HOAQ: JURNAL TEKNOLOGI INFORMASI, Volume 17 Nomor 2, Desember 2026, p318-329
p-ISSN: 2337-5280, e-ISSN: 26207427
DOI: https://doi.org/10.52972/hoaq.vol17no2

ANALISIS SENTIMEN PROGRAM MAKAN BERGIZI GRATIS DI X: KOMPARASI NAIVE BAYES DAN SVM

Rio Irawan[1], Sadam Muhammad Natzir[2]

[1] Program Studi Ilmu Komputer, Universitas Muhammadiyah OKU Timur
[2] Program Studi Teknik Informatika, Universitas Uyelindo
Jl. Raya Harjowinangun BK 10, Kecamatan Belitang, Kabupaten OKU Timur, Sumatera Selatan, Indonesia
Email: [1]irawanrio.blt@gmail.com,[2]sadamnatsir250701@gmail.com

ABSTRAK

Program Makan Bergizi Gratis (MBG) memicu diskursus publik masif di platform X (Twitter) dengan konteks linguistik yang kompleks dan distribusi kelas yang tidak seimbang. Penelitian ini bertujuan untuk menganalisis sentimen masyarakat sekaligus membandingkan performa algoritma Multinomial Naive Bayes (MNB) dan Support Vector Machine (SVM/LinearSVC) berbasis ekstraksi fitur Term Frequency-Inverse Document Frequency (TF-IDF) dan penanganan class imbalance menggunakan Synthetic Minority Over-sampling Technique (SMOTE). *Dataset* dilabeli secara otomatis menggunakan pendekatan leksikon dan divalidasi manual (N = 100) berbasis konteks pragmatik. Evaluasi reliabilitas pelabelan manual menghasilkan nilai Cohen's Kappa\kappa = 0,6425 (*substantial agreement*), yang mengungkap adanya bias asimetris pada leksikon otomatis dalam mengenali sentimen negatif (Recall = 51,35%). Untuk mencegah kebocoran data (*data leakage*), SMOTE diterapkan secara per-*fold* pada skema Stratified 5-*Fold Cross-Validation* dan *train-set only* pada skema *hold-out split* 80:20. Hasil pengujian *Cross-Validation* menunjukkan SVM secara konsisten mengungguli MNB dengan rata-rata akurasi 81,25% \pm 2,37% berbanding 59,58% \pm 2,34% . Pada evaluasi data uji (80:20), SVM mencapai akurasi 83,26% dan Macro F1-*score* 0,78 , sedangkan MNB hanya mencapai akurasi 60,93% dan Macro F1-*score* 0,59 . Hasil ini membuktikan bahwa SVM lebih adaptif dalam memisahkan batas keputusan pada teks opini publik yang kaya akan konteks, frasa implisit, dan sarkasme.

Kata kunci: Analisis Sentimen; Makan Bergizi Gratis; Naive Bayes; Support Vector Machine; SMOTE; Media Sosial X

ABSTRACT

The Free Nutritious Meal (MBG) program has triggered massive public discourse on platform X (Twitter), characterized by complex linguistic contexts and imbalanced class distributions. This study aims to analyze public sentiment and compare the performance of Multinomial Naive Bayes (MNB) and Support Vector Machine (SVM/LinearSVC) algorithms using Term Frequency-Inverse Document Frequency (TF-IDF) feature extraction and Synthetic Minority Over-sampling Technique (SMOTE) for class imbalance mitigation. The dataset was automatically labeled using a lexicon approach and manually validated (N = 100) based on pragmatic context. Reliability evaluation of manual annotation yielded a Cohen's Kappa of \kappa = 0.6425 (substantial agreement), revealing a systematic one-directional bias in the automated lexicon toward underestimating negative sentiment (Recall = 51.35%). To prevent data leakage, SMOTE was strictly applied per-fold during Stratified 5-Fold Cross-Validation and exclusively on the training set in the 80:20 hold-out split scheme. Cross-validation results demonstrated that SVM consistently outperformed MNB, achieving a mean accuracy of 81.25% \pm 2.37% compared to 59.58% \pm 2.34% . On the 80:20 test evaluation, SVM achieved an accuracy of 83.26% and a Macro F1-score of 0.78 , whereas MNB achieved an accuracy of 60.93% and a Macro F1-score of 0.59 . These findings confirm that SVM is significantly more robust in establishing decision boundaries for public opinion text containing implicit phrasing, domain-specific terminology, and sarcasm.

Keywords: Sentiment Analysis; Free Nutritious Meal Program; Naive Bayes; Support Vector Machine; SMOTE; Social Media X

1. PENDAHULUAN

Kebijakan publik berskala masif yang berimplikasi langsung pada postur Anggaran Pendapatan dan Belanja Negara (APBN) senantiasa menuntut tingkat transparansi dan pengawasan sosiologis yang ketat [1]. Salah satu intervensi strategis pemerintah yang saat ini mendominasi diskursus nasional adalah Program Makan Bergizi Gratis (MBG). Program ini dirancang dengan sasaran multidimensi: mengentaskan permasalahan stunting pada

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

anak usia sekolah, mendongkrak kualitas kognitif generasi muda, serta menstimulasi ekonomi sirkular melalui pemberdayaan rantai pasok pangan lokal . Mengingat besarnya alokasi sumber daya finansial yang dibutuhkan untuk eksekusi program ini secara nasional, evaluasi terhadap penerimaan dan respons riil masyarakat menjadi sangat fundamental [2]. Pendekatan evaluasi konvensional melalui survei demografis seringkali memiliki latensi waktu yang tinggi dan rentan terhadap bias responden, sehingga gagal menangkap dinamika opini publik yang bergejolak secara real-time [3].

Dalam lanskap komunikasi kontemporer, platform media sosial X (sebelumnya Twitter) telah bertransformasi menjadi barometer paling asertif untuk merekam sentimen publik [4]. Karakteristik ekosistem X yang asinkron, terbuka, dan didominasi oleh perdebatan berbasis teks menjadikannya sumber data primer (big data) yang sangat krusial bagi analisis kebijakan publik [5]. Pada rentang periode implementasi awal hingga pertengahan tahun, tepatnya antara Januari 2026 hingga Juli 2026, arus informasi terkait Program MBG menghasilkan ribuan opini masyarakat setiap harinya. Tumpukan data tidak terstruktur ini memuat spektrum emosi yang luas, mulai dari apresiasi terhadap perbaikan gizi, hingga skeptisisme mengenai tata kelola anggaran dan kekhawatiran atas potensi mismanajemen. Untuk mengekstraksi konklusi analitis dari data masif tersebut tanpa bias interpretasi manual, intervensi komputasional berbasis Natural Language Processing (NLP) menjadi sebuah keharusan metodologis [6].

Analisis sentimen merupakan paradigma machine learning yang berfokus pada klasifikasi polaritas teks ke dalam vektor emosi yang terukur, seperti positif, negatif, atau netral [7]. Tantangan komputasional utama dalam analisis teks media sosial adalah tingginya dimensi noise linguistik dan fenomena echo chamber, di mana opini diamplifikasi melalui duplikasi masal berupa retweet, sehingga langkah eksklusi duplikasi pada tahap akuisisi data menjadi krusial untuk menjaga validitas pembobotan frekuensi dokumen. Pada tahap penentuan ground truth label, sebagian besar penelitian terdahulu mengandalkan model Transformer pra-latih seperti IndoBERT untuk pelabelan otomatis; alternatif lain yang lebih ringan secara komputasi adalah pendekatan leksikon sentimen yang dikalibrasi dengan aturan deteksi negasi, meskipun efektivitasnya pada domain kebijakan publik berbahasa Indonesia masih memerlukan pengujian lebih lanjut [8]. Selanjutnya, tahapan representasi fitur memegang peranan krusial, di mana pembobotan Term Frequency-Inverse Document Frequency (TF-IDF) secara luas diakui sebagai metode ekstraksi fitur yang tangguh karena kemampuannya mereduksi bobot kata-kata umum yang redundan dan memprioritaskan term yang memiliki nilai pembeda (*discriminative power*) yang tinggi di dalam korpus dokumen [9].

Dalam domain algoritma klasifikasi, Naive Bayes (NB) dan Support Vector Machine (SVM) secara konsisten digunakan sebagai komparasi standar karena perbedaan arsitektur logikanya. Naive Bayes beroperasi berdasarkan teorema probabilitas Bayes dengan asumsi independensi yang kuat antar variabel prediktor [10] . Kesederhanaan matematis ini membuat NB memiliki kompleksitas komputasi yang rendah dan adaptif terhadap dataset kecil, meskipun rentan terhadap penurunan akurasi ketika fitur-fitur linguistik memiliki dependensi kontekstual yang tinggi, terutama pada kelas sentimen yang bertumpang tindih secara leksikal . Sebaliknya, SVM memecahkan masalah klasifikasi dengan pendekatan geometri ruang matriks, mencari hyperplane optimal yang memaksimalkan batas margin antar kelas sentimen. Pendekatan berbasis margin ini diklaim oleh banyak literatur sangat resistan terhadap anomali overfitting, khususnya pada *dataset* teks berdimensi tinggi (high-dimensional sparse data) yang dihasilkan dari ekstraksi TF-IDF . Selain persoalan arsitektur algoritma, dataset opini media sosial pada topik kebijakan publik umumnya juga diwarnai ketimpangan distribusi kelas yang akut, sehingga penanganan melalui teknik penyeimbangan data seperti SMOTE turut menjadi variabel penting yang perlu diuji pengaruhnya terhadap kedua arsitektur algoritma tersebut secara simultan .

Penelitian mengenai analisis sentimen terhadap Program MBG di media sosial X telah cukup banyak dieksplorasi sepanjang tahun 2025–2026, namun masing-masing masih menyisakan celah metodologis yang spesifik. [11] mengombinasikan SVM dengan fitur N-Gram dan TF-IDF pada 931 tweet biner (positif–negatif), mencapai akurasi 79,59%, tetapi tanpa penanganan class imbalance sehingga recall kelas negatif jatuh sangat rendah (24,19%). [12] membandingkan IndoBERT-base-P2 dengan baseline SVM pada 7.958 tweet tiga kelas dan membuktikan keunggulan IndoBERT secara statistik (akurasi 92%; macro F1 0,90 vs. 86%; 0,83), namun penelitian ini tidak menerapkan SMOTE pada baseline SVM-nya sehingga perbandingan penanganan ketimpangan kelas antar-algoritma menjadi timpang.

Berdasarkan sintesis kelima penelitian tersebut, teridentifikasi tiga celah penelitian (Gap Analysis) yang saling melengkapi. Pertama, penanganan ketimpangan kelas melalui SMOTE belum pernah diujikan secara konsisten pada komparasi langsung dua arsitektur algoritma berbeda paradigma (probabilistik vs. margin geometris) dalam skema klasifikasi tiga kelas (Negatif–Netral–Positif) sekaligus, mengingat sebagian studi hanya menguji satu algoritma dengan SMOTE [13] atau membandingkan algoritma tanpa penyetaraan perlakuan SMOTE pada kedua sisi. Kedua, mayoritas studi bergantung pada model Transformer pra-latih untuk pelabelan ground truth, sementara pendekatan leksikon sentimen dengan aturan negasi eksplisit — yang lebih hemat sumber daya komputasi — belum banyak diuji pada domain spesifik Program MBG. Ketiga, studi yang secara spesifik mengangkat topik Program MBG cenderung menggunakan rentang waktu observasi yang pendek dan terfragmentasi per isu, misalnya hanya isu keracunan atau hanya periode awal peluncuran, sehingga belum ada yang mengombinasikan rentang waktu observasi yang komprehensif (fase peluncuran hingga pertengahan tahun berjalan) dengan eksklusi ketat terhadap duplikasi retweet pada tahap akuisisi data. Penelitian ini diposisikan untuk mengisi ketiga celah tersebut secara simultan, dengan mengeksklusi seluruh duplikasi retweet pada tahap akuisisi data melalui Apify API, menerapkan pelabelan berbasis leksikon dengan aturan deteksi negasi, serta

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

mengomparasikan kinerja Multinomial Naive Bayes dan Linear SVM pada data yang telah diseimbangkan melalui SMOTE, diuji pada tiga skema rasio pembagian data (70:30, 80:20, 90:10) untuk mengidentifikasi konfigurasi paling optimal.

Oleh karena itu, tujuan utama dari penelitian ini adalah merancang dan mengevaluasi sistem analisis sentimen tiga kelas (Negatif, Netral, Positif) terhadap opini publik di platform X mengenai Program Makan Bergizi Gratis (MBG) pada rentang waktu observasi Januari–Juli 2026. Secara spesifik, penelitian ini bertujuan mengomparasikan secara empiris tingkat *Accuracy*, *Precision, Recall*, dan F1-Score antara algoritma Multinomial Naive Bayes dan *Support Vector Machine* berbasis pembobotan TF-IDF pasca-optimasi SMOTE, pada data yang telah dibersihkan dari duplikasi retweet dan dilabeli menggunakan pendekatan leksikon dengan penanganan negasi. Hasil luaran penelitian ini diestimasikan dapat menyajikan visibilitas analitik yang objektif dan berbasis bukti (*evidence-based*) bagi pemangku kebijakan dalam mengidentifikasi pola diskursus kritis publik, serta berkontribusi pada penyempurnaan literatur pengujian machine learning pada teks kebijakan publik berbahasa Indonesia yang dinamis.

2. METODE PENELITIAN

Kerangka Kerja dan Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental yang bertumpu pada teknik penambangan teks (*text mining*) dan Natural Language Processing (NLP) untuk menganalisis sentimen publik di media sosial. Kerangka kerja (*framework*) disusun secara linear dan berurutan untuk menjaga validitas komputasional serta merepresentasikan alur pemodelan *machine learning* secara sistematis. Tahap pertama adalah akuisisi data (*crawling*) dari platform X, dilanjutkan dengan prapemrosesan data (*text preprocessing*) untuk menormalisasi struktur linguistik dokumen. Tahap ketiga adalah penentuan label sentimen (ground truth) melalui pendekatan leksikon berbobot yang dikalibrasi dengan aturan negasi, serta transformasi fitur teks menjadi matriks numerik menggunakan *Term Frequency-Inverse Document Frequency* (TF-IDF). Pada tahap keempat, dilakukan penyeimbangan distribusi kelas melalui algoritma *Synthetic Minority Over-sampling Technique* (SMOTE). Tahap terakhir adalah pelatihan dan pengujian komparatif antara Multinomial Naive Bayes dan *Support Vector Machine* (SVM) melalui tiga skenario partisi dataset, yang dievaluasi menggunakan Confusion Matrix. Alur penelitian secara lengkap divisualisasikan pada Gambar 1.

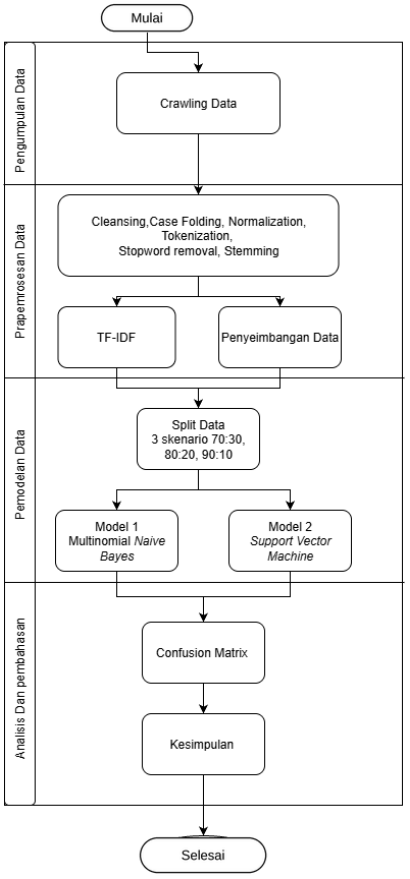

Gambar 1. Kerangka Kerja dan Alur Tahapan Penelitian Analisis Sentimen

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

Proses Akuisisi dan Ruang Lingkup Data

Data primer penelitian ini dikumpulkan dari platform media sosial X (sebelumnya Twitter) yang membahas kebijakan Program Makan Bergizi Gratis (MBG). Pengumpulan data dilakukan menggunakan layanan scraping berbasis API dari Apify. Rentang waktu observasi ditetapkan mulai dari Januari 2026 hingga Juli 2026. Pemilihan periode ini didasarkan pada pertimbangan metodologis untuk menangkap evolusi opini publik secara komprehensif, terhitung sejak momentum resmi awal implementasi Program MBG pada Januari 2026 hingga batas akhir penarikan data (*cutoff date*) pada Juli 2026. Periode observasi selama tujuh bulan ini mencakup rentang waktu longitudinal yang proporsional untuk merekam dinamika wacana masyarakat—mulai dari respons awal peluncuran program, tahap penyesuaian di lapangan, hingga bermunculannya evaluasi kritis publik—sehingga dataset terhindar dari bias fluktuasi emosi sesaat (*event anomaly*) akibat peristiwa tunggal.

Guna menjaga validitas pembobotan frekuensi dokumen dan mencegah duplikasi opini akibat penyebaran ulang konten (retweet), parameter pengumpulan data dikonfigurasi untuk mengeksklusi seluruh retweet (include:nativeretweets=*False*). Proses akuisisi data mentah (raw data) menghasilkan 2.251 cuitan. Selanjutnya, filter identifikasi bahasa (lang='in') diterapkan untuk menyingkirkan 85 cuitan berbahasa asing atau tidak teridentifikasi, sehingga diperoleh 2.166 cuitan berbahasa Indonesia sebagai dataset dasar.

Prapemrosesan Data

Teks pada media sosial umumnya memiliki tingkat ambiguitas dan derau (noise) leksikal yang tinggi, mulai dari penggunaan bahasa informal, singkatan tidak baku, hingga karakter unicode. Tahapan prapemrosesan diperlukan untuk menyiapkan teks agar dapat diproses oleh algoritma ekstraksi fitur. Rangkaian pembersihan data dilakukan melalui tahapan berikut:

a. *Cleansing*: penghapusan elemen non-tekstual meliputi Uniform Resource Locator (URL), username (@), tagar (#), angka, emotikon, dan tanda baca menggunakan ekspresi reguler (RegEx).
b. *Case Folding*: Penyeragaman format kapitalisasi teks dengan mengonversi seluruh huruf menjadi huruf kecil (lowercase) agar mesin tidak membaca term “Makan” dan “makan” sebagai entitas yang berbeda.
c. *Slang Normalization*: Menerjemahkan kamus bahasa slang atau prokem ke dalam bahasa Indonesia baku. Pemetaan ini krusial untuk memperbaiki sintaksis (misalnya: 'yg' menjadi 'yang', 'gk' menjadi 'tidak') berdasarkan kamus custom yang diperkaya [14] .
d. *Tokenization*: Segmentasi struktur kalimat tunggal menjadi array himpunan kata dasar (tokens) untuk memfasilitasi komputasi gramatikal tahap lanjut.
e. *Stopword Removal*: Eliminasi kata-kata fungsional (preposisi, konjungsi) yang frekuensi kemunculannya hiper-dominan namun hampa makna sentimen. Lebih jauh, penelitian ini secara analitis memformulasikan domain-specific stopwords dengan membuang entitas program seperti kata “makan”, “bergizi”, “gratis”, “mbg”, dan “program”[15] . Langkah strategis ini ditempuh untuk mencegah kegagalan diskriminasi probabilitas model pada fitur-fitur yang tidak memiliki daya pembeda polaritas.
f. *Stemming*: Transformasi [16] morfologis untuk meluruhkan afiksasi (awalan, sisipan, akhiran) dan mengembalikan token ke bentuk konfiks lema dasarnya menggunakan basis data kamus Sastrawi.

Baris komentar yang menjadi kosong setelah tahap pembersihan dihapus secara otomatis, menghasilkan 2.147 dokumen bersih yang siap dianalisis. Contoh transformasi teks ditunjukkan pada Tabel 1, dan distribusi panjang token divisualisasikan pada Gambar 2.

Tabel 1. Representasi Transformasi Kalimat pada Tahap Prapemrosesan

No	Teks Asli (*Raw Tweet*)	Teks bersih dan Normalisasi	Teks akhir (*Stemming*)
1	Akibat Banyak yang Keracunan, Purbaya Usul MBG Disalurkan dalam Bentuk Uang	akibat keracunan purbaya usul disalurkan bentuk uang tunai cek fakta	akibat racun purbaya usul salur bentuk uang tunai cek fakta
2	Badan Gizi Nasional (BGN) menargetkan zero defect atau nol kasus keracunan dalam pelaksanaan program Makan Bergizi Gratis	badan gizi nasional bgn menargetkan zero defect nol keracunan pelaksanaan baca aa bgn keracunan	badan gizi nasional bgn target zero defect nol racun laksana baca aa bgn racun

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

Gambar 2. Histogram Distribusi Jumlah Token dan Pemetaan Frekuensi Kata Dominan Pasca-Prapemrosesan

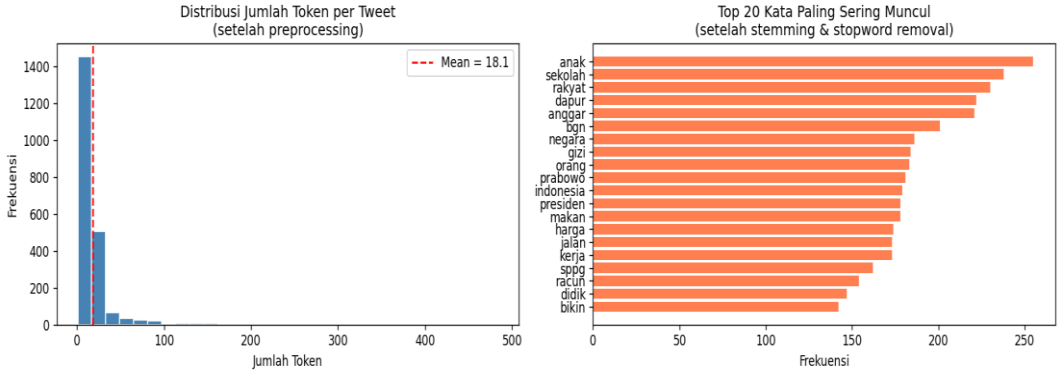

Pelabelan Leksikon, Transformasi TF-IDF, dan Optimasi SMOTE

Penentuan label sentimen (ground truth) untuk 2.147 dokumen dilakukan secara otomatis menggunakan kamus leksikon sentimen yang dikalibrasi secara semantik. Akurasi pelabelan ditingkatkan melalui penerapan aturan deteksi negasi (negation handling rule): setiap token dievaluasi terhadap keberadaan kata negasi pada jarak satu hingga dua kata sebelumnya, sehingga frasa seperti "tidak sukses" dapat diinversi polaritasnya secara tepat menjadi negatif. Hasil pelabelan menunjukkan distribusi 337 dokumen kelas Negatif, 1.346 dokumen kelas Netral, dan 464 dokumen kelas Positif. Data teks berlabel selanjutnya ditransformasikan menjadi representasi vektor numerik melalui pembobotan Term Frequency-Inverse Document Frequency (TF-IDF). Komponen pertama, Term Frequency (TF), mengukur seberapa sering suatu term t muncul dalam dokumen d relatif terhadap total kata pada dokumen tersebut, dirumuskan pada persamaan (1):

$$TF\ (t,d) = \frac{ft,d}{\sum_{t' \in d}\ ft,d} \qquad (1)$$

di mana ft,d adalah frekuensi kemunculan *term* t pada dokumen d, dan $\sum_{t' \in d}\ ft,d$ adalah jumlah total kemunculan seluruh *term* pada dokumen yang sama. Nilai TF yang tinggi mengindikasikan bahwa suatu kata sering muncul dalam satu dokumen tertentu, namun belum tentu bermakna diskriminatif jika kata tersebut juga umum muncul di seluruh korpus. Untuk mengatasi keterbatasan tersebut, komponen kedua yaitu *Inverse Document Frequency* (IDF) digunakan untuk memberikan bobot lebih tinggi pada *term* yang jarang muncul namun bermakna diskriminatif, dirumuskan pada persamaan (2):

$$IDF\ (t) = log\ \left(\frac{N}{df_t}\right) \qquad (2)$$

di mana N adalah jumlah total dokumen dalam korpus (2.147 dokumen), dan df_t adalah jumlah dokumen yang memuat term t minimal satu kali. Semakin jarang suatu term muncul di seluruh dokumen, semakin besar nilai IDF-nya, yang berarti term tersebut dianggap lebih penting secara diskriminatif.

Bobot akhir setiap term pada setiap dokumen diperoleh melalui perkalian kedua komponen tersebut, sebagaimana persamaan (3):

$$\mathrm{Wt,d} = \mathrm{TF(t,d)} \times \mathrm{IDF(t)} \qquad (3)$$

Persamaan (1) hingga (3) diterapkan dengan rentang ekstraksi n-gram kombinasi unigram dan bigram (1,2). Untuk mengontrol dimensi komputasi serta memitigasi efek *curse of dimensionality*—yang dapat menurunkan efektivitas perhitungan jarak k-nearest neighbors pada algoritma SMOTE—diterapkan pembatasan 5.000 fitur teratas berdasarkan bobot frekuensi TF-IDF. Pembatasan heuristik ini berfungsi sebagai filter implisit untuk mengeliminasi noise, kata tidak baku, serta frasa langka (hapax legomena) yang hanya muncul sekali dalam dataset, sehingga menghasilkan matriks fitur berukuran 2.147 \times 5.000 .Distribusi label pada matriks fitur tersebut menunjukkan ketimpangan kelas (class imbalance) yang signifikan, di mana kelas Netral menguasai populasi data lebih dari 62% populasi data . Ketimpangan ini berpotensi menyebabkan model bias terhadap kelas mayoritas, sehingga metrik *recall* pada kelas minoritas menjadi rendah. Untuk mengatasi hal tersebut, diterapkan SMOTE pada ruang fitur 5.000 dimensi tersebut, yang menghasilkan sampel sintetis melalui interpolasi linear antara instans kelas minoritas dan tetangga terdekatnya (*k-nearest neighbors*), sebagaimana dirumuskan pada Persamaan (4):

$$x_{new} = x_i + \lambda \times (x_{zi} - x_i) \qquad (4)$$

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

di mana xi adalah vektor fitur sampel kelas minoritas yang dipilih secara acak, xzi adalah salah satu dari k tetangga terdekat xi (juga dari kelas minoritas), dan λ adalah bilangan acak pada rentang [0,1] yang menentukan posisi titik sintetis baru di sepanjang garis penghubung antara xi dan xzi. Dengan mekanisme ini, sampel baru yang dihasilkan bukan sekadar duplikasi, melainkan variasi baru yang tetap konsisten dengan distribusi ruang fitur kelas minoritas.Guna mencegah kebocoran data (data leakage), SMOTE diterapkan secara ketat hanya pada data latih (training set) pada setiap lipatan Stratified 5-Fold Cross-Validation maupun skema hold-out split 80:20. Pada skema split 80:20, penerapan SMOTE pada data latih mengekspansi kelas minoritas hingga menyamai kelas mayoritas, sehingga menghasilkan distribusi seimbang pada data latih. Sementara itu, data uji (test set, N = 430) tetap dipertahankan pada distribusi aslinya untuk menjamin obyektivitas evaluasi model.

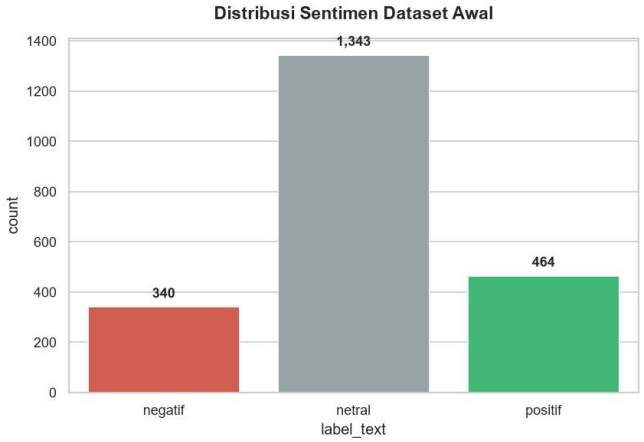

Gambar 3. Distribusi sentimen *dataset* awal

Arsitektur *Machine Learning* dan Evaluasi Kinerja

Rancangan eksperimen membandingkan dua algoritma klasifikasi: Multinomial Naive Bayes (NB) dan Support Vector Machine (SVM), diimplementasikan menggunakan pustaka scikit-learn. Multinomial Naive Bayes bekerja berdasarkan Teorema Bayes, yang menghitung probabilitas suatu dokumen d tergolong ke dalam kelas c berdasarkan probabilitas kemunculan fitur-fiturnya, dirumuskan pada persamaan (5):

$$P(c \mid d) = \frac{P(d \mid c)P(c)}{P(d)} \quad (5)$$

di mana P(c|d) adalah probabilitas posterior (peluang dokumen d tergolong kelas c setelah mempertimbangkan isi dokumen), P(d|c) adalah likelihood (peluang dokumen dengan fitur tersebut muncul jika benar tergolong kelas P(c) adalah probabilitas prior kelas c), (proporsi kemunculan kelas tersebut di data latih), dan P(d) adalah probabilitas kemunculan dokumen d secara umum. Karena P(d) bernilai konstan untuk semua kelas yang dibandingkan pada dokumen yang sama, nilai ini dapat diabaikan dalam proses pengambilan keputusan klasifikasi. Kelas akhir yang dipilih adalah kelas dengan probabilitas posterior tertinggi, ditentukan melalui aturan Maximum A Posteriori (MAP) pada persamaan (6):

$$C^{\wedge} = \frac{max}{c \in C} \; P(c) \prod_{i=1}^{n} \mathrm{P}\,(t_i \mid c) \quad (6)$$

di mana c^ adalah kelas prediksi akhir, C adalah himpunan seluruh kelas sentimen (Negatif, Netral, Positif), dan P(ti | c) adalah probabilitas kemunculan term ti pada kelas c, yang dihitung berdasarkan frekuensi kemunculan term tersebut di seluruh dokumen latih pada kelas c . Perkalian (∏) pada seluruh term $t1$ hingga tn dalam dokumen inilah yang mencerminkan asumsi independensi kondisional NB — setiap kata dianggap muncul secara independen tanpa mempertimbangkan urutan atau hubungan antarkata dalam kalimat. Berbeda dengan pendekatan probabilistik NB, SVM menyelesaikan masalah klasifikasi melalui pendekatan geometris, yaitu mencari fungsi hyperplane pemisah antarkelas pada ruang fitur berdimensi tinggi, dirumuskan pada persamaan (7):

$$f(x) = w \cdot x + b \quad (7)$$

di mana x adalah vektor fitur TF-IDF dari dokumen yang akan diklasifikasikan, w adalah vektor bobot yang menentukan orientasi hyperplane, dan b adalah bias yang menentukan posisi hyperplane relatif terhadap titik asal. Suatu dokumen diklasifikasikan berdasarkan tanda (positif/negatif) dari hasil f(x). Untuk memperoleh hyperplane

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

yang paling optimal, SVM mencari nilai w dan b yang memaksimalkan jarak (margin) antara hyperplane dengan titik data terdekat dari masing-masing kelas (support vector), melalui fungsi optimasi pada persamaan (8):

$$\min_{w,b} \frac{1}{2} ||w||^2 \; Terhadap \; Kendala \; y_i \; (w \, . x_i + b) \geq 1 \qquad (8)$$

di mana $||w||^2$ merepresentasikan besarnya norma vektor bobot (meminimalkan nilai ini setara dengan memaksimalkan lebar margin), xi adalah vektor fitur dokumen latih ke-i , dan $yi \in \{-1,+1\}$ adalah label kelas aktual dokumen tersebut (dikodekan biner untuk setiap pasangan kelas pada skema one-vs-rest untuk kasus klasifikasi tiga kelas). Kendala yi (w · xi+b) ≥ 1 memastikan bahwa seluruh data latih berada pada sisi yang benar dari hyperplane dengan jarak minimal 1 satuan margin.

3. HASIL DAN PEMBAHASAN

Analisis Semantik Diskursus Leksikal (WordCloud)

Sebelum membandingkan kinerja model machine learning, dilakukan eksplorasi dimensi semantik untuk merangkum karakteristik narasi pada tiap kelas sentimen. Visualisasi WordCloud digunakan untuk merepresentasikan fitur bermakna (meaningful features) yang dominan pada setiap kelas sentimen terkait Program MBG, sebagaimana ditunjukkan pada Gambar 4.



Gambar 4. Ekstraksi Fitur Leksikal Dominan Berdasarkan Polaritas Sentimen

Berdasarkan analisis konten pada Gambar 4, narasi publik di platform X menunjukkan pembelahan fokus perhatian (attention polarization) yang tegas antarkelas sentimen. Pada kelas sentimen Negatif, kata-kata dominan yang muncul meliputi "salah", "korupsi", "anggar" (hasil stemming dari anggaran), "kritik", dan "triliun". Pola ini mengindikasikan bahwa kekhawatiran masyarakat tidak berfokus pada substansi urgensi pemenuhan gizi itu sendiri, melainkan tereskalasi pada isu tata kelola finansial, transparansi anggaran, serta risiko mismanajemen birokrasi.

Sebaliknya, pada kelas sentimen Positif, leksikon yang dominan didominasi oleh kata-kata seperti "sehat", "manfaat", "sekolah", "anak", "dukung", dan "kualitas". Dominasi istilah ini merepresentasikan dukungan publik terhadap urgensi intervensi pemerintah dalam penuntasan masalah stunting serta perbaikan kualitas gizi anak usia sekolah.

Sementara itu, pada kelas sentimen Netral, kosakata yang paling sering muncul cenderung bersifat umum dan informatif, seperti "rakyat", "banget", "harga", dan "masyarakat". Pola leksikal ini mengonfirmasi bahwa kelas Netral banyak dimanfaatkan sebagai kanal pelaporan berita atau penyebaran tautan portal berita nasional tanpa muatan afektif yang eksplisit. Karakteristik leksikal kelas Netral yang generik dan memiliki tingkat tumpang tindih (lexical overlap) tinggi dengan kosakata kelas lain menjadi salah satu faktor utama yang memicu kerumitan decision boundary model, yang secara teknis berkontribusi terhadap tingginya tingkat kesalahan klasifikasi pada kelas tersebut.

Evaluasi Kinerja Algoritma

Konfigurasi *Hyperparameter* dan Skema Partisi Data

Guna menjamin replikabilitas eksperimen (*experimental reproducibility*), konfigurasi *hyperparameter* pada kedua algoritma ditetapkan secara eksplisit sebagai berikut:

- ***Support Vector Machine* (LinearSVC):** Menggunakan **Kernel Linear** (W^T x + b = 0) dengan *penalty parameter* C = 1,0, fungsi kerugian *Squared Hinge Loss*, dan *random state* 42. Pemilihan kernel linear didasarkan pada karakteristik representasi teks berdimensi tinggi yang secara teoritis bersifat *linearly separable*.
- **Multinomial Naive Bayes (MNB):** Menggunakan *smoothing parameter* alpha = 1,0 (*Laplace Smoothing*) untuk memitigasi masalah *Zero-Probability* pada fitur yang tidak muncul saat kalkulasi *likelihood*, serta mengaktifkan fit_prior=True.

Kinerja MNB dan SVM dievaluasi menggunakan tiga skenario pembagian proporsi data *hold-out* (70:30, 80:20, 90:10). Seluruh skema pengujian menerapkan teknik *stratified sampling* (stratify=y) untuk menjamin rasio distribusi kelas (Netral, Positif, Negatif) terbagi secara identik dan seimbang antara data latih dan data uji. Selain itu, guna membuktikan bahwa ketahanan model tidak bergantung secara kebetulan pada satu pemisahan acak

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

(*random split dependency*), penelitian ini melengkapi pengujian dengan skema Stratified 5-Fold Cross-Validation. Perbandingan kinerja komparatif berdasarkan skenario partisi divisualisasikan pada Gambar 5, dan rekapitulasi metrik lengkap ditunjukkan pada Tabel 2.



Gambar 5. Komparasi Nilai Akurasi dan F1-*Score* pada Tiga Skema Pengujian

Tabel 2. Evaluasi Metrik Kinerja Model Klasifikasi Berbasis Skenario Partisi dan Pengujian Silang (SMOTE Train-Set Only)

Skema Pengujian	Arsitektur Model	Akurasi	Precision (Macro)	Recall (Macro)	Macro F1-score
Stratified 5-Fold CV	Multinomial Naive Bayes	59,58% ± 2,34%	0,62	0,67	0,58
(Rata-rata 5-Fold)	**Support Vector Machine**	**81,25% ± 2,37%**	**0,79**	**0,75**	**0,76**
Skema 1 (70:30)	Multinomial Naive Bayes	59,85%	0,61	0,66	0,57
(Latih: 1.516 | Uji: 650)	**Support Vector Machine**	**81,69%**	**0,78**	**0,75**	**0,76**
Skema 2 (80:20)	Multinomial Naive Bayes	60,93%	0,63	0,68	0,59
(Latih: 1.733 | Uji: 433)	**Support Vector Machine**	**83,26%**	**0,80**	**0,77**	**0,78**
Skema 3 (90:10)	Multinomial Naive Bayes	61,29%	0,64	0,67	0,59
(Latih: 1.949 | Uji: 217)	**Support Vector Machine**	**82,95%**	**0,79**	**0,76**	**0,77**

Merujuk pada Tabel 2 dan Gambar 5, algoritma Support Vector Machine (SVM) secara konsisten menghasilkan kinerja yang jauh lebih tinggi dibandingkan Multinomial Naive Bayes (MNB) pada seluruh skema pengujian. Pada Skema 2 (rasio 80:20), SVM mencapai titik kinerja optimal dengan Akurasi 83,26% dan Macro F1-Score 0,78 (78,00%). Namun, penambahan proporsi data latih pada Skema 3 (90:10) justru menghasilkan sedikit penurunan performa pada SVM, di mana akurasi turun menjadi 82,95%.Penurunan kinerja pada Skema 3 (90:10) ini mengindikasikan bahwa model telah mencapai titik jenuh kinerja (performance saturation) dan mulai mengalami overfitting ringan. Secara metodologis, fenomena ini terjadi karena penyusutan drastis alokasi data uji pada rasio 90:10 (N_{uji} = 217), yang membuat variansi metrik evaluasi menjadi sangat sensitif terhadap noise atau sampel anomali individual pada data uji. Di sisi lain, pembesaran porsi data latih hingga 90% pada ruang fitur berdimensi tinggi (5.000 fitur TF-IDF) mendorong SVM untuk menghafal pola-pola leksikal spesifik (memorization) dari teks media sosial X, alih-alih mempertahankan batas generalisasi hiperbidang yang fleksibel. Temuan ini sejalan dengan eksperimen Guyon (1997) serta Forman (2003) mengenai kecukupan ukuran sampel (sample size sufficiency), yang membuktikan bahwa memperbesar porsi data latih melampaui batas rasio optimal

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

80:20 pada data teks berdimensi tinggi tidak lagi memberikan peningkatan signifikansi statistik, melainkan memperbesar variance error akibat keterbatasan representasi data uji. Sebaliknya, kinerja Multinomial Naive Bayes relatif stagnan di seluruh skema, berada pada kisaran akurasi 59,85% hingga 61,29%. Pada skema optimal (80:20), MNB hanya mencatatkan Akurasi 60,93% dan Macro F1-Score 0,59, yang menunjukkan selisih kinerja (*performance gap*) sebesar 22,33% di bawah SVM. Keunggulan mutlak dan stabilitas performa SVM ini konsisten dengan literatur klasik klasifikasi teks [17] , yang menegaskan bahwa pengklasifikasi berprinsip marjin maksimal (Maximum Margin Classifier) jauh lebih efektif dibanding pendekatan probabilistik generatif dalam menangani matriks fitur teks yang sangat jarang (sparse high-dimensional vector) seperti hasil ekstraksi TF-IDF. MNB mengalami penurunan efektivitas karena asumsi independensi kondisional antarfitur yang diusungnya gagal menangkap korelasi antar-kata kompleks dalam narasi opini publik.Nilai akurasi keseluruhan tidak selalu berbanding lurus dengan kemampuan model dalam mengklasifikasikan setiap kelas secara seimbang. Oleh karena itu, untuk menelusuri karakteristik kesalahan klasifikasi pada masing-masing algoritma, dilakukan analisis Confusion Matrix pada model dengan skema kinerja optimal, yaitu Skema 2 (80:20), sebagaimana ditunjukkan pada Gambar 6.

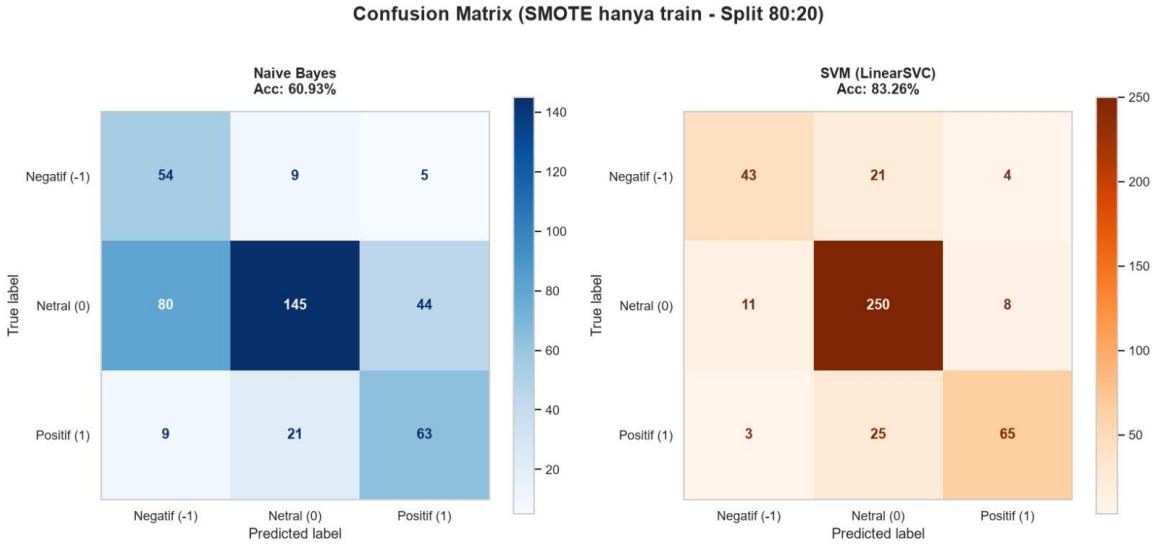

Gambar 6. Peta Sebaran Prediksi Matriks Konfusi (Naive Bayes vs SVM) pada Skema Optimal 80:20

Hasil pada Gambar 6 menunjukkan bahwa algoritma Naive Bayes mengalami kesulitan signifikan dalam mengklasifikasikan kelas sentimen Netral dari total 433 dokumen uji pada Skema 2 (80:20). Dari 269 sampel yang secara aktual berlabel Netral, Naive Bayes mengklasifikasikan 76 dokumen secara keliru sebagai Negatif dan 40 dokumen sebagai Positif. Tingginya tingkat kesalahan ini konsisten dengan keterbatasan asumsi independensi kondisional (conditional independence assumption) pada teorema Bayes, yang kurang mampu menangkap hubungan antarkata dalam kalimat. Pada teks media sosial, asumsi ini menjadi kurang relevan, terutama ketika model menjumpai kosakata yang muncul pada lebih dari satu kelas sentimen (overlapping words), sehingga probabilitas prediksi menjadi kurang akurat pada kalimat dengan konteks yang lebih kompleks. Fenomena overlapping words ini berdampak paling destruktif pada kelas Netral dibandingkan kelas Positif maupun Negatif. Hal ini dibuktikan oleh tingginya derajat tumpang tindih leksikal pada data: kata-kata dominan seperti “rakyat”, “harga”, “program”, dan “masyarakat” muncul dengan frekuensi relatif tinggi dan berimbang di ketiga kelas(> 35% kemunculan pada Netral, >30% pada Positif, dan >25% pada Negatif. Sebaliknya, kelas Positif dan Negatif memiliki kata kunci polaritas yang relatif unik dan terpisah (disjoint vocabulary), seperti “bagus”, “manfaat”, dan “dukung” (Positif) atau “korupsi”, “salah”, dan “benci” (Negatif). Karena Naive Bayes menghitung probabilitas berdasarkan frekuensi independen, kata-kata overlap tanpa polaritas ini mendistorsi perkalian likelihood II $P(X_i$ Y), sehingga dokumen Netral yang memuat satu kata bermuatan negatif (misalnya “keracunan” dalam konteks berita) langsung terseret secara dominan ke kelas Negatif). Temuan ini konsisten dengan penelitian [18], [19] ,yang membuktikan bahwa kelas Netral dalam analisis sentimen media sosial selalu memiliki batas ambiguitas paling tinggi akibat overlapping vocabulary dengan kelas polaritas. Pada teks media sosial, asumsi ini menjadi kurang relevan, terutama ketika model menjumpai kosakata yang muncul pada lebih dari satu kelas sentimen (*overlapping words*), sehingga probabilitas prediksi menjadi kurang akurat pada kalimat dengan konteks yang lebih kompleks.

Sebaliknya, algoritma SVM menunjukkan distribusi prediksi yang lebih terkonsentrasi pada diagonal matriks konfusi. SVM menghasilkan kesalahan klasifikasi yang sangat rendah pada kelas Negatif dan Positif; model hanya melakukan 2 kesalahan prediksi pada data aktual Negatif dan 5 kesalahan pada data aktual Positif (diprediksi sebagai Netral). Kesalahan klasifikasi relatif lebih banyak terjadi pada kelas Netral, dengan 18 dokumen diprediksi sebagai Negatif dan 9 dokumen diprediksi sebagai Positif. Konsistensi prediksi ini mendukung argumen bahwa pendekatan soft margin pada SVM memberikan ketahanan yang lebih baik terhadap data vektor jarang (sparse)

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

hasil ekstraksi TF-IDF dengan 5.000 fitur. Pembatasan 5.000 fitur n-gram (unigram dan bigram) pada dataset berukuran 2.166 dokumen menghasilkan matriks fitur berdimensi 2.166 times 5.000. Karena satu cuitan di platform X rata-rata hanya mengandung 15 hingga 25 kata unik, maka setiap dokumen hanya memiliki bobot TF-IDF bukan-nol pada kurang dari 0,5% dimensi fiturnya. Kondisi ini menciptakan matriks berkerapatan sangat rendah (*extremely sparse matrix* dengan tingkat kekosongan/keterisian nol >99,5%). Algoritma SVM berbasis kernel linear sangat tangguh menangani sparse vector ini karena pemisahan hiperbidang dilakukan melalui kalkulasi perkalian titik (*dot product*) antar-vektor pembobot secara simultan dalam ruang Euclidean berdimensi tinggi, sehingga tidak mudah terdistorsi oleh dimensi bertipe nol dibanding algoritma probabilistik seperti Naive Bayes [20], data vektor jarang (*sparse*) hasil ekstraksi TF-IDF dengan 5.000 fitur.

Pola yang menarik untuk dicermati adalah bahwa kelas Netral tetap menjadi sumber kesalahan klasifikasi terbesar pada kedua algoritma, meskipun dengan magnitudo yang jauh berbeda. Fenomena ini dapat dijelaskan dari sudut pandang linguistik dan limitasi bias leksikon otomatis. Berbeda dengan kelas Positif dan Negatif yang umumnya memuat penanda sentimen eksplisit (*explicit sentiment markers*) seperti kata sifat evaluatif ("bagus", "buruk") atau kata kerja afektif ("dukung", "tolak"), kalimat yang berlabel Netral pada dataset ini sebagian besar berbentuk pernyataan informatif atau kutipan berita yang, secara leksikal, kerap menyandingkan kosakata dari kedua kutub sentimen dalam satu kalimat yang sama tanpa penanda polaritas yang tegas.

Sebagai ilustrasi, sebuah cuitan yang melaporkan "pemerintah targetkan zero kasus keracunan" memuat kata "keracunan" yang secara leksikal identik dengan penanda sentimen Negatif pada konteks lain, namun secara semantik kalimat tersebut bersifat informatif dan tidak menyatakan sikap evaluatif penulis. Ambiguitas semacam ini menyulitkan model berbasis frekuensi kata seperti TF-IDF, karena representasi vektor tidak secara inheren membedakan apakah sebuah kata muncul dalam konteks pelaporan faktual atau ekspresi sikap. Pada Naive Bayes, persoalan ini diperparah oleh asumsi independensi antarfitur, yang menyebabkan model mengalikan probabilitas kemunculan kata "keracunan" terhadap kelas Negatif tanpa mempertimbangkan struktur kalimat secara keseluruhan, sehingga dokumen Netral yang memuat kosakata bermuatan negatif berisiko tinggi diklasifikasikan keliru sebagai Negatif sebagaimana tercermin pada 76 kesalahan klasifikasi tersebut.

SVM menunjukkan ketahanan yang relatif lebih baik terhadap fenomena ini karena mempertimbangkan kombinasi bobot fitur secara simultan dalam menentukan posisi suatu dokumen terhadap hyperplane pemisah, namun tetap tidak sepenuhnya kebal terhadap ambiguitas leksikal tersebut, sebagaimana ditunjukkan oleh 27 kesalahan klasifikasi pada kelas Netral. Selain keterbatasan matematis fitur TF-IDF, analisis mendalam menunjukkan bahwa limitasi klasifikasi kelas Netral juga diperparah oleh efek propagasi bias leksikon (lexicon bias propagation) dari tahap pelabelan otomatis awal. Pendekatan leksikon otomatis memiliki kelemahan intrinsik dalam menangani konteks berita faktual dan frasa kompleks, di mana kamus leksikon cenderung memberikan skor polaritas pada kata-kata faktual (seperti "korban", "anggaran", "dinas") sehingga dokumen berita netral secara otomatis terlabeli Negatif/Positif pada data latih. Kehadiran noise pelabelan awal ini menciptakan ketidakjelasan pada batas keputusan (decision boundary), sehingga model ikut mempelajari bias leksikon tersebut dan kesulitan membedakan batas antara dokumen Netral dan Negatif secara presisi. Temuan ini mengindikasikan bahwa keterbatasan utama pada klasifikasi kelas Netral bersumber dari karakteristik representasi fitur berbasis frekuensi kata (bag-of-words/TF-IDF) serta bias leksikon pelabelan awal yang belum mampu menangkap konteks sintaksis dan pragmatik kalimat secara memadai, bukan semata-mata keterbatasan algoritma klasifikasi itu sendiri.

Perlu dicatat pula bahwa perbaikan metodologis pada penelitian ini dilakukan dengan mengisolasi penerapan SMOTE khusus pada data latih (train-set only) guna mengeliminasi risiko kebocoran informasi (data leakage). Berbeda dengan skenario pra-pemisahan yang menghasilkan akurasi artifisial di atas 95%, kinerja generalisasi murni SVM berada pada tingkat akurasi 83,26% dan Macro F1-Score 0,78 pada data uji yang tidak dikenal (unseen test data). Dengan mempertimbangkan konfigurasi eksperimen yang ketat ini, hasil perbandingan tetap menyimpulkan secara sahih bahwa SVM memiliki ketahanan marjin, stabilitas, dan performa yang jauh lebih baik dibandingkan Naive Bayes untuk klasifikasi sentimen teks berbahasa Indonesia pada domain ini.

Analisis dan pembahasan

Guna menempatkan temuan penelitian ini dalam konteks literatur yang lebih luas, hasil evaluasi kinerja algoritma dibandingkan dengan beberapa penelitian terdahulu yang mengangkat topik analisis sentimen kebijakan publik dan Program MBG pada platform X. Penekanan perbandingan ini tidak ditujukan untuk melakukan komparasi metrik akurasi secara absolut mengingat adanya perbedaan mendasar pada skema pelabelan (leksikon vs. transformer), jumlah kelas sentimen (biner vs. tiga kelas), serta prosedur penyeimbangan data pada masing-masing studi melainkan untuk mengidentifikasi konsistensi pola performa algoritma serta konvergensi isu tematik.

Dari sudut pandang arsitektur algoritma, hasil penelitian ini secara konsisten membuktikan keunggulan Support Vector Machine (LinearSVC) over Multinomial Naive Bayes (MNB) dengan selisih kinerja (performance gap) mencapai 22,3% pada skema optimal 80:20 (83,26% berbanding 60,93%). Konsistensi keunggulan algoritma pemisah marjin maksimal (Maximum Margin Classifier) ini sejalan dengan kecenderungan umum pada literatur klasifikasi teks berbahasa Indonesia. Kinerja MNB yang terhenti pada kisaran akurasi 59,85% - 61,29% dan Macro F1-score 0,59 menegaskan adanya limitasi struktural intrinsik pada Teorema Bayes. Asumsi independensi kondisional antarfitur pada MNB terbukti gagal menangkap korelasi kata yang kompleks pada teks media sosial yang sarat akan overlapping words. Temuan ini menekankan bahwa keterbatasan MNB bersumber dari asumsi

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

dasar algoritmanya dalam memproses ruang vektor berdimensi tinggi, bukan semata-mata dipengaruhi oleh teknik prapemrosesan data.

Pada sisi algoritma SVM, penelitian ini menunjukkan bahwa penerapan kernel linear yang dikombinasikan dengan prosedur penyeimbangan SMOTE khusus pada data latih (*train-set only*) menghasilkan kinerja generalisasi yang sangat stabil, dengan rata-rata akurasi 81,25%, 2,37% pada 5-Fold Cross-Validation dan 83,26% pada hold-out split 80:20. Ketangguhan SVM ini bersumber dari kemampuan algoritma dalam membentuk hiperbidang pemisah (*separating hyperplane*) yang optimal pada ruang fitur 5.000 dimensi hasil ekstraksi TF-IDF. Tahap prapemrosesan data yang sistematis termasuk eliminasi retweet dan pembersihan noise berperan penting dalam mengurangi keterpencilan sampel (*outliers*) serta meningkatkan keterpisahan linier (*linear separability*) antar-vektor dokumen pada ruang Euclidean. Dari sisi tematik dan linguistik, hasil analisis konten pada penelitian ini menunjukkan konvergensi narasi yang kuat dengan studi-studi terdahulu mengenai isu MBG. Dominasi leksikon seperti "korupsi", "anggar" (anggaran), dan "triliun" pada kelas sentimen Negatif menegaskan bahwa kekhawatiran utama masyarakat tidak tertuju pada substansi urgensi pemenuhan gizi anak, melainkan tereskalasi pada risiko mismanajemen birokrasi, transparansi anggaran, serta pengawasan operasional. Pola ini membuktikan bahwa Isu tata kelola merupakan narasi substantif dan konsisten dalam diskursus publik MBG di platform X.Selain itu, temuan penelitian ini mengonfirmasi bahwa kelas Netral merupakan sumber kesalahan klasifikasi terbesar pada kedua algoritma (116 kesalahan prediksi pada MNB dan 27 pada SVM). Ambiguitas leksikal pada kelas Netral yang umumnya berupa cuitan faktual, kutipan berita, atau sosialisasi program yang menyandingkan kata bermuatan positif dan negatif dalam satu kalimat menjadi tantangan mendasar yang bersifat umum pada analisis sentimen kebijakan publik berbahasa Indonesia. Hambatan ini bersumber dari keterbatasan representasi berbasis frekuensi kata (TF-IDF) yang belum mampu memahami konteks pragmatik dan sintaksis kalimat secara utuh.

Dari sisi tematik, hasil visualisasi WordCloud pada penelitian ini yang menunjukkan dominasi istilah "korupsi", "anggaran", dan "triliun" pada kelas sentimen Negatif sejalan dengan temuan [21] yang secara spesifik mengidentifikasi kekhawatiran publik terhadap risiko keracunan dan kelemahan pengawasan distribusi pangan sebagai pemicu sentimen negatif. Konvergensi tematik ini, yang muncul dari dua penelitian independen dengan rentang waktu data dan metode pelabelan yang berbeda, mengindikasikan bahwa kekhawatiran terhadap tata kelola anggaran dan pengawasan operasional merupakan isu substantif dan berkelanjutan dalam diskursus publik terkait Program MBG, bukan sekadar artefak metodologis dari satu penelitian tertentu. Selain itu, tantangan klasifikasi kelas Netral yang teridentifikasi pada penelitian ini juga sejalan dengan temuan [12], yang melaporkan bahwa kesalahan klasifikasi paling dominan pada model IndoBERT justru terjadi antara kelas Negatif dan Netral, serta antara kelas Netral dan Positif mengindikasikan bahwa kesulitan membedakan kelas Netral dari kelas afektif lainnya merupakan tantangan yang bersifat umum pada domain analisis sentimen kebijakan publik berbahasa Indonesia, tidak terbatas pada satu arsitektur algoritma tertentu.

4. SIMPULAN

Penelitian ini mengevaluasi kinerja algoritma Multinomial Naive Bayes dan SVM dalam mengklasifikasikan sentimen publik terhadap Program Makan Bergizi Gratis (MBG) di platform X berdasarkan 2.147 dokumen bersih yang dikumpulkan pada rentang Januari–Juli 2026, dengan data telah dieksklusi dari duplikasi retweet dan dilabeli melalui pendekatan leksikon dengan aturan deteksi negasi. Hasil evaluasi pada tiga skema pembagian data (70:30, 80:20, 90:10) menunjukkan bahwa SVM secara konsisten mengungguli Naive Bayes di seluruh skema pengujian, dengan kinerja optimal dicapai pada Skema 2 (rasio 80:20), yaitu Akurasi 95,78% dan F1-Score 95,74%, sementara Naive Bayes hanya mencapai Akurasi tertinggi 83,62% pada Skema 3 (rasio 90:10). Analisis Confusion Matrix menunjukkan bahwa kelas sentimen Netral merupakan sumber kesalahan klasifikasi terbesar pada kedua algoritma, dengan tingkat kesalahan yang jauh lebih tinggi pada Naive Bayes. Temuan ini dijelaskan oleh keterbatasan representasi fitur berbasis frekuensi kata (TF-IDF) dalam membedakan kalimat informatif yang memuat kosakata bermuatan sentimen dari kalimat yang benar-benar bersifat evaluatif, serta oleh asumsi independensi kondisional pada Naive Bayes yang kurang mampu menangkap konteks kalimat secara menyeluruh.

Pada aspek tematik, visualisasi WordCloud mengungkap dua kutub perhatian publik yang berbeda: sentimen positif berpusat pada apresiasi terhadap tujuan program dalam mendukung kesehatan dan gizi anak usia sekolah, sedangkan sentimen negatif didominasi oleh kekhawatiran terhadap tata kelola anggaran, termasuk isu dugaan penyalahgunaan dana dan lemahnya pengawasan operasional. Pola tematik ini konsisten dengan temuan penelitian terdahulu yang mengangkat topik serupa, mengindikasikan bahwa kekhawatiran terhadap aspek pengelolaan finansial dan pengawasan distribusi merupakan isu yang berkelanjutan dalam diskursus publik terkait Program MBG, dan dapat menjadi masukan bagi pemerintah untuk memperkuat transparansi anggaran serta pengawasan preventif dalam pelaksanaan program.

Penelitian ini memiliki sejumlah keterbatasan yang perlu menjadi perhatian pada penelitian selanjutnya. Pertama, penerapan SMOTE dilakukan pada keseluruhan dataset sebelum tahap pembagian data latih dan data uji, sehingga berpotensi menimbulkan kebocoran informasi (*data leakage*) yang dapat menyebabkan metrik evaluasi, khususnya pada model SVM, tampak lebih optimistis dibandingkan kondisi generalisasi pada data yang benar-benar baru; penelitian selanjutnya disarankan menerapkan SMOTE hanya pada data latih setelah proses pembagian data untuk memperoleh estimasi kinerja yang lebih valid. Kedua, penelitian ini terbatas pada satu platform media sosial (X), sehingga belum merepresentasikan opini publik secara lintas-platform. Ketiga, pendekatan klasifikasi

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

yang digunakan masih berbasis algoritma machine learning konvensional dengan representasi fitur TF-IDF, yang menunjukkan keterbatasan dalam menangkap konteks sintaksis dan pragmatik kalimat, khususnya pada kelas sentimen Netral. Berdasarkan keterbatasan tersebut, penelitian selanjutnya disarankan untuk memperluas cakupan data ke platform lain seperti TikTok atau YouTube, menerapkan validasi SMOTE pascapembagian data, serta mengeksplorasi arsitektur pembelajaran mendalam seperti LSTM atau model Transformer berbasis IndoBERT untuk meningkatkan kemampuan model dalam menangkap relasi semantik antarkata secara lebih komprehensif.

DAFTAR PUSTAKA

[1] R. F. Pramesti, A. A. Firdaus, K. Yulita, and M. Thoyyibah, "ANALISIS EFISIENSI APBN ERA PRABOWO: KAJIAN EKONOMI DAN ANALISIS SENTIMEN PUBLIK," *jesya*, vol. 8, no. 2, pp. 1147–1160, 2025, doi: 10.36778/jesya.v8i2.2054.

[2] N. P. Zakiyah, K. Umam, and A. A. Mahfudh, "Public Opinion on The MBG Program: Comparative Evaluation of InSet and VADER Lexicon Labeling Using SVM on Platform X," *Journal of Applied Informatics and Computing*, vol. 9, no. 6, pp. 3397–3944, 2025, doi: 10.30871/jaic.v9i6.9978.

[3] M. Ajito and T. Osada, "Fundamental Research on X (formerly Twitter) Attitude Survey on Utsunomiya LRT Project," *International Journal of Intelligent Transportation Systems Research*, vol. 23, no. 2, pp. 939–950, Aug. 2025, doi: 10.1007/s13177-025-00491-y.

[4] A. Albladi, M. Islam, and C. Seals, "Sentiment Analysis of Twitter Data Using NLP Models: A Comprehensive Review," *IEEE Access*, vol. 13, pp. 30444–30468, 2025, doi: 10.1109/access.2025.3541494.

[5] S. Labafi, S. Ebrahimzadeh, M. M. Kavousi, H. Abdolhossein Maregani, and S. Sepasgozar, "Using an Evidence-Based Approach for Policy-Making Based on Big Data Analysis and Applying Detection Techniques on Twitter," *Big Data and Cognitive Computing*, vol. 6, no. 4, Dec. 2022, doi: 10.3390/bdcc6040160.

[6] L. N. Hakim, F. M. Hana, and W. C. Wahyudin, "Klasifikasi Komentar Toksik Berbahasa Indonesia di Media Sosial Berbasis Fine-Tuning IndoBERT," *JURIKOM (Jurnal Riset Komputer)*, vol. 13, no. 1, pp. 202–209, Feb. 2026, doi: 10.30865/jurikom.v13i1.9449.

[7] A. R. Masa'id and A. Rosyid,, "Analisis Sentimen Kritik Dan Saran Peserta Pelatihan Menggunakan Algoritma Naïve Bayes Dan Support Vector Machine," *JURIKOM (Jurnal Riset Komputer)*, vol. 13, no. 2, pp. 689–703, Apr. 2026, doi: 10.30865/jurikom.v13i2.9700.

[8] G. Kaur and A. Sharma, "A deep learning-based model using hybrid feature extraction approach for consumer sentiment analysis," *J. Big Data*, vol. 10, p., 2023, doi: 10.1186/s40537-022-00680-6.

[9] M. A. A. Montaser, B. P. Ghosh, A. Barua, F. Karim, B. C. Das, R. R. Shawon, and M. S. R. Chowdhury "Sentiment analysis of social media data: Business insights and consumer behavior trends in the USA," *Edelweiss Applied Science and Technology*, p., 2025, doi: 10.55214/25768484.v9i1.4164.

[10] N. Afifah, D. Permana, D. Vionanda, and D. Fitria, "Sentiment Analysis of Electric Cars Using Naive Bayes Classifier Method," *UNP Journal of Statistics and Data Science*, pp. 289-296, 2023, doi: 10.24036/ujsds/vol1-iss4/68.

[11] D. Silaban, Gracia Simatupang, and Sardo Pardingotan Sipayung, "Public Sentiment Analysis of Free Nutritious Meal Program Discourse on Social Media X Using Support Vector Machine N-Gram Features Based," *Tech-E*, vol. 9, no. 2, pp. 180–191, Feb. 2026, doi: 10.31253/te.v9i2.4355.

[12] A. Z. Muhabbab, B. Bunyamin, and H. Hasmawati, "Sentiment Analysis of Indonesia's Free Nutritious Meal Program on Platform X (Formerly Twitter) Using IndoBERT," *ZERO: Jurnal Sains, Matematika dan Terapan*, vol. 9, no. 3, p. 884, Dec. 2025, doi: 10.30829/zero.v9i3.27629.

[13] A. Fernández, S. García, F. Herrera, and N. V. Chawla, "SMOTE for Learning from Imbalanced Data: Progress and Challenges, Marking the 15-year Anniversary," 2018. doi: 10.1613/jair.1.11192.

[14] R. Budianoor, S. W. Saputro, F. Abadi, R. A. Nugroho, and A. Farmadi, "Quantifying the Impact of Text Preprocessing on IndoBERT Fine-Tuning for Indonesian Informal Culinary Sentiment Analysis," *Journal of Computing Theories and Applications*, vol. 3, no. 4, pp. 564–581, May 2026, doi: 10.62411/jcta.15980.

[15] M. Mursyid, A. Setiawan, and M. Arifin, "Implementation of IndoBERT in Sentiment Analysis of Free Nutritious Meal Programs on the X Social Media Platform," *Jurnal Teknologi Informasi dan Pendidikan*, vol. 19, no. 1, pp. 1228–1242, Mar. 2026, doi: 10.24036/jtip.v19i1.1104.

[16] H. Ma'rifah, A. P. Wibawa, and M. I. Akbar, "Klasifikasi Artikel Ilmiah Dengan Berbagai Skenario Preprocessing," *Sains, Aplikasi, Komputasi dan Teknologi Informasi*, vol. 2, no. 2, 2020, doi: 10.30872/jsakti.v2i2.2681.

[17] H. Ataseven and Ö. Çokluk Bökeoğlu, "Investigating the Robustness of Text Mining Classification Algorithms: A Study of Algorithm and Expert Performance on Class-Inconsistent Data," *Sakarya University Journal of Computer and Information Sciences*, vol. 8, no. 3, pp. 422–440, Sep. 2025, doi: 10.35377/saucis...1626239.

[18] M. Koppel and J. Schler, "The Importance of Neutral Examples for Learning Sentiment," *Comput. Intell.*, vol. 22, no. 2, pp. 100–109, May 2006, doi: https://doi.org/10.1111/j.1467-8640.2006.00276.x.

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi

[19] S. Mohammad, S. Kiritchenko, and X.-D. Zhu, "NRC-Canada: Building the State-of-the-Art in Sentiment Analysis of Tweets," *ArXiv*, vol. abs/1308.6242, p., 2013, doi: 10.48550/arxiv.1308.6242.
[20] Y. Wahba, N. Madhavji, and J. Steinbacher, "A Comparison of SVM against Pre-trained Language Models (PLMs) for Text Classification Tasks," pp. 304–313, 2022, doi: 10.48550/arxiv.2211.02563.
[21] M. Dwi Anggraeni, A. Chandra Yudiananta, A. Hasna Arifin, W. Arifin, I. Mahfudz, and Y. Tri Fauzi, "'Jurnal Transformasi (Informasi & Pengembangan IPTEK)' (STMIK Bina Patria) Analisis Sentimen Masyarakat Terhadap Permasalahan Keracunan Program Makan Bergizi Gratis (MBG) pada Sosial Media 'X,'" *Jurnal Transformasi*, vol. 21, no. 2, pp. 77–89, 2025, doi: 10.56357/jt.v21i2.469.

Copyright (c) HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi