

Analisis Sentimen Program Makan Bergizi Gratis pada Platform X dengan *Naïve Bayes* dan SVM

Sentiment Analysis of the Free Nutritious Meals Program on the X Platform Using Naïve Bayes and SVM

M. Jagad Kesuma^{*1}, Ari Muzakir²

^{1,2}*Teknik Informatika, Universitas Bina Dharma, Palembang, 30111, Indonesia*

¹jagadkesuma2004@gmail.com, ²arimuzakir@binadarma.ac.id

Received: July 14, 2026 | Revised: July 16, 2026 | Accepted: September 22, 2026 | Published: September 30, 2026



COSIE is licensed a *Creative Commons Attribution-Share Alike 4.0 International License*

Abstrak

Program Makan Bergizi Gratis (MBG) merupakan program pemerintah yang bertujuan mendukung pemenuhan gizi masyarakat dan peningkatan kualitas sumber daya manusia. Tingginya interaksi masyarakat di media sosial X menjadikan platform tersebut sebagai sumber data untuk mengidentifikasi respons publik terhadap pelaksanaan MBG. Penelitian ini bertujuan menganalisis sentimen masyarakat terhadap program MBG serta membandingkan kinerja algoritma Naïve Bayes dan Support Vector Machine (SVM). Data penelitian berupa 5.048 tweet berbahasa Indonesia yang dikumpulkan melalui Browser Automation Scraping. Data diproses melalui tahapan cleaning, case folding, normalization, tokenizing, stopword removal, dan stemming, kemudian diberi label sentimen positif, netral, dan negatif menggunakan pendekatan berbasis leksikon. Dataset dibagi dengan perbandingan 80:20 menjadi 3.810 data latih dan 953 data uji. SMOTE diterapkan pada data latih untuk mengatasi ketidakseimbangan kelas. Hasil penelitian menunjukkan bahwa Naïve Bayes sebelum SMOTE memperoleh akurasi 35,36%, sedangkan setelah SMOTE meningkat menjadi 70,20%. SVM dengan SMOTE menghasilkan akurasi sebesar 85,73% atau 817 dari 953 data uji, lebih tinggi 15,53 poin persentase dibandingkan Naïve Bayes dengan SMOTE. Hasil tersebut menunjukkan adanya perbedaan kinerja antara kedua algoritma, dengan SVM menghasilkan kinerja klasifikasi keseluruhan yang lebih tinggi pada dataset penelitian.

Kata Kunci : analisis sentimen, makan bergizi gratis, machine learning, Naïve Bayes, Support Vector Machine.

Abstract

The Free Nutritious Meals (MBG) program is a government program aimed at supporting nutritional fulfillment and improving human resource quality. The high level of public interaction on X makes the platform a potential source of data for identifying public responses to the implementation of MBG. This study aims to analyze public sentiment toward the MBG program and compare the performance of the Naïve Bayes and Support Vector Machine (SVM) algorithms. The research data consisted of 5,048 Indonesian-language tweets collected through Browser Automation Scraping. The data were processed through cleaning, case folding, normalization, tokenizing, stopword removal, and stemming, followed by sentiment labeling into positive, neutral, and negative categories using a lexicon-based approach. The dataset was divided using an 80:20 ratio into 3,810 training data and 953 test data. SMOTE was applied to the training data to address class imbalance. The results showed that Naïve Bayes achieved an accuracy of 35.36% before SMOTE and increased to 70.20% after SMOTE. SVM with SMOTE achieved an accuracy of 85.73%, correctly classifying 817 of 953 test data, which was 15.53 percentage points higher than Naïve Bayes with SMOTE. These results indicate a difference in the performance of the two algorithms, with SVM achieving higher overall classification performance on the research dataset.

Keywords: sentiment analysis, free nutritious meals, machine learning, Naïve Bayes, Support Vector Machine.

1. PENDAHULUAN

Program Makan Bergizi Gratis (MBG) merupakan salah satu program pemerintah Indonesia yang berkaitan dengan upaya pemenuhan kebutuhan gizi masyarakat, khususnya anak usia sekolah, serta peningkatan kualitas sumber daya manusia. Pelaksanaan program ini juga berkaitan dengan pencapaian *Sustainable Development Goals* (SDGs), khususnya tujuan kedua mengenai penghapusan kelaparan dan tujuan ketiga mengenai kesehatan dan kesejahteraan [1].

Sebagai program berskala nasional, MBG memperoleh beragam respons masyarakat, baik berupa dukungan maupun kritik terhadap pelaksanaan program. Penelitian mengenai MBG pada media sosial menunjukkan bahwa opini masyarakat dapat dianalisis berdasarkan kecenderungan sentimen menggunakan metode machine learning. Tsabitah et al. [1] menganalisis sentimen program makan siang gratis menggunakan *Naïve Bayes*, sedangkan Jakak et al. [2] menganalisis sentimen publik terhadap program MBG pada Instagram menggunakan SVM. Hasil tersebut menunjukkan bahwa media sosial dapat menjadi sumber data untuk mengidentifikasi respons publik terhadap program MBG.

Media sosial, khususnya X, merupakan salah satu sumber data yang memungkinkan pengguna menyampaikan opini secara terbuka. Andini et al. [3] menunjukkan pemanfaatan data pengguna X untuk analisis sentimen, sedangkan Yusril et al. [4] menerapkan *text mining* pada data tweets. Data teks dari media sosial dapat dianalisis menggunakan machine learning untuk mengelompokkan opini ke dalam kategori sentimen tertentu [5], [6], [7]. Dalam proses tersebut, *preprocessing* seperti *cleaning*, *case folding*, normalisasi, tokenisasi, stopword removal, dan stemming diperlukan untuk menghasilkan data teks yang lebih terstruktur [8], [9].

Dalam konteks MBG, analisis sentimen dapat memberikan gambaran mengenai respons pengguna media sosial terhadap pelaksanaan program. Peraturan Presiden Republik Indonesia Nomor 83 Tahun 2024 tentang Badan Gizi Nasional [10] menjadi salah satu landasan kelembagaan dalam penyelenggaraan pemenuhan kebutuhan gizi nasional. Oleh karena itu, analisis opini pada media sosial dapat digunakan sebagai salah satu pendekatan untuk mengidentifikasi kecenderungan respons publik terhadap program MBG.

Algoritma *Naïve Bayes* merupakan salah satu metode klasifikasi yang dapat digunakan untuk pengolahan data teks karena pendekatannya berbasis probabilistik. Setiawan dan Suryono [11] serta Ali dan Hendrastuty [12] menerapkan dan membandingkan *Naïve Bayes* dengan algoritma lain dalam analisis sentimen. Sementara itu, SVM banyak digunakan dalam klasifikasi teks karena mampu menangani data dengan dimensi fitur yang tinggi [13], [14]. Penerapan SVM untuk analisis sentimen pada media sosial juga telah dilakukan oleh Manuaba et al. [15] dan Arfian et al. [16]. Perbandingan *Naïve Bayes* dan SVM menunjukkan bahwa kinerja algoritma dapat berbeda sesuai dengan karakteristik dataset dan skenario eksperimen [17], [18].

Permasalahan lain dalam klasifikasi sentimen adalah ketidakseimbangan jumlah data antar kelas. Kondisi tersebut dapat menyebabkan model lebih dipengaruhi oleh kelas mayoritas. Salah satu teknik yang dapat digunakan untuk mengatasi masalah tersebut adalah *Synthetic Minority Oversampling Technique* (SMOTE), yaitu dengan membentuk sampel sintesis pada kelas minoritas. Amalia et al. [19] menerapkan SMOTE dalam analisis sentimen menggunakan SVM dan menunjukkan pentingnya mempertimbangkan strategi pembagian data dalam evaluasi model. Oleh karena itu, penerapan SMOTE pada data pelatihan dapat digunakan untuk membantu menyeimbangkan distribusi kelas sebelum proses klasifikasi.

Penelitian mengenai sentimen terhadap MBG telah dilakukan dengan berbagai metode dan sumber data. Tsabitah et al. [1] menggunakan *Naïve Bayes* pada program makan siang gratis, sedangkan Jakak et al. [2] menggunakan SVM pada data Instagram. Pratama et al. [20] membandingkan Decision Tree dan *Naïve Bayes* pada data MBG di X, sementara Haerani [21] menggunakan GRU pada komentar di X. Penelitian Saleh dan Imanda [14] juga secara khusus membandingkan *Naïve Bayes* dan SVM untuk program makanan gratis pada platform Twitter (X). Perbedaan platform, periode pengumpulan data, metode pelabelan, jumlah kelas, penanganan ketidakseimbangan data, dan prosedur evaluasi dapat menghasilkan perbedaan kinerja model.

Berdasarkan penelitian terdahulu, analisis sentimen MBG telah dilakukan menggunakan berbagai algoritma dan sumber data, tetapi masih terdapat perbedaan pada karakteristik dataset dan protokol


eksperimen. Penelitian ini melakukan perbandingan terkontrol antara *Naïve Bayes* dan SVM pada data X mengenai MBG dengan tiga kelas sentimen, yaitu positif, negatif, dan netral. Pelabelan dilakukan menggunakan pendekatan berbasis leksikon, sedangkan SMOTE diterapkan hanya pada data latih untuk menangani ketidakseimbangan kelas. Kedua algoritma dievaluasi menggunakan data uji yang sama berdasarkan *accuracy*, *precision*, *recall*, dan *F1-score*. Kontribusi penelitian ini bersifat empiris dan terbatas pada dataset serta protokol eksperimen yang digunakan, dengan memberikan gambaran respons pengguna X terhadap MBG dan perbandingan kinerja kedua algoritma pada kondisi penelitian tersebut.

2. METODE PENELITIAN

2.1. Pendekatan dan rancangan penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode klasifikasi machine learning untuk menganalisis sentimen masyarakat terhadap program Makan Bergizi Gratis (MBG) pada media sosial X, yang sebelumnya dikenal sebagai Twitter. Pendekatan kuantitatif digunakan karena penelitian memanfaatkan data numerik berupa jumlah data, distribusi kelas sentimen, serta nilai kinerja model yang diperoleh melalui proses pengujian. Analisis dilakukan dengan membandingkan dua algoritma klasifikasi, yaitu *Naïve Bayes* dan *Support Vector Machine* (SVM), dalam mengelompokkan opini masyarakat ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. Sebelum proses klasifikasi, data teks direpresentasikan dalam bentuk numerik menggunakan *Term Frequency–Inverse Document Frequency* (TF-IDF) dengan konfigurasi unigram–bigram. Pembentukan vocabulary dilakukan berdasarkan data latih untuk menghindari kebocoran informasi (*data leakage*), kemudian matriks TF-IDF digunakan sebagai fitur masukan bagi kedua algoritma. Algoritma *Naïve Bayes* menggunakan varian *Multinomial Naïve Bayes* dengan parameter $\alpha = 1,0$, sedangkan SVM menggunakan kernel linear dengan parameter $C = 1,0$. Pembagian data dilakukan dengan random state = 42 sehingga hasil eksperimen dapat direproduksi. SMOTE diterapkan hanya pada data latih setelah pembagian data dan sebelum proses pelatihan model untuk menangani ketidakseimbangan kelas.

Penelitian dilaksanakan pada data yang tersedia di platform media sosial X dengan periode pelaksanaan penelitian selama lima bulan, yaitu Maret sampai Agustus 2026. Data yang dianalisis berupa unggahan atau tweet berbahasa Indonesia yang berkaitan dengan program MBG. Rancangan penelitian terdiri atas beberapa tahapan utama, yaitu identifikasi masalah, pengumpulan data, pembentukan dataset, *text preprocessing*, pelabelan sentimen, pembagian data, pembentukan model klasifikasi, pengujian model, evaluasi kinerja, dan analisis hasil. Secara umum, alur penelitian dapat ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

2.2. Jenis dan Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari unggahan pengguna pada platform X. Data dikumpulkan berdasarkan kata kunci yang berkaitan dengan program Makan Bergizi Gratis sehingga data yang diperoleh merepresentasikan opini masyarakat mengenai pelaksanaan dan dampak program tersebut.

Data mentah yang berhasil dikumpulkan terdiri atas 5.048 data atau baris unggahan berbahasa Indonesia. Setiap data merepresentasikan satu unit opini masyarakat yang kemudian digunakan sebagai objek dalam analisis sentimen. Data disimpan dalam format Microsoft Excel dengan ekstensi .xlsx untuk mempermudah proses pemeriksaan, pembersihan, pengolahan, dan analisis data.

Atribut awal yang terdapat dalam dataset meliputi username, konten teks, tanggal unggahan, jumlah like, dan jumlah komentar. Dari atribut tersebut, konten teks menjadi variabel utama yang digunakan dalam proses klasifikasi sentimen. Atribut lain digunakan sebagai informasi pendukung untuk menggambarkan karakteristik data yang diperoleh.

2.3. Teknik Pengumpulan Data

Pengumpulan data dilakukan menggunakan teknik data crawling atau scraping dengan memanfaatkan Browser Automation Scraping dan bahasa pemrograman Python. Data diperoleh dari platform X pada periode Maret hingga Agustus 2026 menggunakan kata kunci pencarian “makan bergizi gratis” dan “MBG”. Proses pencarian ditujukan untuk memperoleh unggahan berbahasa Indonesia yang membahas Program Makan Bergizi Gratis (MBG). Kriteria inklusi meliputi unggahan yang memuat salah satu kata kunci tersebut dan memiliki konteks yang berkaitan dengan program MBG, sedangkan unggahan yang tidak berkaitan dengan MBG, bukan berbahasa Indonesia, tidak memiliki teks yang dapat dianalisis, serta unggahan duplikat dikeluarkan dari dataset. Penghapusan duplikat dilakukan berdasarkan kesamaan isi teks sehingga setiap unggahan hanya dihitung satu kali. Proses scraping dilakukan dengan membuka halaman pencarian X, memasukkan kata kunci, memuat hasil pencarian secara bertahap, dan mengambil teks unggahan yang memenuhi kriteria penelitian. Dari proses tersebut diperoleh 5.048 data awal, yang selanjutnya digunakan untuk tahap *preprocessing*, pelabelan sentimen, dan proses klasifikasi.

2.4. Text Preprocessing

Text *preprocessing* dilakukan untuk mengubah data teks mentah menjadi data yang lebih terstruktur dan sesuai untuk digunakan dalam proses klasifikasi. Tahapan ini diperlukan karena data media sosial umumnya mengandung karakteristik tidak terstruktur, seperti penggunaan huruf kapital, tanda baca, username, tautan, simbol, angka, kata tidak baku, serta kata yang tidak memiliki kontribusi terhadap proses klasifikasi.

Tahapan text *preprocessing* dalam penelitian ini meliputi *Cleaning*, *Case folding*, *Normalization*, *Tokenizing*, *stopword removal*, dan *Stemming*. Tahapan tersebut dilakukan secara berurutan sebagai berikut.

1. *Cleaning*

Tahap *Cleaning* dilakukan untuk menghilangkan unsur-unsur yang tidak diperlukan dalam proses analisis, seperti URL, mention, tanda baca, karakter khusus, simbol, angka tertentu, dan elemen lain yang tidak memberikan informasi penting terhadap sentimen. Tahap ini bertujuan menghasilkan teks yang lebih bersih dan mengurangi noise dalam dataset.

2. *Case folding*

Case folding dilakukan dengan mengubah seluruh karakter huruf menjadi huruf kecil (lowercase). Proses ini bertujuan menyeragamkan bentuk kata sehingga kata yang memiliki makna sama tetapi ditulis dengan kombinasi huruf kapital dan huruf kecil dapat dikenali sebagai bentuk yang sama.

3. *Normalization*

Normalization dilakukan untuk mengubah kata tidak baku, singkatan, kata alay, dan istilah informal menjadi bentuk yang lebih standar. Proses ini menggunakan kamus normalisasi yang awalnya terdiri atas 5.047 entri, kemudian disesuaikan melalui penghapusan entri yang tidak relevan dan perbaikan pasangan kata sehingga diperoleh 4.763 entri. Validasi dilakukan dengan memeriksa kesesuaian kata dan mempertahankan istilah yang relevan dengan konteks sentimen, termasuk kata negasi seperti “tidak” dan “enggak”. Sebagai contoh, “krn” dinormalisasi menjadi “karena” dan “mbg” menjadi

“makan bergizi gratis”. Tahap ini bertujuan menyeragamkan kosakata sebelum proses *tokenizing*, *stopword removal*, dan *stemming*.

4. *Tokenizing*

Tokenizing merupakan proses memecah teks menjadi unit-unit kata atau token. Sebagai contoh, kalimat mengenai program MBG akan dipisahkan menjadi beberapa kata yang selanjutnya dapat dianalisis berdasarkan karakteristik masing-masing.

5. *Stopword removal*

Tahap *stopword removal* dilakukan dengan menghilangkan kata-kata umum yang memiliki kontribusi rendah terhadap proses klasifikasi sentimen. Penghapusan *stopword* bertujuan mengurangi jumlah kata yang tidak informatif sehingga model dapat lebih berfokus pada kata-kata yang memiliki keterkaitan dengan sentimen.

6. *Stemming*

Stemming dilakukan untuk mengubah kata berimbuhan menjadi bentuk kata dasarnya. Tahapan ini bertujuan menyeragamkan variasi bentuk kata sehingga kata yang berasal dari akar kata yang sama dapat diperlakukan sebagai satu bentuk yang memiliki representasi serupa dalam proses klasifikasi.

2.5. Pelabelan Sentimen

Setelah proses pengumpulan dan *preprocessing*, data dikelompokkan ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. Pelabelan dilakukan berdasarkan nilai *sentiment score* yang diperoleh dari proses analisis sentimen. Kriteria pelabelan ditentukan berdasarkan tanda nilai skor sebagai berikut :

Tabel 1. Pelabelan Sentimen

Nilai <i>Sentiment score</i>	Kategori Sentimen
$Score < 0$	Negatif
$Score = 0$	Netral
$Score > 0$	Positif

Kata yang muncul berulang dihitung sesuai frekuensi kemunculannya, sedangkan kata negasi seperti “tidak” dan “enggak” dipertahankan pada tahap *preprocessing* karena dapat memengaruhi interpretasi sentimen. Kata yang tidak dikenali oleh leksikon tidak memberikan tambahan skor. Untuk meningkatkan keandalan label, dilakukan pemeriksaan terhadap [jumlah sampel] data secara manual dan dibandingkan dengan hasil pelabelan leksikon. Hasil pemeriksaan menunjukkan tingkat kesesuaian sebesar [persentase]%. Ketiga kategori tersebut selanjutnya digunakan sebagai kelas target dalam proses klasifikasi menggunakan algoritma *Naïve Bayes* dan *Support Vector Machine*.

2.6. Pembentukan Model Klasifikasi

Penelitian ini menggunakan dua algoritma machine learning, yaitu *Naïve Bayes* dan *Support Vector Machine*, untuk mengetahui algoritma yang memberikan kinerja terbaik dalam mengklasifikasikan sentimen masyarakat.

1. *Naïve Bayes*

Naïve Bayes merupakan algoritma klasifikasi probabilistik yang didasarkan pada Teorema Bayes. Algoritma ini menghitung probabilitas suatu data termasuk ke dalam kelas tertentu berdasarkan karakteristik atau fitur yang dimilikinya. Dalam analisis sentimen, algoritma *Naïve Bayes* digunakan untuk menentukan kategori sentimen suatu teks berdasarkan pola kata yang terdapat di dalam data pelatihan. Keunggulan *Naïve Bayes* terletak pada proses komputasi yang relatif sederhana dan kemampuannya dalam menangani data teks berdimensi tinggi. Algoritma ini juga banyak diterapkan pada klasifikasi dokumen dan analisis sentimen karena dapat bekerja dengan jumlah fitur yang besar.

2. *Support Vector Machine*

Support Vector Machine merupakan algoritma klasifikasi yang bekerja dengan mencari hyperplane terbaik untuk memisahkan data dari kelas yang berbeda. Pada penelitian ini, SVM digunakan untuk memisahkan data teks ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. SVM dipilih sebagai algoritma pembanding karena memiliki kemampuan yang baik dalam menangani data

berdimensi tinggi, termasuk data teks yang telah direpresentasikan dalam bentuk fitur numerik. Perbandingan antara SVM dan *Naïve Bayes* dilakukan untuk mengetahui algoritma yang memberikan performa klasifikasi paling optimal pada dataset opini masyarakat mengenai program MBG.

2.7. Pembagian Data dan Ekstraksi Fitur

Data yang telah melalui proses *preprocessing* selanjutnya diubah dari bentuk teks menjadi representasi numerik agar dapat diproses oleh algoritma machine learning. Proses ini dilakukan melalui teknik ekstraksi fitur dengan mengubah kata-kata dalam dokumen menjadi vektor numerik.

Dataset kemudian dibagi menjadi data pelatihan (*training data*) dan data pengujian (*testing data*). Data pelatihan digunakan untuk membangun model klasifikasi, sedangkan data pengujian digunakan untuk mengukur kemampuan model dalam mengklasifikasikan data yang belum digunakan pada proses pembelajaran.

Pembagian dataset dilakukan secara konsisten pada kedua algoritma sehingga perbandingan kinerja *Naïve Bayes* dan SVM dapat dilakukan secara objektif. Dengan menggunakan dataset dan data pengujian yang sama, perbedaan hasil klasifikasi dapat dikaitkan dengan karakteristik masing-masing algoritma.

2.8. Evaluasi Model

Evaluasi dilakukan untuk mengetahui kemampuan masing-masing algoritma dalam melakukan klasifikasi sentimen. Empat metrik digunakan dalam penelitian ini, yaitu akurasi, presisi, *recall*, dan *F1-score*.

Akurasi digunakan untuk mengukur proporsi data yang berhasil diklasifikasikan dengan benar dari keseluruhan data pengujian. Presisi menunjukkan tingkat ketepatan model ketika memberikan prediksi pada suatu kelas. *Recall* menunjukkan kemampuan model dalam menemukan seluruh data yang sebenarnya termasuk dalam suatu kelas. Sementara itu, *F1-score* merupakan ukuran gabungan antara presisi dan *recall*.

Evaluasi dilakukan terhadap ketiga kelas sentimen sehingga dapat diketahui tidak hanya tingkat kinerja model secara keseluruhan, tetapi juga kemampuan masing-masing algoritma dalam mengenali sentimen positif, negatif, dan netral.

Hasil evaluasi kedua algoritma kemudian dibandingkan untuk menentukan model dengan performa terbaik. Model dengan nilai evaluasi yang lebih tinggi dianggap memiliki kemampuan klasifikasi yang lebih baik terhadap dataset penelitian.

2.9. Analisis Distribusi Sentimen

Selain membandingkan kinerja algoritma, penelitian ini juga menganalisis distribusi data berdasarkan kategori sentimen. Analisis dilakukan dengan menghitung jumlah dan persentase data yang termasuk ke dalam kategori positif, negatif, dan netral.

Distribusi tersebut digunakan untuk mengetahui kecenderungan opini masyarakat terhadap program MBG. Dominasi suatu kategori sentimen digunakan sebagai indikator kecenderungan umum opini publik dalam dataset penelitian. Hasil distribusi kemudian diinterpretasikan dengan mempertimbangkan konteks program MBG, sehingga tidak hanya menunjukkan jumlah data pada setiap kategori, tetapi juga memberikan gambaran mengenai kecenderungan penerimaan, kritik, atau sikap observatif masyarakat terhadap pelaksanaan program.

3. HASIL

3.1. Hasil Pra-Pemrosesan Data Teksual

Pra-pemrosesan dilakukan terhadap data mentah yang diperoleh dari platform X untuk mengubah teks yang tidak terstruktur menjadi data yang lebih bersih dan terstandar. Tahapan tersebut meliputi *Case folding*, data *Cleaning*, *Normalization*, *Tokenization*, *stopword removal*, dan *Stemming*. Proses ini dilakukan karena data media sosial mengandung berbagai bentuk noise, seperti penggunaan huruf kapital yang tidak konsisten, tanda baca, tautan, simbol, kata tidak baku, serta kata umum yang kurang memberikan informasi terhadap klasifikasi sentimen.

Hasil pra-pemrosesan menunjukkan bahwa setiap tahapan memberikan perubahan terhadap representasi teks. Perubahan tersebut tidak hanya mengurangi noise, tetapi juga mempertahankan kata-kata yang dianggap penting untuk menentukan polaritas sentimen.

1. *Case folding*

Case folding dilakukan dengan mengubah seluruh karakter alfabet dalam teks menjadi huruf kecil. Tahap ini bertujuan menyeragamkan representasi kata sehingga kata yang sama tetapi ditulis dengan kapitalisasi berbeda tidak diperlakukan sebagai fitur yang berbeda oleh model.

Tabel 2. Hasil Tahap *Case folding*

Sebelum <i>Case folding</i>	Setelah <i>Case folding</i>
Giva UI: “banyak teman-teman kami tidak melakukan daftar ulang krn keterbatasan ekonomi” MC: “oke yayayayaya” lanjut Giva: “menurut bapak mana lebih penting, pengembangan pendidikan atau MBG” Wamendagri: “jawabannya jelas, pendidikan penting & MBG harus dikoreksi. cukup ya” bener-bener bagi mereka MBG harga mati	giva ui banyak temanteman kami tidak melakukan daftar ulang krn keterbatasan ekonomi mc oke yayayayaya lanjut giva menurut bapak mana lebih penting pengembangan pendidikan atau mbg wamendagri jawabannya jelas pendidikan penting mbg harus dikoreksi cukup ya benerbener bagi mereka mbg harga mati

Berdasarkan Tabel 2, teks yang semula memiliki variasi huruf kapital telah diubah menjadi huruf kecil secara konsisten. Selain menyeragamkan bentuk karakter, proses tersebut juga menghilangkan beberapa tanda baca dan karakter pemisah yang tidak diperlukan dalam representasi teks. Hasil *Case folding* selanjutnya digunakan sebagai masukan untuk proses data *Cleaning*.

2. Data *Cleaning*

Data *Cleaning* dilakukan untuk menghilangkan unsur yang tidak relevan atau berpotensi menjadi noise dalam proses klasifikasi. Tahapan ini mencakup penghapusan tautan, username, hashtag, simbol, emotikon, tanda baca, dan karakter lain yang tidak memberikan kontribusi langsung terhadap identifikasi sentimen. Penghilangan noise pada data teks diperlukan agar fitur yang digunakan oleh model lebih merepresentasikan informasi linguistik yang berkaitan dengan objek penelitian.

Tabel 3. Hasil Tahap Data Cleansing

Sebelum <i>Data Cleaning</i>	Setelah <i>Data Cleaning</i>
giva ui banyak temanteman kami tidak melakukan daftar ulang krn keterbatasan ekonomi mc oke yayayayaya lanjut giva menurut bapak mana lebih penting pengembangan pendidikan atau mbg wamendagri jawabannya jelas pendidikan penting mbg harus dikoreksi cukup ya benerbener bagi mereka mbg harga mati	giva ui banyak temanteman kami tidak melakukan daftar ulang krn keterbatasan ekonomi mc oke yayayayaya lanjut giva menurut bapak mana lebih penting pengembangan pendidikan atau mbg wamendagri jawabannya jelas pendidikan penting mbg harus dikoreksi cukup ya benerbener bagi mereka mbg harga mati

Hasil pada Tabel 3 menunjukkan bahwa data telah terbebas dari unsur-unsur yang tidak diperlukan dalam proses klasifikasi. Tahapan ini menghasilkan teks yang lebih sederhana sehingga proses berikutnya dapat dilakukan dengan lebih terarah.

3. Normalization

Normalisasi dilakukan untuk menyeragamkan kata tidak baku menjadi bentuk yang lebih sesuai dengan kosakata bahasa Indonesia. Tahap ini penting karena pengguna media sosial cenderung menggunakan singkatan, bahasa informal, dan variasi penulisan. Perbedaan bentuk tersebut dapat menyebabkan kata yang memiliki makna sama dianggap sebagai fitur yang berbeda oleh model. Pada penelitian ini digunakan kamus normalisasi yang dikembangkan dari kamus alay milik Nikmatun Aliyah Salsabila. Kamus awal terdiri atas 5.047 pasangan kata dan setelah dilakukan penyesuaian digunakan sebanyak 4.763 pasangan kata.

Tabel 4. Hasil Tahap *Normalization*

Sebelum <i>Normalization</i>	Setelah <i>Normalization</i>
giva ui banyak temanteman kami tidak melakukan daftar ulang krn keterbatasan	giva ui banyak temanteman kami tidak melakukan daftar ulang karena keterbatasan

ekonomi mc oke yayayayaya lanjut giva menurut bapak mana lebih penting pengembangan pendidikan atau mbg wamendagri jawabannya jelas pendidikan penting mbg harus dikoreksi cukup ya benerbener bagi mereka mbg harga mati	ekonomi mc oke yayayayaya lanjut giva menurut bapak mana lebih penting pengembangan pendidikan atau makan bergizi gratis wamendagri jawabannya jelas pendidikan penting makan bergizi gratis harus dikoreksi cukup ya benerbener bagi mereka makan bergizi gratis harga mati
---	--

Perubahan pada Tabel 4 memperlihatkan bahwa beberapa bentuk tidak baku, seperti “krn”, diubah menjadi “karena”, sedangkan istilah “mbg” diseragamkan menjadi “makan bergizi gratis”. Normalisasi tersebut membantu mengurangi variasi fitur dalam dataset dan meningkatkan konsistensi representasi teks.

4. *Tokenization*

Tokenization dilakukan dengan memecah setiap teks menjadi unit kata atau token. Pada penelitian ini, proses tersebut dilakukan menggunakan fungsi TweetTokenizer dari pustaka Natural Language Toolkit (NLTK).

Tabel 5. Hasil Tahap *Tokenization*

Sebelum <i>Tokenization</i>	Setelah <i>Tokenization</i>
giva ui banyak temanteman kami tidak melakukan daftar ulang karena keterbatasan ekonomi mc oke yayayayaya lanjut giva menurut bapak mana lebih penting pengembangan pendidikan atau makan bergizi gratis wamendagri jawabannya jelas pendidikan penting makan bergizi gratis harus dikoreksi cukup ya benerbener bagi mereka makan bergizi gratis harga mati	[giva, ui, banyak, temanteman, kami, tidak, melakukan, daftar, ulang, karena, keterbatasan, ekonomi, mc, oke, yayayayaya, lanjut, giva, menurut, bapak, mana, lebih, penting, pengembangan, pendidikan, atau, makan, bergizi, gratis, wamendagri, jawabannya, jelas, pendidikan, penting, makan, bergizi, gratis, harus, dikoreksi, cukup, ya, benerbener, bagi, mereka, makan, bergizi, gratis, harga, mati]

Berdasarkan Tabel 5, satu teks yang sebelumnya berbentuk kalimat telah diubah menjadi sekumpulan token. Representasi tersebut diperlukan karena algoritma klasifikasi tidak bekerja secara langsung pada teks mentah, tetapi membutuhkan fitur yang dapat direpresentasikan secara numerik.

5. *Stopword removal*

Stopword removal dilakukan dengan menghilangkan kata-kata umum yang memiliki kontribusi relatif rendah terhadap proses klasifikasi. Proses ini menggunakan daftar stopwords bahasa Indonesia dari Sastrawi. Namun, tidak seluruh kata yang terdapat dalam daftar stopwords dihapus. Beberapa kata dipertahankan karena memiliki fungsi penting dalam menentukan konteks dan sentimen. Kata negasi seperti “tidak” dan “enggak” dipertahankan karena penghapusannya dapat mengubah makna sentimen. Kata penguat seperti “sangat”, “terlalu”, “segera”, “sekali”, dan “kurang” juga dipertahankan karena dapat memberikan informasi mengenai intensitas sentimen.

Tabel 6. Hasil Tahap *Stopword removal*

Sebelum <i>Stopword removal</i>	Setelah <i>Stopword removal</i>
[giva, ui, banyak, temanteman, kami, tidak, melakukan, daftar, ulang, karena, keterbatasan, ekonomi, mc, oke, yayayayaya, lanjut, giva, menurut, bapak, mana, lebih, penting, pengembangan, pendidikan, atau, makan, bergizi, gratis, wamendagri, jawabannya, jelas, pendidikan, penting, makan, bergizi, gratis, harus, dikoreksi, cukup, ya, benerbener, bagi, mereka, makan, bergizi, gratis, harga, mati]	[giva, daftar, ulang, keterbatasan, ekonomi, giva, menurut, pengembangan, pendidikan, makan, bergizi, gratis, wamendagri, jawabannya, pendidikan, makan, bergizi, gratis, dikoreksi, benerbener, makan, bergizi, gratis, harga, mati]

Hasil pada Tabel 6 menunjukkan bahwa kata-kata yang dianggap kurang informatif telah dikurangi, sedangkan kata yang berpotensi memengaruhi interpretasi sentimen tetap dipertahankan. Strategi tersebut diperlukan agar proses pengurangan fitur tidak menghilangkan informasi penting yang dapat memengaruhi hasil klasifikasi.

6. *Stemming*

Tahap terakhir adalah *Stemming*, yaitu proses mengubah kata berimbuhan menjadi bentuk dasarnya. Proses *Stemming* dilakukan menggunakan pustaka Sastrawi. Tahap ini bertujuan mengurangi variasi bentuk kata sehingga kata yang berasal dari akar kata yang sama dapat direpresentasikan secara lebih seragam.

Tabel 7. Hasil Tahap *Stemming*

Sebelum <i>Stemming</i>	Setelah <i>Stemming</i>
[giva, daftar, ulang, keterbatasan, ekonomi, giva, menurut, pengembangan, pendidikan, makan, bergizi, gratis, wamendagri, jawabannya, pendidikan, makan, bergizi, gratis, dikoreksi, benerbener, makan, bergizi, gratis, harga, mati]	[giva, daftar, ulang, batas, ekonomi, giva, turut, kembang, didik, makan, gizi, gratis, wamendagri, jawab, didik, makan, gizi, gratis, koreksi, benerbener, makan, gizi, gratis, harga, mati]

Berdasarkan Tabel 7, kata “keterbatasan” berubah menjadi “batas”, “pengembangan” menjadi “kembang”, “pendidikan” menjadi “didik”, dan “bergizi” menjadi “gizi”. Dengan demikian, hasil akhir *preprocessing* menghasilkan data teks yang lebih terstruktur dan siap digunakan pada tahap pelabelan serta pembentukan model klasifikasi.

3.2. Hasil Labelisasi Dataset

Setelah melalui proses *preprocessing*, dataset diberi label berdasarkan pendekatan lexicon-based. Pendekatan ini dilakukan dengan mencocokkan kata dalam teks dengan kamus yang telah memiliki nilai polaritas. Nilai dari kata-kata yang ditemukan kemudian digunakan untuk memperoleh *sentiment score*.

Hasil penilaian tersebut digunakan untuk membentuk tiga kelas sentimen. Data dengan skor kurang dari nol dikategorikan sebagai negatif, skor sama dengan nol dikategorikan sebagai netral, dan skor lebih dari nol dikategorikan sebagai positif.

Tabel 8. Contoh Labelisasi Dataset

<i>Tweet Setelah Preprocessing</i>	Skor	Label
[giva, daftar, ulang, batas, ekonomi, giva, turut, kembang, didik, makan, gizi, gratis, wamendagri, jawab, didik, makan, gizi, gratis, koreksi, benerbener, makan, gizi, gratis, harga, mati]	8	Positif

Berdasarkan proses tersebut, diperoleh dataset akhir sebanyak 4.763 data yang digunakan untuk proses klasifikasi. Pelabelan menjadi tiga kelas memungkinkan model diuji tidak hanya dalam membedakan opini positif dan negatif, tetapi juga dalam mengidentifikasi opini netral yang tidak menunjukkan polaritas yang kuat.

3.3. Pembagian Dataset

Dataset sebanyak 4.763 data dibagi menggunakan metode *train-test split* dengan proporsi 80:20, sehingga diperoleh 3.810 data pelatihan dan 953 data pengujian. Pembagian data dilakukan menggunakan fungsi `train_test_split` dengan `random state = 42` dan stratify berdasarkan label sentimen untuk mempertahankan proporsi setiap kelas pada data pelatihan dan pengujian. Selanjutnya, SMOTE hanya diterapkan pada data pelatihan setelah proses pembagian data, sedangkan data pengujian tidak dilakukan oversampling untuk mencegah data *leakage* dan memastikan evaluasi model menggunakan data yang tidak terlibat dalam proses pelatihan.


Data pelatihan digunakan untuk membangun model *Naïve Bayes* dan SVM, sedangkan data pengujian digunakan untuk mengetahui kemampuan model dalam mengklasifikasikan data yang tidak digunakan selama proses pelatihan. Penggunaan dataset pengujian yang sama pada kedua algoritma memungkinkan perbandingan kinerja dilakukan secara lebih objektif.

Pada data pengujian, terdapat 128 data negatif, 469 data netral, dan 356 data positif. Distribusi tersebut menunjukkan bahwa kelas netral merupakan kelas dengan jumlah data terbesar, sedangkan kelas negatif merupakan kelas dengan jumlah data paling sedikit.

3.4. Hasil Evaluasi Model *Naïve Bayes* Sebelum SMOTE

Pengujian awal dilakukan menggunakan algoritma *Naïve Bayes* tanpa penerapan teknik penyeimbangan data sebagai baseline. Berdasarkan pengujian terhadap 953 data uji, model memperoleh akurasi sebesar 35,36%. Nilai *precision*, *recall*, dan *F1-score* untuk setiap kelas dihitung berdasarkan confusion matrix dengan urutan kelas negatif, netral, dan positif. Hasil evaluasi tersebut kemudian digunakan sebagai pembandingan terhadap kinerja *Naïve Bayes* setelah penerapan SMOTE dan SVM dengan SMOTE.

Nilai macro average menunjukkan *precision* sebesar 0,67, *recall* sebesar 0,52, dan *F1-score* sebesar 0,36. Sementara itu, weighted average menghasilkan *precision* sebesar 0,82, *recall* sebesar 0,35, dan *F1-score* sebesar 0,35.



Gambar 2. Hasil Klasifikasi Model Awal Sebelum SMOTE

Rendahnya akurasi menunjukkan bahwa model belum mampu melakukan klasifikasi secara seimbang. Pada kelas negatif, model memperoleh *recall* sebesar 0,99, tetapi *precision* hanya 0,17. Kondisi tersebut menunjukkan bahwa model sangat sering memprediksi data sebagai negatif meskipun data tersebut sebenarnya berasal dari kelas lain.

Sebaliknya, kelas netral memperoleh *precision* sebesar 0,92, tetapi *recall* hanya 0,07. Artinya, meskipun sebagian besar data yang diprediksi sebagai netral memang benar, model hanya mampu menemukan sebagian kecil dari keseluruhan data netral yang sebenarnya.

Kelas positif menunjukkan performa yang relatif lebih baik dengan *precision* 0,93, *recall* 0,49, dan *F1-score* 0,64. Hasil tersebut menunjukkan bahwa model lebih mampu mengenali karakteristik kata yang berkaitan dengan sentimen positif dibandingkan kelas netral.

*** === HASIL EVALUASI MODEL BARU ===				
	precision	recall	f1-score	support
Negatif	0.44	0.74	0.55	128
Netral	0.87	0.54	0.67	469
Positif	0.72	0.90	0.80	356
accuracy			0.70	953
macro avg	0.68	0.73	0.67	953
weighted avg	0.76	0.70	0.70	953

Gambar 3. Confusion Matrix Model Awal Sebelum SMOTE


Confusion matrix menunjukkan bahwa model mengalami kesalahan klasifikasi yang cukup besar. Sebanyak 178 data positif dan 421 data netral diprediksi sebagai negatif. Sementara itu, hanya 35 dari 469 data netral yang berhasil diklasifikasikan dengan benar.

Temuan tersebut menunjukkan bahwa ketidakseimbangan distribusi kelas memberikan pengaruh terhadap keputusan model. Model cenderung menghasilkan prediksi yang bias terhadap kelas tertentu sehingga kemampuan membedakan masing-masing kategori sentimen menjadi rendah.

3.5. Hasil Evaluasi *Naïve Bayes* Setelah SMOTE

Untuk mengatasi ketidakseimbangan kelas pada data pelatihan, diterapkan *Synthetic Minority Oversampling Technique* (SMOTE) setelah proses train-test split. SMOTE digunakan dengan sampling strategy = 'auto', k-neighbors = 5, dan random state = 42, sehingga kelas minoritas pada data pelatihan disintesis hingga memiliki jumlah yang seimbang dengan kelas mayoritas. Hasil SMOTE kemudian digunakan sebagai dataset pelatihan yang sama untuk algoritma *Naïve Bayes* dan *Support Vector Machine* (SVM), sedangkan data pengujian tetap menggunakan 953 data asli tanpa proses oversampling. Setelah penerapan SMOTE, akurasi *Naïve Bayes* meningkat dari 35,36% menjadi 70,20%, atau sebesar 34,84 poin persentase. Penggunaan dataset hasil SMOTE yang sama memastikan perbandingan kedua algoritma dilakukan pada kondisi data pelatihan yang setara.

Nilai macro average juga meningkat menjadi *precision* 0,68, *recall* 0,73, dan *F1-score* 0,67. Sementara itu, weighted average menghasilkan *precision* 0,76, *recall* 0,70, dan *F1-score* 0,70. Peningkatan tersebut menunjukkan bahwa SMOTE memberikan pengaruh positif terhadap kemampuan model dalam mengenali kelas yang sebelumnya kurang terwakili. Dengan distribusi data pelatihan yang lebih seimbang, model tidak terlalu bergantung pada kelas tertentu dan dapat menghasilkan prediksi yang lebih merata.



Gambar 4. Confusion Matrix Model *Naïve Bayes* Setelah SMOTE

Hasil confusion matrix setelah SMOTE menunjukkan adanya peningkatan kemampuan klasifikasi dibandingkan model awal. Perbaikan tersebut terutama terlihat dari meningkatnya kemampuan model dalam mengenali pola dari kelas yang sebelumnya sulit diklasifikasikan.

Dengan demikian, hasil pengujian memberikan indikasi bahwa penerapan SMOTE relevan untuk dataset penelitian karena distribusi kelas sentimen tidak seimbang. Namun, peningkatan kinerja *Naïve Bayes* tersebut masih perlu dibandingkan dengan algoritma SVM untuk menentukan model yang paling sesuai.

3.6. Perbandingan *Naïve Bayes* dan *Support Vector Machine*

Perbandingan kinerja dilakukan menggunakan dataset pengujian yang sama sebanyak 953 data untuk *Naïve Bayes* + SMOTE dan *Support Vector Machine* (SVM) + SMOTE. Evaluasi dilakukan berdasarkan *accuracy*, *precision*, *recall*, dan *F1-score* pada masing-masing kelas sentimen, yaitu negatif, netral, dan positif. Selain metrik per kelas, digunakan pula macro average dan weighted average untuk memberikan gambaran kinerja model secara keseluruhan. Akurasi tetap dilaporkan sebagai metrik utama karena memberikan gambaran proporsi keseluruhan data uji yang berhasil diklasifikasikan dengan benar,


sedangkan *precision*, *recall*, *F1-score*, serta macro dan weighted average digunakan untuk mengevaluasi kinerja masing-masing kelas dan memperhatikan ketidakseimbangan distribusi sentimen.

Tabel 8. Perbandingan Kinerja *Naïve Bayes* dan *Support Vector Machine*

Kelas Sentimen	<i>Naïve Bayes</i> + SMOTE	Persentase Benar	SVM + SMOTE	Persentase Benar	Selisih
Negatif	95/128	74,22%	89/128	69,53%	4,69% (NB unggul)
Netral	254/469	54,16%	433/469	92,32%	38,16% (SVM unggul)
Positif	320/356	89,89%	295/356	82,87%	7,02% (NB unggul)
Total	669/953	70,20%	817/953	85,73%	15,53% (SVM unggul)

Berdasarkan Tabel 8, SVM + SMOTE menghasilkan kinerja keseluruhan yang lebih tinggi dibandingkan *Naïve Bayes* + SMOTE. SVM mampu mengklasifikasikan 817 dari 953 data dengan benar atau sebesar 85,73%, sedangkan *Naïve Bayes* hanya mampu mengklasifikasikan 669 data dengan benar atau sebesar 70,20%.

Dengan demikian, terdapat selisih kinerja sebesar 15,53 poin persentase yang menunjukkan bahwa SVM lebih efektif secara keseluruhan dalam mengklasifikasikan sentimen pada dataset penelitian.



Gambar 5. Diagram Perbandingan Persentase Kinerja *Naïve Bayes* dan *Support Vector Machine*

Perbedaan paling besar terlihat pada kelas netral. SVM dengan SMOTE mampu mengklasifikasikan 433 dari 469 data netral dengan benar atau sebesar 92,32%, sedangkan *Naïve Bayes* dengan SMOTE mengklasifikasikan 254 data atau 54,16% dengan benar. Selisih sebesar 38,16 poin persentase menunjukkan bahwa pada dataset pengujian dan pembagian data 80:20 yang digunakan dalam penelitian ini, SVM memiliki tingkat *recall* yang lebih tinggi pada kelas netral dibandingkan *Naïve Bayes*. Perbedaan tersebut turut berkontribusi terhadap perbedaan akurasi keseluruhan kedua model. Namun, hasil ini diperoleh dari satu pembagian dataset, sehingga belum dapat digunakan untuk menyimpulkan bahwa perbedaan kinerja tersebut bersifat konsisten pada pembagian data yang berbeda.

Sebaliknya, *Naïve Bayes* masih menunjukkan keunggulan pada kelas negatif dan positif. Pada kelas negatif, *Naïve Bayes* mencapai 74,22%, sedangkan SVM mencapai 69,53%. Pada kelas positif, *Naïve Bayes* mencapai 89,89%, sedangkan SVM memperoleh 82,87%. Dengan demikian, *Naïve Bayes* lebih baik dalam mengenali dua kelas tersebut, tetapi keunggulan tersebut belum mampu mengimbangi perbedaan kinerja yang sangat besar pada kelas netral.

4. PEMBAHASAN

Hasil penelitian menunjukkan bahwa penerapan machine learning mampu mengklasifikasikan sentimen masyarakat terhadap Program Makan Bergizi Gratis (MBG) pada platform X ke dalam tiga kategori, yaitu positif, netral, dan negatif. Dari 5.048 data awal, setelah melalui tahapan *cleaning*, *case folding*, *normalization*, *tokenizing*, *stopword removal*, dan *stemming*, diperoleh 4.763 data. Pengujian menunjukkan bahwa *Naïve Bayes* tanpa SMOTE memperoleh akurasi 35,36% dan meningkat menjadi 70,20% setelah SMOTE. Sementara itu, SVM dengan SMOTE memperoleh akurasi 85,73%. Peningkatan

pada *Naïve Bayes* menunjukkan bahwa penyeimbangan kelas pada data latih melalui SMOTE membantu model mengenali pola dari kelas dengan jumlah data lebih sedikit.

Perbedaan kinerja antara kedua algoritma sebesar 15,53 poin persentase menunjukkan bahwa pada dataset dan protokol eksperimen penelitian ini, SVM menghasilkan akurasi keseluruhan yang lebih tinggi dibandingkan *Naïve Bayes*. Perbedaan tersebut terutama terlihat pada kelas netral, dengan SVM berhasil mengklasifikasikan 92,32% data secara benar, sedangkan *Naïve Bayes* sebesar 54,16%. Sebaliknya, *Naïve Bayes* menghasilkan persentase klasifikasi benar yang lebih tinggi pada kelas negatif sebesar 74,22% dan kelas positif sebesar 89,89%, dibandingkan SVM masing-masing sebesar 69,53% dan 82,87%.

Perbedaan tersebut secara metodologis dapat dipengaruhi oleh karakteristik data teks yang digunakan. Tahapan normalization dan stemming menyeragamkan variasi penulisan sehingga kata yang memiliki bentuk berbeda dapat direpresentasikan secara lebih konsisten. Namun, hasil pelabelan berbasis leksikon tetap bergantung pada kata dan skor sentimen yang terdapat dalam leksikon, sehingga teks yang mengandung konteks, negasi, bahasa informal, atau makna yang tidak secara langsung tercermin dalam leksikon dapat menghasilkan pola fitur yang berbeda. Dalam kondisi tersebut, SVM memiliki mekanisme pemisahan kelas berdasarkan batas keputusan (hyperplane) pada ruang fitur, sedangkan *Naïve Bayes* menggunakan probabilitas kemunculan fitur dengan asumsi independensi antarkata. Perbedaan mekanisme tersebut secara masuk akal dapat berkontribusi terhadap perbedaan hasil klasifikasi, khususnya pada data netral yang cenderung memiliki polaritas sentimen lebih lemah. Interpretasi ini merupakan penjelasan berdasarkan karakteristik metode dan data penelitian, bukan bukti bahwa SVM selalu lebih unggul pada seluruh jenis dataset.

Hasil penelitian ini sejalan dengan penelitian Novantirani et al., Arfia, dan Pradana et al. yang menerapkan SVM untuk analisis sentimen pada data media sosial. Pada penelitian terkait MBG, Tsabitah et al. menggunakan *Naïve Bayes*, Wardianto et al. menggunakan SVM pada Instagram, sedangkan Haerani menggunakan GRU pada platform X. Penelitian ini melengkapi penelitian tersebut melalui perbandingan *Naïve Bayes* dan SVM pada dataset X mengenai MBG dengan tiga kelas sentimen, pelabelan berbasis leksikon, serta penerapan SMOTE pada data latih. Dengan demikian, kontribusi penelitian ini bersifat empiris dan terbatas pada dataset serta protokol eksperimen yang digunakan.

Hasil penelitian juga memiliki implikasi bahwa analisis sentimen dapat digunakan untuk memperoleh gambaran mengenai respons pengguna X terhadap MBG. Namun, hasil klasifikasi tidak dapat dianggap sebagai representasi seluruh masyarakat karena data hanya berasal dari satu platform dan label sentimen diperoleh menggunakan pendekatan berbasis leksikon. Keterbatasan tersebut membuka peluang penelitian lanjutan melalui penggunaan anotasi manual untuk memperoleh ground truth yang lebih kuat, perluasan sumber data ke platform lain, serta pengujian algoritma lain seperti Random Forest, LSTM, GRU, atau model transformer berbahasa Indonesia.

5. KESIMPULAN

Berdasarkan hasil penelitian analisis sentimen terhadap Program Makan Bergizi Gratis (MBG) pada media sosial X menggunakan algoritma *Naïve Bayes* dan *Support Vector Machine* (SVM), tujuan penelitian telah tercapai melalui identifikasi sentimen positif, netral, dan negatif serta perbandingan kinerja kedua algoritma. Penerapan *Synthetic Minority Oversampling Technique* (SMOTE) meningkatkan akurasi *Naïve Bayes* dari 35,36% menjadi 70,20%, sedangkan SVM + SMOTE menghasilkan akurasi sebesar 85,73% atau 817 dari 953 data uji. Dengan demikian, pada dataset, *preprocessing*, konfigurasi SMOTE, pembagian data, dan skema evaluasi yang digunakan dalam penelitian ini, SVM + SMOTE menghasilkan akurasi 15,53 poin persentase lebih tinggi dibandingkan *Naïve Bayes* + SMOTE. Hasil tersebut menunjukkan adanya perbedaan kinerja empiris antara kedua algoritma pada dataset penelitian ini, tetapi belum dapat diinterpretasikan sebagai perbedaan yang signifikan secara statistik karena penelitian tidak melakukan pengujian statistik atau pengulangan eksperimen.

Perbedaan kinerja juga terlihat pada setiap kelas sentimen. SVM + SMOTE unggul pada kelas netral dengan persentase klasifikasi benar sebesar 92,32%, sedangkan *Naïve Bayes* + SMOTE lebih baik pada kelas negatif sebesar 74,22% dan positif sebesar 89,89%. Hasil tersebut menunjukkan bahwa SVM lebih

efektif dalam membedakan teks dengan polaritas yang tidak kuat, sementara *Naïve Bayes* memiliki keunggulan dalam mengenali pola kata yang memiliki kecenderungan sentimen lebih kuat. Penelitian ini berkontribusi dalam memberikan gambaran empiris mengenai respons masyarakat terhadap MBG serta bukti komparatif mengenai kinerja algoritma machine learning pada data media sosial berbahasa Indonesia.

Penelitian ini memiliki keterbatasan pada pelabelan berbasis leksikon yang belum sepenuhnya menangkap konteks, negasi, sarkasme, dan bahasa informal pada data X. Sumber data yang hanya berasal dari platform X juga belum dapat menggambarkan persepsi masyarakat secara keseluruhan. Selain itu, penggunaan satu kali train-test split 80:20 belum dapat menunjukkan kestabilan kinerja model. Penelitian selanjutnya disarankan menggunakan repeated stratified cross-validation, anotasi manual, sumber data yang lebih beragam, serta algoritma deep learning atau transformer untuk menguji konsistensi hasil.

PENDANAAN

Tidak ada pihak eksternal yang memberikan pendanaan untuk penelitian ini.

PERNYATAAN KETERSEDIAAN DATA

Data tersebut dapat diperoleh dari penulis korespondensi melalui permintaan yang wajar.

KONFLIK KEPENTINGAN

Penulis menyatakan bahwa tidak terdapat konflik kepentingan dalam penelitian, penulisan, maupun publikasi artikel ini

DAFTAR PUSTAKA

- [1] L. Tsabitah, D. A. Karima, Z. D. P. Munaspin, N. M. Titiana, and F. Fathoni, "Analisis Sentimen Program Makan Siang Gratis Dalam Mendukung SDGS Menggunakan Naïve Bayes," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 4, pp. 6288–6294, 2025.
- [2] P. M. Jakak, M. Rohman, and others, "Analisis Sentimen Public Program Makan Bergizi Gratis Platform Instagram Dengan Algoritma Svm," *Smartics J.*, vol. 11, no. 1, pp. 14–20, 2025.
- [3] S. Andini, R. Kurniawan, and S. Anwar, "Analisis Sentimen Pengguna X Mengenai Opini Masyarakat Tentang Dinasti Politik Menggunakan Algoritma Naïve Bayes," *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 2, 2025.
- [4] A. N. Yusril, I. Larasati, and Q. Aini, "Implementasi Text Mining untuk Advertising dengan Menggunakan Metode K-Means Clustering pada Data Tweets Gojek Indonesia," *Sist. J. Sist. Inf.*, vol. 9, no. 3, pp. 586–596, 2020.
- [5] B. Siswoyo and N. A. P. Utomo, "Pemanfaatan machine learning untuk klasifikasi sentimen pelanggan pada media sosial," *J. Teknol. Inf. Digit.*, vol. 1, no. 1, pp. 29–34, 2025.
- [6] F. Pedregosa *et al.*, "Scikit-learn: Machine learning in Python," *J. Mach. Learn. Res.*, vol. 12, pp. 2825–2830, 2011.
- [7] P. Bintoro, R. Ratnasari, E. Wihardjo, I. P. Putri, and A. Asari, "Pengantar machine learning," 2024, *PT MAFY MEDIA LITERASI INDONESIA*.
- [8] S. N. Aziza, L. Somantri, and I. Setiawan, "Analisis Pemetaan Tingkat Rawan Banjir di Kecamatan Bontang Barat Kota Bontang Berbasis Sistem Informasi Geografis," *JJPG Jur. Pendidik. Geogr.*, vol. 9, no. 2, pp. 109–120, 2021.
- [9] E. Nirmala, *Metode Klasifikasi Modern Dalam Machine Learning Menggunakan Python*. Media Pustaka Indo, 2026.
- [10] P. R. Indonesia, "Peraturan Presiden Republik Indonesia Nomor 83 Tahun 2024 tentang Badan Gizi Nasional," *Sekr. Negara Republik Indones.*, 2024.
- [11] A. Setiawan and R. R. Suryono, "Analisis Sentimen Ibu Kota Nusantara menggunakan Algoritma Support Vector Machine dan Naïve Bayes," *Edumatic J. Pendidik. Inform.*, vol. 8, no. 1, pp. 183–192, 2024.
- [12] H. Ali and N. Hendrastuty, "Comparison of Naïve Bayes Classifier, Support Vector Machine, Random Forest Algorithms for Public Sentiment Analysis of Kip-K Program on Twitter," *J. Tek. Inform.*, vol. 5, no. 6, pp. 1701–1712, 2024.
- [13] D. Masitoh, R. R. Setiawan, and S. Adiyono, "Sentimen Analisis Mobile Banking Menggunakan Algoritma Naïve Bayes Dan Support Vector Machine Pada Google Play Store," *IDEALIS Indones. J. Inf. Syst.*, vol. 9, no. 2, pp. 326–335, 2026.

- [14] M. F. Saleh and R. Imanda, "Public Sentiment Analysis of the Free Meal Program: A Comparison of Naïve Bayes and Support Vector Machine Methods on the Twitter (X) Social Media Platform," *J. Appl. Informatics Comput.*, vol. 9, no. 1, pp. 131–139, 2025.
- [15] I. B. N. W. Manuaba, G. R. Dantes, and G. Indrawan, "Analisis sentimen data provider layanan internet pada twitter menggunakan support vector machine dengan penambahan algoritma levenshtein distance," *J. SISKOM-KB (Sistem Komput. dan Kecerdasan Buatan)*, vol. 5, no. 2, pp. 9–17, 2022.
- [16] M. H. Arfian *et al.*, "Analisis Sentimen Pada Media Sosial Menggunakan Metode Support Vector Machine," *J. Ilmu Tek. dan Komput.*, vol. 9, no. 01, pp. 1–6, 2025.
- [17] H. Y. Pradana, I. Slamet, and E. Zukhronah, "Analisis Sentimen Kinerja Pemerintahan Menggunakan Algoritma NBC, KNN, dan SVM," *Pros. Simp. Nas. Multidisiplin*, vol. 4, pp. 114–121, 2022.
- [18] N. Sari, "Penerapan Algoritma Klasifikasi Naïve Bayes Dan Support Vector Machine Untuk Analisis Sentimen Cyberbullying Bilingual Di Aplikasi X," *J. Sist. Sist. Inf.*, vol. 14, no. 1, 2025.
- [19] K. S. Amalia, A. Dzulkarnain, and B. R. Lidyawati, "Comparison Of Split Data Ratio Performance In Sentiment Analysis Of Pon XXI Aceh-Sumut 2024 Using Support Vector Machine With Smote Application," *J. Sist. Inf. dan Inform.*, vol. 9, no. 1, pp. 55–66, 2026.
- [20] K. Y. Pratama, S. Achmadi, and K. A. Sari, "Analisis Sentimen Terhadap Makan Bergizi Gratis Pada Sosial Media X Menggunakan Metode Decicion Tree Dengan Pembanding Naïve Bayes," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 6, pp. 11061–11067, 2025.
- [21] F. Haerani, "Analisis Sentimen Program Makan Bergizi Gratis Berdasarkan Komentar Di Media Sosial X Menggunakan GRU," *J. Inform. dan Tek. Elektro Terap.*, vol. 14, no. 1, 2026.