cloud computing* yang terintegrasi dengan lingkungan eksekusi sistem. Arsitektur klasifikasi dikembangkan menggunakan pustaka *scikit-learn* dengan menerapkan konfigurasi parameter model secara eksplisit tanpa melibatkan tahapan pencarian parameter optimal (*tuning hyperparameter*) tambahan. Algoritma utama Multinomial Naïve Bayes dijalankan menggunakan parameter *smoothing default* dengan nilai $\alpha=1.0$. Sementara itu, algoritma komparasi *Support Vector Machine* (SVM) dikonfigurasi secara linear memanfaatkan fungsi SVC dengan menetapkan parameter kernel='linear' dan nilai regularisasi bobot $C=1.0$ guna memaksimalkan batas jarak pemisah geometri (*hyperplane margin*) pada klasifikasi sentimen. Alur tahapan eksperimen penelitian secara menyeluruh digambarkan pada Gambar 1.



Gambar 1. Alur Penelitian

2.1. Pengumpulan dan Objek Dataset

Objek penelitian ini difokuskan pada komentar tertulis netizen Indonesia di platform TikTok mengenai Program MBG. Dataset diperoleh melalui teknik *purposive sampling* menggunakan layanan *Apify TikTok*

Comments Scraper. Data diambil secara proporsional dari 4 (empat) akun berita resmi nasional terverifikasi, yaitu BBC News Indonesia, Metro TV, tvOnenews, dan KompasTV dengan total sampel bersih sebanyak 4.000 komentar dalam format berkas .xlsx.

2.2. Prapemrosesan Data (*Preprocessing*)

Teks ulasan mentah dikondisikan terlebih dahulu melalui eksekusi kode Python di Google Colab menggunakan beberapa urutan tahapan sebagai berikut [18]:

1. *Data Cleaning*: Menghapus angka, simbol, tanda baca, emoji, dan URL.
2. *Case Folding*: Mengubah seluruh karakter huruf dalam teks menjadi huruf kecil (*lowercase*).
3. *Spelling Normalization*: Mentransformasi kata tidak baku dan singkatan khas TikTok menjadi kosakata baku EYD dengan memanfaatkan *slang dictionary*.
4. *Tokenization*: Memotong untaian kalimat komentar menjadi satuan token kata tunggal.
5. *Stopword Removal & Stemming*: Menghilangkan kata hubung fungsional yang tidak bermakna sentimen dan mengubah kata berimbuhan menjadi bentuk kata dasar, dibantu *library* Sastrawi.

2.3. Pelabelan Otomatis Berbasis Leksikon

Otomatisasi penentuan label awal (*ground truth*) menerapkan metode *Lexicon-Based Approach* menggunakan kamus *InSet Lexicon* bahasa Indonesia [9]. Aturan klasifikasi ditentukan berdasarkan akumulasi nilai skor polaritas kata dalam ulasan. Jika skor kalimat bernilai ≥ 0 , maka data otomatis dikelompokkan ke dalam kelas sentimen positif, dan jika skor < 0 , maka dikelompokkan ke dalam kelas sentimen negatif.

2.4. Ekstraksi Fitur dan Pembagian Data

Proses ekstraksi fitur mengubah data tekstual bersih menjadi matriks representasi numerik menggunakan metode *Count Vectorizer* yang menghitung frekuensi kemunculan kata utuh di setiap dokumen komentar [39]. Selanjutnya, data dialokasikan ke dalam data latih (*training*) dan data uji (*testing*) menggunakan konfigurasi pembagian rasio acak standar sebesar 80:20 [20].

2.5. Pemodelan Klasifikasi Komparasi

Data numerik hasil ekstraksi dieksplorasi secara paralel menggunakan dua algoritma *machine learning*, yaitu *Multinomial Naive Bayes* berbasis perhitungan probabilitas Teorema Bayes seperti Persamaan 1 [21].

$$P(C | X) = \frac{P(X|C) \times P(C)}{P(X)} \quad (1)$$

Algoritma komparasi *Support Vector Machine* (SVM) *kernel* linear yang bekerja menentukan parameter garis pembatas geometri (*hyperplane*) dengan rumus umum dasar pada Persamaan 2 [8].

$$f(x) = (w \times x) + b \quad (2)$$

Eksperimen diperluas lintas skenario [12] dengan membandingkan performa data asli (Kategori A) melawan data hasil manipulasi penyeimbangan *Undersampling* (Kategori B) pada struktur klasifikasi biner dan multi-kelas (3 kelas) [22].

2.6. Evaluasi Performa Model

Kekuatan akurasi model diukur secara presisi lewat pemetaan *Confusion Matrix*, yang kemudian diturunkan menjadi kalkulasi nilai *Accuracy*, *Precision*, *Recall*, dan *F1-score* [16]. Rumus perhitungan nilai akurasi global disajikan melalui Persamaan [23].


$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

3. HASIL DAN PEMBAHASAN

3.1. Hasil Distribusi Pelabelan Data

Berdasarkan hasil eksekusi komputasi pelabelan otomatis terhadap total 4.000 data ulasan opini publik mengenai program Makan Bergizi Gratis (MBG), diperoleh sebaran data yang sangat timpang (*class imbalance*). Kelas sentimen positif mendominasi ruang diskusi secara mutlak sebanyak 3.584 ulasan (89,60%), sedangkan kelompok ulasan kritis bermuatan sentimen negatif hanya memperoleh porsi sebaran sebanyak 416 ulasan (10,40%). Kesenjangan persentase polaritas ini disajikan secara jelas melalui grafik lingkaran pada Gambar 2.


Gambar 2 memvisualisasikan ketimpangan data opini publik di platform TikTok, di mana sentimen positif mendominasi porsi diskusi secara ekstrem. Dominasi respons positif ini merefleksikan besarnya ekspektasi dan dukungan emosional dari netizen Indonesia terhadap pemenuhan gizi anak-anak.



Gambar 2. Persentase Distribusi Sentimen *Dataset* Komentar

Sebelum dilakukan pengujian performa algoritma komparasi pada tahap hasil, seluruh *dataset* telah melalui serangkaian tahapan persiapan terstruktur sebagaimana dirancang pada bab metodologi. Proses diawali dengan pengumpulan data (*scraping*) sebanyak 4.000 komentar yang telah dibersihkan dari platform TikTok. *Dataset* tersebut kemudian diproses melalui tahapan *preprocessing* teks yang meliputi *data cleaning*, *case folding*, *spelling normalization*, *tokenization*, serta *stopword removal* dan *stemming* dengan bantuan *library* Sastrawi. Setelah data dalam kondisi bersih, dilakukan pembobotan kata menggunakan metode *Count Vectorizer* guna mentransformasikan token teks menjadi matriks numerik, sehingga *dataset* resmi siap digunakan dan diumpankan ke tahap pengujian performa utama model *Multinomial Naive Bayes* dan *Support Vector Machine* (SVM).

Selain pengujian pada skenario biner, penelitian ini melakukan ekspansi analisis ke skenario multi-kelas (3 kelas). Langkah ini diambil untuk menangkap dinamika opini publik secara objektif dan meminimalkan bias klasifikasi terhadap komentar netizen yang bersifat informatif maupun saran operasional. Hasil visualisasi persentase sebaran distribusi data untuk skenario multi-kelas tersebut disajikan pada Gambar 3.



Gambar 3. Persentase Distribusi Sentimen Opini Publik Skenario Multi-Kelas (3 Kelas)

Ekspansi skenario dilakukan dengan memetakan polaritas opini ke dalam kelas positif, netral, dan negatif. Berdasarkan Gambar 3, sentimen positif mendominasi ruang diskursus dengan persentase 78,70% (3.148 ulasan). Sementara itu, kelas netral menempati porsi sebesar 10,90% (436 ulasan) dan didominasi oleh pertanyaan teknis terkait regulasi, linimasa pelaksanaan, serta saran operasional. Di sisi lain, kelompok ulasan kritis bermuatan sentimen negatif memperoleh sebaran sebesar 10,40% (416 ulasan) yang berfokus pada kecemasan tata kelola anggaran dan higienitas makanan. Kemunculan kelas netral ini krusial untuk mereduksi bias klasifikasi biner dan memetakan objektivitas respons publik secara multidimensional.

3.2. Hasil Pengujian Utama Model Utama (Rasio 80:20)

Pengujian utama dijalankan menggunakan 20% data uji (800 sampel) dari *dataset* asli tanpa penyeimbangan. Algoritma *Multinomial Naive Bayes* memperoleh nilai akurasi global sebesar 91,62%. Namun, *Naive Bayes* mengalami kelemahan fatal dalam mengenali karakteristik ulasan negatif, di mana nilai *recall* sentimen negatif merosot tajam menjadi 0,24 (24%) akibat adanya 63 data negatif yang keliru diklasifikasikan sebagai positif. Sebaliknya, SVM dengan *kernel linear* menunjukkan performa superior, dengan akurasi mencapai 99,12%. Rincian komparasi dipaparkan pada Tabel 1.

Tabel 1. Laporan Kinerja Klasifikasi Komparasi Model (Rasio 80:20)

Algoritma Model	Kategori Sentimen	Precision	Recall	F1-Score	Support (Data Uji)
Multinomial Naive Bayes	Negatif	0.83	0.24	0.37	83

Algoritma Model	Kategori Sentimen	Precision	Recall	F1-Score	Support (Data Uji)
Support Vector Machine (Model Komparasi)	(Model Utama)	0.92	0.99	0.96	717
	Akurasi Akhir	-	-	91.62%	800
	Negatif	0.99	0.93	0.96	83
	Positif	0.99	1.00	1.00	717
	Akurasi Akhir	-	-	99.12%	800


Berdasarkan rekapitulasi data pada Tabel 1, hasil pengujian menunjukkan adanya disparitas performa yang signifikan antara kedua model yang dievaluasi. Algoritma *Support Vector Machine* (SVM) dengan kernel linear secara konsisten menunjukkan kinerja superior, dengan akurasi akhir sebesar 99,12% dan nilai *F1-score* yang seimbang pada kedua kelas sentimen. Sebaliknya, meskipun *Multinomial Naive Bayes* mampu mencatat akurasi global sebesar 91,62%, model ini mengalami penurunan performa yang ekstrem pada kelas negatif, dengan nilai *recall* yang hanya mencapai 0,24. Fenomena ini mengindikasikan ketidakmampuan pendekatan probabilitas *Naive Bayes* dalam menangani karakteristik ketidakseimbangan kelas (*class imbalance*) pada korpus data aslinya. Sebaliknya, karakteristik arsitektural SVM terbukti jauh lebih kokoh (*robust*) dan stabil dalam mereduksi kesalahan klasifikasi pada ruang fitur teks opini publik yang timpang dan kompleks.

3.3. Visualisasi Grafis Matriks Evaluasi (*Confusion Matrix*)

Untuk memetakan rincian prediksi benar dan salah dari kedua algoritma secara visual, dibentuk grafik pemetaan matriks komparasi seperti yang diilustrasikan secara tekstual pada Gambar 4 dan 5.


Berdasarkan analisis visual pada Gambar 4, grafik matriks mengekspos titik lemah algoritma *Naïve Bayes* yang meloloskan banyak data dengan *False Positive* (63 ulasan). Hal ini terjadi karena *Naive Bayes* sangat dipengaruhi oleh frekuensi data pada kelas mayoritas (positif). Sebaliknya, grafik matriks SVM memperlihatkan kerapatan diagonal yang sangat presisi, membuktikan bahwa SVM tidak mudah terdistorsi oleh data yang tidak seimbang. Pengujian performa algoritma juga dilakukan lintas dimensi menggunakan skenario multikelas (3 kelas). Rincian klasifikasi prediksi benar dan salah untuk model 3 kelas dari algoritma *Multinomial Naive Bayes* disajikan pada Gambar 6, sedangkan hasil untuk algoritma *Support Vector Machine* (SVM) disajikan pada Gambar 7.

Confusion Matrix - Model Naïve Bayes (91.62%)




Gambar 4. Matriks Evaluasi *Confusion Matrix* Model Klasifikasi Utama *Multinomial Naive Bayes*.

Confusion Matrix - Model SVM (99.12%)




Gambar 5. Matriks Evaluasi *Confusion Matrix* Model Komparasi *Support Vector Machine* (SVM).

Confusion Matrix - Model Naive Bayes 3 Kelas (84.75%)



Gambar 6. Matriks Evaluasi *Confusion Matrix* Multi-Kelas Algoritma *Multinomial Naive Bayes*

Confusion Matrix - Model SVM 3 Kelas (98.50%)



Gambar 7. Matriks Evaluasi *Confusion Matrix* Multi-Kelas Algoritma SVM

Analisis visual pada Gambar 6 menunjukkan penurunan akurasi global Multinomial Naive Bayes menjadi 84,75%. Grafik matriks mengekspos kelemahan model probabilistik ini dalam mengenali kelas minoritas, di mana terdapat 43 ulasan negatif dan 31 ulasan netral yang keliru diklasifikasikan ke dalam sentimen positif akibat bias sebaran frekuensi data mayoritas. Sebaliknya, Gambar 7 membuktikan superioritas arsitektural dari algoritma SVM kernel linear yang sukses mempertahankan akurasi tinggi sebesar 98,50% pada skenario 3 kelas. Model SVM berhasil memprediksi secara presisi sebanyak 629 data positif, 81 data netral, dan 78 data negatif tepat pada garis diagonal utama matriks dengan tingkat misklasifikasi yang sangat minimal. Performa ini membuktikan ketangguhan geometri *hyperplane* SVM yang tidak mudah terdistorsi oleh penambahan dimensi kelas baru maupun kondisi ketidakseimbangan data (*class imbalance*).

3.4. Hasil Eksperimen Lintas Skenario dan Intervensi Penyeimbangan

Rekapitulasi perbandingan pengujian lintas komposisi rasio *split data* dan intervensi *undersampling* disajikan secara lengkap pada Tabel 2.

Tabel 2. Matriks Rekapitulasi Performa Akurasi Global Komparasi Model

Kategori Pengujian	Skenario Kelas	Rasio Latih:Uji	Akurasi Naïve Bayes	Akurasi SVM
Kategori A: Data Asli (Tanpa Sampling)	Skenario 2 Kelas (Biner)	80 : 20	91,62%	99,12%
		70 : 30	92,25%	99,50%
		90 : 10	91,50%	99,50%
	Skenario 3 Kelas (Positif, Netral, Negatif)	80 : 20	84,75%	98,50%
		70 : 30	85,08%	98,42%
		90 : 10	85,00%	99,00%
Kategori B: Menggunakan Penyeimbangan (Undersampling)	Skenario 2 Kelas (Biner Seimbang)	80 : 20	83,83%	97,60%
		70 : 30	78,40%	97,20%
		90 : 10	80,95%	97,62%
	Skenario 3 Kelas (Multi-Kelas Seimbang)	80 : 20	74,77%	96,33%
		70 : 30	72,70%	97,85%
		90 : 10	76,15%	95,41%

Berdasarkan rekapitulasi data pada Tabel 2, hasil eksperimen komparasi menunjukkan bahwa algoritma *Support Vector Machine* (SVM) secara konsisten menampilkan performa yang lebih baik dibandingkan dengan Multinomial Naive Bayes pada seluruh skenario pengujian, baik pada dimensi biner maupun multi-kelas. Untuk menjamin transparansi metodologi, eksperimen ini menggunakan total 4.000 data ulasan asli. Pada Kategori A (Data Asli Tanpa Sampling) skenario 2 kelas (biner), sebaran data terdiri atas 3.148 ulasan positif dan 416 ulasan negatif. Pengujian rasio 80:20 (3.564 data latih dan 436 data uji biner) menghasilkan akurasi SVM sebesar 99,12% dan Naive Bayes sebesar 91,62%. Ketika rasio bergeser ke 70:30, SVM mencapai titik optimal sebesar 99,50% dan Naive Bayes menyentuh 92,25% karena penambahan porsi data uji memperluas variasi kamus kata (*token variance*). Namun, saat kompleksitas ditingkatkan ke dalam skenario 3 kelas dengan melibatkan 436 data netral, performa Naive Bayes merosot drastis akibat masalah ketidakseimbangan kelas (*class imbalance*). Pada rasio 80:20 data asli 3 kelas (800 data uji: 629 positif, 81 netral, 90 negatif), akurasi SVM tetap kokoh di angka 98,50%, sedangkan Naive Bayes terhambat di angka 84,75%. Efek bias ini semakin ekstrem pada rasio 90:10 3 kelas (400 data uji), di mana Naive Bayes anjlok ke titik terendah 83,00% karena porsi data uji yang terlalu minim tidak mampu mengompensasi dominasi probabilitas kelas mayoritas pada data latih, berbeda dengan SVM yang justru menyentuh akurasi tertinggi sebesar 99,00%.

Pada Kategori B dengan intervensi *Undersampling*, pemangkasan data dilakukan untuk menyeimbangkan distribusi kelas. Pada skenario 2 kelas seimbang, total data dipangkas mengikuti kuota kelas minoritas menjadi 832 ulasan (416 positif dan 416 negatif). Hasil pengujian menunjukkan performa yang relatif stabil pada kedua model, di mana SVM berada di kisaran 97,20% hingga 97,62%, sedangkan Naive Bayes berada di rentang 78,40% hingga 83,83%. Penurunan performa yang signifikan kembali terjadi ketika intervensi *undersampling* diterapkan pada skenario 3 kelas seimbang (total 1.248 ulasan; masing-masing 416 data per kelas). Evaluasi pada rasio 80:20 (250 data uji) memicu devaluasi akurasi Naive Bayes sebesar 74,77% akibat efek *information loss* dari pemangkasan data positif secara masif, sedangkan SVM tetap kokoh meraih akurasi 96,33%. Bergeser pada rasio 70:30 (374 data uji), akurasi bernilai 72,70% pada Naive Bayes dan 97,85% pada SVM. Namun, pada pengujian rasio 90:10 (125 data uji), algoritma Naive Bayes merangkak naik ke angka 76,15% karena hilangnya bias mayoritas sepenuhnya, sedangkan SVM justru mengalami penurunan ke titik terendahnya sebesar 95,41%.


Secara ilmiah, bertahannya keunggulan akurasi SVM di seluruh variasi rasio berakar pada karakteristik geometri *hyperplane* margin maksimal yang dibentuk oleh fungsi kernel linear. Batas keputusan klasifikasi SVM hanya dipengaruhi secara eksklusif oleh sampel-sampel terluar (*support vectors*) dan bukan oleh total volume data, sehingga sangat resisten terhadap masalah ketimpangan data maupun penyusutan data akibat *sampling*. Sebaliknya, karakteristik Multinomial Naive Bayes sebagai model probabilistik murni sangat

bergantung pada akumulasi frekuensi kemunculan token kata. Ketika dihadapkan pada skenario data yang timpang atau data yang dipersempit lewat *undersampling*, kalkulasi probabilitas *a priori* model akan selalu bias ke arah kelas dengan kepadatan dokumen tertinggi, sehingga memicu tingginya tingkat misklasifikasi (*false positive*) pada ruang fitur teks informal media sosial yang kompleks.

Untuk menguji sensitivitas model secara riil, penelitian ini juga melakukan uji simulasi data real-time pada skenario 3 kelas menggunakan blok simulator prediksi. Berdasarkan hasil pengujian tersebut, ditemukan adanya kegagalan klasifikasi (*misclassification*) oleh model Multinomial Naïve Bayes pada komentar: “*Alhamdulillah program makan bergizi gratis ini sangat bermanfaat untuk gizi anak sekolah*”, yang secara keliru diprediksi ke dalam kelas Netral. Hal ini terjadi karena pendekatan berbasis frekuensi kata pada Naïve Bayes gagal menangkap pembobotan fitur positif secara utuh akibat sebaran data yang renggang. Sebaliknya, algoritma SVM berhasil memprediksi teks simulasi tersebut secara akurat ke dalam kelas Positif berkat keunggulan arsitektur geometri hyperplane yang lebih kokoh terhadap ambiguitas teks informal.

3.5. Visualisasi Grafik Batang Lintas Skenario (Cross-Scenario Bar Chart)

Tren naik-turunnya akurasi dari pengujian lintas skenario pada Tabel 2 kemudian divisualisasikan ke dalam grafik batang perbandingan pada Gambar 8.



Gambar 8. Grafik Batang Perbandingan Akurasi Lintas Skenario

Grafik batang pada Gambar 8 menunjukkan fluktuasi kinerja yang sangat mencolok. Performa SVM (batang hitam) tetap stabil mendominasi batas atas grafik di setiap skenario. Sebaliknya, grafik akurasi *Naïve Bayes* (batang arsiran) merosot tajam ketika memasuki skenario Kategori B dengan titik terendah 72,70%. Grafik ini membuktikan secara empiris bahwa pemangkasan data secara acak melalui teknik *undersampling* merusak performa probabilistik *Naïve Bayes* akibat hilangnya informasi penting pada ruang fitur dokumen teks.

3.6. Analisis Awan Kata (WordCloud) dan Tren Topik Publik

Tahap akhir analisis dilakukan dengan mengekstrak 10 kosakata dominan yang paling sering muncul pada masing-masing kelompok polaritas untuk menangkap substansi opini riil publik. Hasil ekstraksi frekuensi kata dipaparkan pada Tabel 3.

Tabel 3. Daftar Kata Dominan Terbanyak pada Setiap Kelas Sentimen

No	Kata Kunci Sentimen Positif	Frekuensi Kemunculan	Kata Kunci Sentimen Negatif	Frekuensi Kemunculan
1	membantu	880 kali	anggaran	185 kali
2	terbantu	592 kali	korupsi	138 kali
3	bersyukur	454 kali	utang	78 kali
4	bermanfaat	445 kali	mahal	78 kali
5	bergizi	372 kali	amburadul	76 kali
6	bagus	364 kali	kecewa	75 kali
7	sukses	359 kali	basi	64 kali
8	terimakasih	341 kali	keracunan	60 kali
9	alhamdulillah	332 kali	mubazir	57 kali
10	lancar	322 kali	bangkrut	55 kali

Kerapatan jalinan kata kunci di atas divisualisasikan secara spasial menggunakan diagram awan kata pada Gambar 9 dan 10.

**Gambar 9.** Representasi Visualisasi wordcloud kata kunci dominan kelas Sentimen Positif**Gambar 10.** Representasi visualisasi WordCloud kata kunci dominan kelas Sentimen Negatif

Gambar 10 menampilkan representasi visual yang kontras. Sebagaimana disajikan pada rincian visual Gambar 9, Pada *kluster* awan kata positif, ukuran teks terbesar didominasi oleh kata 'membantu', 'terbantu', dan 'bersyukur', merefleksikan kepuasan dan optimisme masyarakat atas realisasi program pemenuhan gizi anak sekolah. Sebaliknya, *kluster* awan kata negatif memunculkan ukuran teks dominan seperti 'anggaran' dan 'korupsi', diiringi kata 'basi' serta 'keracunan'. Diagram awan kata ini membuktikan bahwa kritik publik di platform TikTok berfokus pada kecemasan penyalahgunaan dana fiskal negara serta tuntutan standardisasi higienitas makanan di lapangan.

Temuan dalam penelitian ini menunjukkan bahwa algoritma *Support Vector Machine* (SVM) memiliki ketangguhan superior dengan raihan akurasi mencapai 99,12% dibandingkan *Multinomial Naive Bayes* yang tertahan di angka 91,62%. Fenomena keberhasilan SVM muncul karena karakteristik algoritmanya yang sangat andal dalam memetakan batas pemisah (*hyperplane*) linier pada ruang dimensi fitur teks yang tinggi dan renggang. Sebaliknya, performa *Naive Bayes* merosot tajam akibat sifat probabilistiknya yang sangat sensitif terhadap kondisi ketidakseimbangan kelas (*class imbalance*) ekstrem, di mana porsi sentimen positif mendominasi secara mutlak sebesar 89,60%. Temuan orisinal ini sejalan dengan hasil pengujian pada beberapa studi terdahulu [14][22] yang juga mengonfirmasi keunggulan konsisten model SVM linier atas *Naive Bayes* dalam penambahan data opini publik mengenai program Makan Bergizi Gratis (MBG).

Implikasi praktis dari visualisasi *WordCloud* merekam bahwa kluster sentimen negatif berfokus pada kecemasan riil netizen TikTok terhadap potensi penyalahgunaan anggaran negara, korupsi, serta tuntutan standardisasi mutu higienitas makanan di lapangan. Keterbatasan utama dalam penelitian ini terletak pada ketergantungan model terhadap metode pelabelan otomatis berbasis leksikon (*lexicon-based*) yang kurang akurat dalam menangani aspek nuansa bahasa informal dan kalimat sarkasme, serta risiko hilangnya variasi data minoritas akibat penerapan intervensi teknik *Undersampling*. Oleh karena itu, saran pengembangan untuk penelitian selanjutnya adalah mengintegrasikan teknik penyeimbangan data sintetis seperti SMOTE dan menerapkan metode ekstraksi fitur alternatif berbasis *TF-IDF* guna mengoptimalkan penyerapan karakteristik teks ulasan yang lebih kompleks.

4. KESIMPULAN

Berdasarkan hasil eksperimen pengujian komparasi terhadap 4.000 data komentar TikTok terkait Program Makan Bergizi Gratis (MBG), dapat disimpulkan bahwa opini publik didominasi oleh sentimen positif sebesar 89,60%, sementara sentimen negatif mencakup 10,40%. Hasil pengujian performa klasifikasi pada skenario biner asli membuktikan superioritas mutlak dari algoritma *Support Vector Machine* (SVM) *kernel*

linear dengan raihan akurasi tertinggi sebesar 99,12%, mengungguli algoritma *Multinomial Naive Bayes* yang memperoleh akurasi 91,62%. Penelitian ini memberikan kontribusi ilmiah berupa bukti empiris mengenai ketangguhan model geometri linear SVM yang sangat kokoh dalam mempertahankan stabilitas akurasi di atas 95% lintas skenario, berbanding terbalik dengan model probabilistik *Naive Bayes* yang sangat rentan mengalami degradasi performa ekstrem hingga menyentuh 72,70% akibat intervensi pemangkasan data undersampling pada teks ulasan informal TikTok. Analisis *WordCloud* merekam bahwa sentimen positif terpusat pada dukungan pemenuhan gizi anak, sedangkan sentimen negatif terfokus pada kekhawatiran penyalahgunaan anggaran dan korupsi. Kelebihan penelitian ini terletak pada keberhasilan penerapan teknik *undersampling* yang terbukti stabil menjaga konsistensi performa metrik akurasi komparasi model pada skenario multi-kelas, sedangkan kelemahannya adalah adanya risiko pembuangan variasi informasi data mayoritas serta keterbatasan pelabelan *lexicon-based* dalam menangani kalimat sarkasme. Sebagai rekomendasi implementasi ke depan, sistem pemantauan komputasional ini dapat diterapkan secara praktis oleh Badan Gizi Nasional sebagai instrumen evaluasi kebijakan operasional dan keluhan publik secara *real-time*. Untuk penelitian selanjutnya, disarankan menerapkan teknik penyeimbangan data sintesis seperti SMOTE dan memanfaatkan metode ekstraksi fitur alternatif *TF-IDF* guna mengoptimalkan penyerapan karakteristik teks informal.

REFERENSI

- [1] F. Fatkhurrohman, B. I. Nugroho, and N. Fadillah, "Analisis sentimen program makan bergizi gratis pemerintah RI melalui twitter menggunakan metode SVM," *Journal of Artificial Intelligence and Digital Business (RIGGS)*, vol. 4, no. 3, pp. 3906–3917, 2025. <https://doi.org/10.31004/riggs.v4i3.2533>
- [2] V. Agustina and A. Herliana, "Analisis sentimen publik atas kebijakan efisiensi anggaran 2025 dengan text mining dan natural language processing," *Jurnal Media Informatika (JUMIN)*, vol. 6, no. 3, pp. 2182–2194, 2025. <https://doi.org/10.55338/jumin.v6i3.6301>
- [3] A. Putriyeki, D. Sulistiawati, N. Khairani, and R. R. A. Kusuma, "Analisis multidimensional sentimen masyarakat terhadap program makan bergizi gratis pada media sosial X," *Integrative Perspectives of Social and Science Journal (IPSSJ)*, vol. 2, no. 1, pp. 1004–1024, 2025. <https://ipssj.com/index.php/ojs/article/view/142>
- [4] D. F. M. Dina, T. Haryanti, and M. A. Haq, "Analisis sentimen terhadap komentar pada media sosial tiktok yang berpotensi menyebabkan depresi menggunakan metode naive bayes," *Computing Insight: Journal of Computer Science*, vol. 7, no. 1, pp. 1–9, June 2025. https://doi.org/10.30651/comp_insight.v7i1.26327
- [5] A. A. Putri and D. Novianto, "Analisis sentimen masyarakat indonesia terhadap program makan bergizi gratis (MBG) di media sosial X menggunakan perbandingan algoritma naive bayes dan support vector machine," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 10, no. 3, pp. 5047–5052, June 2026. <https://doi.org/10.36040/jati.v10i3.18441>
- [6] M. F. N. Pradigta, A. Yani, and M. A. Azis, "Analisis sentimen review aplikasi tiktok dengan algoritma naive bayes," pp. 6–31, 2020. <https://repository.nusamandiri.ac.id/index.php/repo/viewitem/11534>
- [7] N. Apriliani, N. Suarna, and W. Prihartono, "Analisis sentimen review penggunaan tiktok melalui pendekatan algoritma naive bayes," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 6, pp. 3725–3731, Dec. 2023. <https://doi.org/10.36040/jati.v7i6.8299>
- [8] S. A. S. Mola, P. R. Lete, Triyanto, B. J. A. J. A. Pa, and T. Widiastuti, "Analisis sentimen menggunakan metode naive bayes dan metode support vector machine pada kasus pelantikan artis sebagai anggota anggota dpr ri tahun 2024," *HOAQ: Jurnal Teknologi Informasi*, vol. 15, no. 1, pp. 22–32, Mei 2024. <https://doi.org/10.52972/hoa.vol15no1.p22-32>
- [9] A. S. Rizkia, Wufron, and F. F. Roji, "Sentiment analysis of coretax: A comparison of manual, transformers-based, and lexicon-based data labeling on indoBERT performance (Analisis sentimen coretax: Perbandingan pelabelan data manual, transformers-based, dan lexicon-based pada performa indoBERT)," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 3, pp. 1037–1048, July 2025. <https://doi.org/10.57152/malcom.v5i3.2151>
- [10] K. Setiawan and K. J. Apriyanto, "Pengembangan model analisis sentimen berbasis naive bayes terhadap isu kepemimpinan presiden prabowo di tiktok," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 8, no. 4, pp. 1111–1121, 2025. <https://garuda.kemdiktisaintek.go.id/documents/detail/5399782>
- [12] Y. A. Prasetyo, E. Utami, and A. Yaqin, "Pengaruh komposisi split data terhadap performa akurasi analisis sentimen algoritma naive bayes dan SVM," *Journal of Electrical Engineering and Computer (JEECOM)*, vol. 6, no. 2, pp. 382–390, Oct. 2024. <https://doi.org/10.33650/jeecom.v6i2.9188>
- [13] F. A. Indriyani, A. Fauzi, and S. Faisal, "Analisis sentimen aplikasi tiktok menggunakan algoritma naive bayes dan support vector machine," *TEKNOSAINS: Jurnal Sains, Teknologi dan Informatika*, vol. 10, no. 2, pp. 176–184, July 2023. <https://doi.org/10.37373/tekno.v10i2.419>
- [14] R. Amelsan and Muntahanah, "Analisis perbandingan kinerja algoritma naive bayes dan SVM dalam

- mengklasifikasi sentimen terhadap MBG," JATI (Jurnal Mahasiswa Teknik Informatika), vol. 10, no. 3, pp. 5442–5449, June 2026. <https://doi.org/10.36040/jati.v10i3.18357>
- [15] F. A. Maresti, K. Mustaqim, and N. G. Ginasta, "Implementasi naive bayes pada sistem asesmen program kemitraan dan bina lingkungan PT. Pos Indonesia," Jurnal Ilmiah KOMPUTASI, vol. 23, no. 2, pp. 147–154, June 2024. <https://doi.org/10.32409/jikstik.23.2.3584>
- [16] A. Putri, Jasmir, and B. Purnama, "Classification of scholarship eligibility using naïve bayes with attribute optimization based on K-means clustering (Klasifikasi kelayakan penerima beasiswa menggunakan naive bayes dengan optimasi atribut berbasis K-means clustering)," MALCOM: Indonesian Journal of Machine Learning and Computer Science, vol. 5, no. 4, pp. 1450–1462, Oct. 2025. <https://doi.org/10.57152/malcom.v5i4.2312>
- [18] I. M. Juniandika and I. B. M. Mahendra, "Analisis sentimen aplikasi zenius menggunakan metode logistic regression," JNATIA: Jurnal Nasional Teknologi Informasi dan Aplikasinya, vol. 1, no. 4, pp. 1171–1178, Aug. 2023. <https://doi.org/10.24843/JNATIA.2023.v01.i04.p20>
- [19] R. Vincent, I. Maulana, and O. Komarudin, "Perbandingan klasifikasi naive bayes dan support vector machine dalam analisis sentimen dengan multiclass di twitter," JATI (Jurnal Mahasiswa Teknik Informatika), vol. 7, no. 4, pp. 2496–2505, Aug. 2023. <https://doi.org/10.36040/jati.v7i4.7152>
- [20] R. Wati, S. Ernawati, and H. Rachmi, "Pembobotan TF-IDF menggunakan naïve bayes pada sentimen masyarakat mengenai isu kenaikan BIPIH (TF-IDF weighting using naïve bayes on public sentiment on the issue of rising BIPIH)," Jurnal Manajemen Informatika (JAMIKA), vol. 13, no. 1, pp. 84–93, Apr. 2023. <https://doi.org/10.34010/jamika.v13i1.9424>
- [21] A. Sagostian, L. Yuda, and Yandi, "Analisis sentimen komentar netizen terhadap video pemindahan dan pembangunan ibu kota nusantara di tiktok menggunakan metode naïve bayes," HOAQ: Jurnal Teknologi Informasi, vol. 16, no. 2, pp. 181–185, Dec. 2025. <https://doi.org/10.52972/hoaq.vol16no2>
- [22] Z. P. Tiararosa, I. S. Wijaya, and E. Rohaini, "Perbandingan SVM dan naive bayes pada analisis sentimen MBG di platform TikTok dan Instagram," Jurnal Informatika Dan Rekayasa Komputer (JAKAKOM), vol. 6, no. 1, pp. 1983–1993, Apr. 2026. <https://doi.org/10.33998/jakakom.2026.6.1.2750>
- [23] R. E. Pambudi, H. Purnomo, and A. Aglasia, "Analisis klasifikasi sentimen pengguna MyPertamina menggunakan metode evaluasi precision, recall, dan F1-score," Aisyah Journal of Informatics and Electrical Engineering, vol. 7, no. 2, pp. 17–22, Aug. 2025. <https://aisyahuniversity.ac.id>