


Analisis Kinerja Algoritma SVM dan Naïve Bayes untuk Klasifikasi Sentimen Program Makan Gratis

DOI: <http://dx.doi.org/10.35889/jutisi.v14i3.3183>

Creative Commons License 4.0 (CC BY – NC) 

Muhammad Iranda^{1*}, Nurul Huda²

Teknik Informatika, Universitas Bina Darma, Palembang, Indonesia

*e-mail *Corresponding Author.* muhammadiranda321@gmail.com

Abstract

The development of social media facilitates the massive dissemination of public opinion, including towards the government's free meal program. The high volume of comments makes manual analysis inefficient, thus requiring technological approaches such as sentiment analysis for automatic opinion classification. This study focuses on comparing the performance of the SVM (Support Vector Machine) and Naïve Bayes algorithms in classifying public sentiment collected from X social media data. The research method includes data crawling, preprocessing with Natural Language Processing (NLP), and classification using both algorithms. Testing results on an imbalanced dataset show that SVM is the best model with 96% accuracy and an F1-score of 0.48 for the minority (negative) class, significantly outperforming Naïve Bayes variants which tend to predict the majority class. The findings demonstrate that the SVM algorithm has higher reliability in sentiment classification on datasets with imbalanced class distribution.

Keywords: *Sentiment Analysis; Support Vector Machines; Naive Bayes; Free Lunch Program; Text Classification*

Abstrak

Perkembangan media sosial memfasilitasi penyampaian opini publik secara masif, termasuk terhadap program makan gratis pemerintah. Volume komentar yang tinggi menjadikan analisis manual tidak efisien, sehingga memerlukan pendekatan teknologi seperti analisis sentimen untuk klasifikasi opini otomatis. Penelitian ini berfokus pada perbandingan performa algoritma SVM (*Support Vector Machine*) dan *Naïve Bayes* dalam mengklasifikasikan sentimen masyarakat yang diambil dari data media sosial X. Metode penelitian mencakup pengumpulan data crawling, pra-pemrosesan dengan *Natural Language Processing* (NLP), hingga klasifikasi menggunakan kedua algoritma. Hasil pengujian pada dataset yang tidak seimbang menunjukkan bahwa SVM merupakan model terbaik dengan akurasi 96% dan nilai *F1-score* 0.48 pada kelas minoritas (negatif), secara signifikan mengungguli varian Algoritma *Naïve Bayes* sering kali lebih condong memprediksi pada kelas mayoritas. Hasil penelitian ini membuktikan bahwa algoritma SVM memiliki keandalan lebih tinggi dalam klasifikasi sentimen pada dataset dengan distribusi kelas yang tidak seimbang.

Kata kunci: *Analisis Sentimen; Support Vector Machine; Naïve Bayes; Program Makan Gratis; Klasifikasi Teks*

1. Pendahuluan

Perkembangan teknologi informasi telah mengubah secara signifikan cara masyarakat menyampaikan opini terhadap isu-isu publik. Media sosial menjadi ruang terbuka yang memungkinkan penyebaran pendapat secara cepat, luas, dan masif. Fenomena ini memberikan peluang sekaligus tantangan, terutama ketika isu yang dibicarakan berkaitan dengan kebijakan pemerintah. Salah satu program yang saat ini menarik perhatian publik adalah kebijakan makan gratis. Topik ini penting diteliti karena persepsi masyarakat terhadap kebijakan publik berperan besar dalam keberhasilan implementasi, sekaligus menjadi dasar evaluasi bagi pembuat kebijakan.

Situasi aktual menunjukkan bahwa diskusi masyarakat mengenai program makan gratis di media sosial berlangsung sangat intens. Data komentar yang terkumpul jumlahnya ribuan, mencerminkan adanya dukungan sekaligus kritik. Namun, volume data yang besar dengan keragaman bahasa dan ekspresi masyarakat menimbulkan masalah nyata: sulitnya melakukan analisis persepsi secara manual. Masalah ini bersifat terukur karena besarnya jumlah data komentar yang masuk tidak sebanding dengan kemampuan analisis manual, sehingga membutuhkan metode otomatis untuk mengklasifikasikan opini masyarakat secara lebih cepat dan akurat.

Pendekatan yang dapat diterapkan adalah analisis sentimen dengan memanfaatkan *Natural Language Processing* (NLP). Dengan menggunakan analisis ini, opini masyarakat dapat dikategorikan secara otomatis ke dalam sentimen positif, negatif, atau netral [1]. Berbagai penelitian menunjukkan bahwa algoritma *Naïve Bayes* dan *Support Vector Machine* (SVM) merupakan metode yang banyak diaplikasikan dalam klasifikasi teks. *Naïve Bayes* dikenal dengan proses pelatihan yang sederhana dan cepat [2], sementara SVM memiliki kemampuan menemukan *hyperplane* optimal sehingga sering menghasilkan akurasi yang lebih tinggi pada data teks kompleks [3]. Sejumlah studi sebelumnya juga membandingkan kedua algoritma ini dalam berbagai konteks, seperti opini terhadap mobil listrik, ulasan aplikasi, hingga kebijakan pendidikan, dan mayoritas menunjukkan keunggulan SVM. Namun demikian, kinerja algoritma dapat berbeda tergantung konteks dan karakteristik dataset yang digunakan, terutama ketika dihadapkan pada permasalahan dataset yang tidak seimbang (*imbalanced dataset*).

Dengan adanya kondisi tersebut, penelitian ini diarahkan pada dua sasaran pokok. Sasaran pertama yaitu membandingkan kinerja algoritma *Naïve Bayes* dan *Support Vector Machine* (SVM) dalam mengklasifikasikan sentimen masyarakat terhadap program makan gratis yang dibahas di *platform* media sosial X. Kedua, mengidentifikasi persepsi dominan masyarakat mengenai program tersebut berdasarkan hasil klasifikasi model terbaik. Penelitian ini diharapkan memberikan manfaat praktis bagi Badan Gizi Nasional sebagai bahan evaluasi kebijakan, serta manfaat akademis berupa kontribusi terhadap pengembangan penelitian analisis sentimen di ranah kebijakan publik dengan konteks dataset yang tidak seimbang.

2. Tinjauan Pustaka

Berbagai penelitian dalam beberapa tahun terakhir secara konsisten menampilkan hasil perbandingan performa antara algoritma *Support Vector Machine* (SVM) dan *Naïve Bayes* dalam melakukan analisis sentimen pada data teks berbahasa Indonesia. Dalam konteks analisis kebijakan publik, penelitian oleh Febriyani dan Elisa Februariyanti [4] mengkaji sentimen publik mengenai kebijakan Kampus Merdeka pada *platform* X dengan menerapkan algoritma *Naïve Bayes* dan *Support Vector Machine* (SVM). Hasilnya menunjukkan bahwa SVM lebih akurat dengan perolehan 87% dibandingkan *Naïve Bayes* yang mendapatkan 81%.

Selain itu, studi yang berfokus pada ulasan pengguna aplikasi juga menunjukkan tren serupa. Maulana dan Bagas Akbar Fahmi [5], melakukan analisis sentimen pada ulasan aplikasi *Pluang* di *Play Store*. Hasilnya, SVM mencapai akurasi hingga 99,50%, secara konsisten lebih baik daripada *Naïve Bayes* yang memperoleh akurasi hingga 99,25%. Tren serupa juga ditemukan oleh Widia Ningsih [6], yang menganalisis sentimen publik di X terhadap penggunaan mobil listrik di Indonesia. Penelitian mereka menemukan bahwa SVM lebih unggul dengan akurasi 70.82%, sedangkan *Naïve Bayes* hanya mencapai 63.02%.


Meskipun mayoritas penelitian menunjukkan keunggulan SVM, ada studi yang menghasilkan temuan berbeda. Wahyu Septian dan Francis Matheos Sarimole [7] menganalisis sentimen publik terkait isu penundaan Pemilu 2024 pada *platform* X. Dalam penelitian ini, *Naïve Bayes* justru mampu menghasilkan akurasi yang sangat tinggi hingga 98,80%. Perbedaan hasil ini mengindikasikan bahwa kinerja algoritma bergantung pada konteks serta karakteristik data yang dianalisis. Hal ini sejalan dengan kesimpulan penelitian Apriyani dan Meyti Eka Fikri Nur [8], yang menyatakan bahwa baik *Naïve Bayes* maupun SVM sama-sama baik untuk analisis sentimen media sosial, dan dalam beberapa kasus, SVM sedikit lebih baik.

Berdasarkan penelitian-penelitian terdahulu, tampak bahwa arsitektur SVM cenderung menjadi pilihan yang lebih unggul dan stabil dalam berbagai kasus analisis sentimen berbahasa Indonesia. Meskipun demikian, penelitian oleh Septian dan Sarimole [7] membuktikan bahwa *Naïve Bayes* juga berpotensi memberikan akurasi yang sangat tinggi, mengindikasikan bahwa tidak ada satu algoritma yang mutlak terbaik untuk semua kondisi. Kinerja algoritma sangat bergantung pada keunikan dataset. Kebaruan penelitian ini terletak pada penerapan pendekatan

komparatif terhadap topik kebijakan publik yang spesifik dan aktual, yaitu "Program Makan Bergizi Gratis." Secara konseptual, penelitian ini berbeda dari penelitian-penelitian sebelumnya karena berfokus pada evaluasi kedua algoritma pada dataset yang memiliki karakteristik unik dan tidak seimbang (*imbalanced dataset*), sebuah kondisi yang umum terjadi dalam analisis opini publik. Dengan menganalisis data yang didominasi oleh sentimen tertentu [9], penelitian ini memberikan solusi untuk mengetahui algoritma mana yang paling andal dalam menghadapi tantangan klasifikasi pada dataset yang bias terhadap kelas mayoritas.

3. Metodologi

Metodologi dalam penelitian ini disusun secara sistematis melalui lima tahapan pokok yang berurutan, mulai dari pengumpulan data hingga evaluasi model [10]. Setiap tahapannya diuraikan sebagai berikut.



Gambar 1. Tahapan penelitian

3.1 Data Crawling

Tahapan penelitian ini diawali dengan mengumpulkan data dari *platform X*. Data yang diperoleh merupakan data mentah berisi unggahan dan cuitan relevan yang kemudian akan menjadi objek utama pada proses analisis sentimen [11].

3.2 Data Preprocessing

Setelah data mentah terkumpul, tahapan selanjutnya adalah pra-pemrosesan data (*data preprocessing*). Langkah ini bertujuan untuk membersihkan data dari *noise* (informasi pengganggu) dan mengubahnya menjadi format yang terstruktur dan siap untuk dianalisis [12]. Prosedur yang dilakukan pada tahap ini meliputi beberapa langkah, seperti *cleansing* (menghapus karakter yang tidak diperlukan, tautan URL, serta simbol tanda baca), *Case Folding* (penyeragaman huruf menjadi kecil), *Tokenizing* (proses memecah kalimat menjadi kata), *Stopword Removal* (penghapusan kata-kata umum yang tidak memiliki makna signifikan), serta *Stemming* (mengembalikan kata ke bentuk dasarnya).

3.3 Pelabelan Data

Setelah melewati proses pembersihan, data selanjutnya diproses pada tahap pelabelan (*data labeling*). Pada tahap ini, setiap data teks (misalnya, setiap komentar atau ulasan) diberi label kategori yang sesuai dengan tujuan penelitian, seperti 'positif', 'negatif', atau 'netral' untuk analisis sentimen [13]. Proses pelabelan ini dilakukan sebagai dasar bagi algoritma machine learning mampu mengenali pola dari data pada proses klasifikasi.

3.4 Klasifikasi SVM dan Naïve Bayes

Tahapan inti dalam penelitian ini adalah proses klasifikasi yang menggunakan algoritma *Support Vector Machine* (SVM) dan *Naïve Bayes*. Dataset berlabel yang telah tersedia kemudian dibagi menjadi dua subset, yaitu data latih (*training data*) dan data uji (*testing data*), dengan proporsi 80% dialokasikan untuk pelatihan dan 20% sisanya untuk pengujian. Data latih dimanfaatkan untuk melatih kedua model secara terpisah, sehingga setiap model mampu mempelajari pola serta karakteristik dari masing-masing kelas sentimen. Setelah proses pelatihan selesai dilakukan, kedua model yang telah terbentuk selanjutnya digunakan untuk melakukan prediksi label pada data yang sebelumnya tidak pernah digunakan dalam proses pembelajaran, yaitu data uji [14].

3.5 Evaluasi

Tahap terakhir adalah evaluasi kinerja model. Pada tahap ini, kedua model yang telah dilatih (SVM dan *Naïve Bayes*) diuji kemampuannya menggunakan data uji. Prediksi setiap model dibandingkan dengan label asli untuk menilai tingkat akurasi kerjanya, dengan evaluasi

menggunakan metrik standar seperti *accuracy*, *precision*, *recall*, dan *F1-score* [15]. Hasil evaluasi ini kemudian dianalisis untuk membandingkan kedua algoritma dan menyimpulkan model mana yang paling efektif untuk menyelesaikan masalah klasifikasi pada penelitian ini.

4. Hasil dan Pembahasan

4.1. Crawling data

Pengumpulan Data dikumpulkan menggunakan teknik crawling dari media sosial X. Proses ini memanfaatkan *tool Tweet-Harvest* untuk mengambil unggahan (*tweet*) publik secara otomatis berdasarkan kata kunci yang sesuai dengan topik penelitian, yaitu tentang “makan bergizi gratis”.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
1	conversati	created_at	favorite	full_text	id_str	in	in	lang	location	quote_cou	reply_cour	retweet_c	tweet_url	user_id	st_username
2	1.89E+18	Fri Jan 31 12:00	0	Bersama kita bisa bantu majukan UMKI	1.89E+18			in		0	0	0	https://x.c	1.70E+18	
3	1.89E+18	Fri Jan 31 12:00	0	Makan bergizi gratis jalan mulus buat bi	1.89E+18			in		0	0	0	https://x.c	1.70E+18	
4	1.89E+18	Fri Jan 31 12:00	0	Makan bergizi gratis mendorong pertun	1.89E+18			in		0	0	0	https://x.c	1.69E+18	
5	1.89E+18	Fri Jan 31 12:00	0	Ajak semua teman dukung UMKM lewa	1.89E+18			in		0	0	0	https://x.c	1.68E+18	
6	1.89E+18	Fri Jan 31 12:00	0	Makan bergizi gratis membantu mencip	1.89E+18			in		0	0	0	https://x.c	1.70E+18	
7	1.89E+18	Fri Jan 31 12:00	0	Makan Bergizi Gratis memberikan dor	1.89E+18			in		0	0	0	https://x.c	1.69E+18	
8	1.89E+18	Fri Jan 31 12:00	0	Bermanfaat makan gratis bergizi sambi	1.89E+18			in		0	0	0	https://x.c	1.83E+18	
9	1.89E+18	Fri Jan 31 12:00	0	Program makan bergizi gratis bantu UV	1.89E+18			in		0	0	0	https://x.c	1.72E+18	
10	1.89E+18	Fri Jan 31 12:00	0	Mahasiswa pun bisa bantu UMKM maju	1.89E+18			in		0	0	0	https://x.c	1.68E+18	
11	1.89E+18	Fri Jan 31 12:00	0	Makan bergizi gratis bantu kita mengha	1.89E+18			in		0	0	0	https://x.c	1.84E+18	
12	1.89E+18	Fri Jan 31 12:00	0	Makan bergizi gratis jadi langkah nyata	1.89E+18			in		0	0	0	https://x.c	1.81E+18	
13	1.89E+18	Fri Jan 31 12:00	0	UMKM makin sukses kalau kita dukung	1.89E+18			in		0	0	0	https://x.c	1.68E+18	
14	1.88E+18	Fri Jan 31 12:00	0	@fiantora90 @BaseAnakFK Kalau diliha	1.89E+18			in		0	1	0	https://x.c	1.77E+18	
15	1.89E+18	Fri Jan 31 12:00	0	Makan Bergizi Gratis memberikan dam	1.89E+18			in		0	0	0	https://x.c	1.69E+18	

Gambar 2. Data mentah hasil *crawling*

Proses *crawling* dimulai dengan mengambil *tweet* publik dari *platform* X. Setiap *tweet* yang berhasil dikumpulkan mencakup berbagai informasi mentah seperti ID percakapan, waktu unggah, dan teks lengkap dari unggahan tersebut. Jumlah data yang terkumpul dalam penelitian mencapai 7.781 *tweet*, dengan proses pengambilan dilakukan secara bertahap selama enam bulan, dari Januari hingga Juni. Setiap hasil *crawling* bulanan kemudian disimpan secara sistematis dalam berkas terpisah dengan format *.csv*, yang memudahkan dalam proses pengolahan dan analisis data selanjutnya.

4.2. Preprocessing data

Langkah-langkah pra-pemrosesan data dilakukan guna menyiapkan data untuk pengolahan, antara lain:

4.2.1 Cleaning

Pembersihan *tweet* dilakukan dengan menghilangkan komponen yang tidak diperlukan, misalnya *URL*, *mention* (@username), tagar (#hashtag), dan karakter non-alfabet lainnya.

Tabel 1 Contoh Hasil Cleansing Data

Full text	Cleaning
@fiantora90 @BaseAnakFK Kalau dilihat dari logika berfikir ini salah sih. Ga runtut alurnya salah besar dalam menentukan tujuan. Pertama saya tanya tujuan Makan Bergizi Gratis itu untuk apa? Apakah itu sudah menjadi cita-cita terjauh yang pantas untuk dijadikan prioritas utama?	Kalau dilihat dari logika berfikir ini salah sih Ga runtut alurnya salah besar dalam menentukan tujuan Pertama saya tanya tujuan Makan Bergizi Gratis itu untuk apa Apakah itu sudah menjadi citacita terjauh yang pantas untuk dijadikan prioritas utama

4.2.2 Case Folding

Proses ini menyeragamkan teks ke dalam huruf kecil (*lowercase*) agar konsisten, sehingga perbedaan kapitalisasi pada kata tidak memengaruhi pengelompokan dan dianggap sama.

Tabel 2 Hasil Penerapan *Case Folding*

<i>Cleaning</i>	<i>Case Folding</i>
Kalau dilihat dari logika berfikir ini salah sih Ga runtut alurnya salah besar dalam menentukan tujuan Pertama saya tanya tujuan Makan Bergizi Gratis itu untuk apa Apakah itu sudah menjadi citacita terjauh yang pantas untuk dijadikan prioritas utama	kalau dilihat dari logika berfikir ini salah sih ga runtut alurnya salah besar dalam menentukan tujuan pertama saya tanya tujuan makan bergizi gratis itu untuk apa apakah itu sudah menjadi citacita terjauh yang pantas untuk dijadikan prioritas utama

4.2.3 Normalisasi

Pada tahapan ini, proses dilakukan dengan cara mengganti kata-kata yang tidak baku menjadi baku atau singkatan menjadi bentuk baku sesuai acuan kamus guna memastikan standar kosakata.

Tabel 3 Contoh Teks Setelah Proses Normalisasi

<i>Case Folding</i>	Normalisasi
kalau dilihat dari logika berfikir ini salah sih ga runtut alurnya salah besar dalam menentukan tujuan pertama saya tanya tujuan makan bergizi gratis itu untuk apa apakah itu sudah menjadi citacita terjauh yang pantas untuk dijadikan prioritas utama	kalau dilihat dari logika berpikir ini salah sih tidak runtut alurnya salah besar dalam menentukan tujuan pertama saya tanya tujuan makan bergizi gratis itu untuk apa apakah itu sudah menjadi citacita terjauh yang pantas untuk dijadikan prioritas utama

4.2.4 Tokenizing

Langkah ini dilakukan dengan memecah sebuah kalimat atau teks menjadi bagian-bagian kata individual (token) yang menjadi dasar untuk analisis lebih lanjut.

Tabel 4 Hasil Penerapan *Tokenizing*

Normalisasi	<i>Tokenizing</i>
kalau dilihat dari logika berpikir ini salah sih tidak runtut alurnya salah besar dalam menentukan tujuan pertama saya tanya tujuan makan bergizi gratis itu untuk apa apakah itu sudah menjadi citacita terjauh yang pantas untuk dijadikan prioritas utama	['kalau', 'dilihat', 'dari', 'logika', 'berpikir', 'ini', 'salah', 'sih', 'tidak', 'runtut', 'alurnya', 'salah', 'besar', 'dalam', 'menentukan', 'tujuan', 'pertama', 'saya', 'tanya', 'tujuan', 'makan', 'bergizi', 'gratis', 'itu', 'untuk', 'apa', 'apakah', 'itu', 'sudah', 'menjadi', 'citacita', 'terjauh', 'yang', 'pantas', 'untuk', 'dijadikan', 'prioritas', 'utama']

4.2.5 Stopword Removal

Tahapan ini dilakukan dengan menghapus kata-kata yang kerap muncul namun tidak mengandung makna penting. (misalnya "yang", "di", "adalah") dari daftar token.

Tabel 5 Hasil Penerapan *Stop Removal*

<i>Tokenizing</i>	<i>Stop Removal</i>
['kalau', 'dilihat', 'dari', 'logika', 'berpikir', 'ini', 'salah', 'sih', 'tidak', 'runtut', 'alurnya', 'salah', 'besar', 'dalam', 'menentukan', 'tujuan', 'pertama', 'saya', 'tanya', 'tujuan', 'makan', 'bergizi', 'gratis', 'itu', 'untuk', 'apa', 'apakah', 'itu', 'sudah', 'menjadi', 'citacita', 'terjauh', 'yang', 'pantas', 'untuk', 'dijadikan', 'prioritas', 'utama']	['logika', 'berpikir', 'salah', 'sih', 'runtut', 'alurnya', 'salah', 'menentukan', 'tujuan', 'tujuan', 'makan', 'bergizi', 'gratis', 'citacita', 'terjauh', 'dijadikan', 'prioritas', 'utama']

4.2.6 Stemming

Mengubah kata-kata berimbuhan ke dalam bentuk kata dasarnya (misalnya "menganalisis" menjadi "analisa") untuk mengurangi variasi kata dan mengelompokkan kata dengan makna inti yang sama.

Tabel 6 Hasil Penerapan *Stemming*

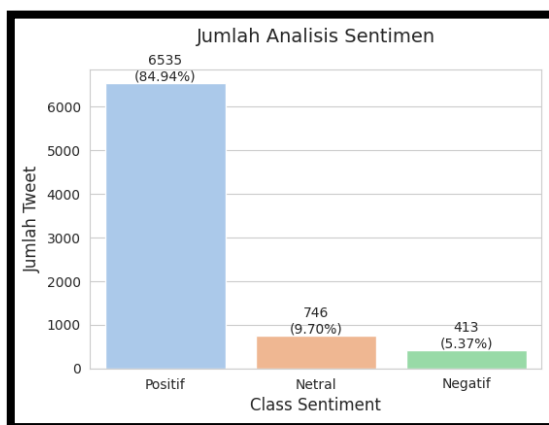
<i>Stop Removal</i>	<i>Stemming</i>
['logika', 'berpikir', 'salah', 'sih', 'runtut', 'alurnya', 'salah', 'menentukan', 'tujuan', 'tujuan', 'makan', 'bergizi', 'gratis', 'citacita', 'terjauh', 'dijadikan', 'prioritas', 'utama']	logika pikir salah sih runtut alur salah tentu tuju tuju makan gizi gratis citacita jauh jadi prioritas utama

Penelitian ini memanfaatkan *Natural Language Toolkit* (NLTK), sebuah pustaka Python yang dikembangkan khusus untuk pemrosesan dan pemodelan teks. Penggunaan NLTK berfungsi untuk menyederhanakan serta mempercepat tahapan pengolahan data. serta mengubah data teks yang tidak terstruktur menjadi format yang siap untuk analisis lebih lanjut.

4.3. Pelabelan data

Proses pelabelan sentimen pada setiap *tweet* dilakukan secara otomatis menggunakan bahasa pemrograman Python. Dalam penelitian ini, penentuan sentimen (positif, negatif, atau netral) memanfaatkan kamus InSet (*Indonesia Sentiment Lexicon*). Kamus ini berisi daftar kata dalam Bahasa Indonesia yang masing-masing telah diberi bobot sentimen; misalnya, kata dengan kecenderungan positif memiliki skor positif, sedangkan kata dengan kecenderungan negatif memiliki skor negatif. Sentimen dari sebuah *tweet* ditentukan dengan menjumlahkan total bobot dari kata-kata yang terkandung di dalamnya.

Berdasarkan hasil proses pelabelan otomatis terhadap 7.781 *tweet* yang membahas "Program Makan Gratis", diperoleh distribusi sentimen sebagai berikut: 6.535 *tweet* (84,94%) diklasifikasikan sebagai positif, 746 *tweet* (9,70%) sebagai netral, dan hanya 413 *tweet* (5,37%) sebagai negatif. Hasil ini menunjukkan adanya ketidakseimbangan kelas (*imbalanced dataset*) yang sangat signifikan, di mana sentimen positif sangat mendominasi keseluruhan data.



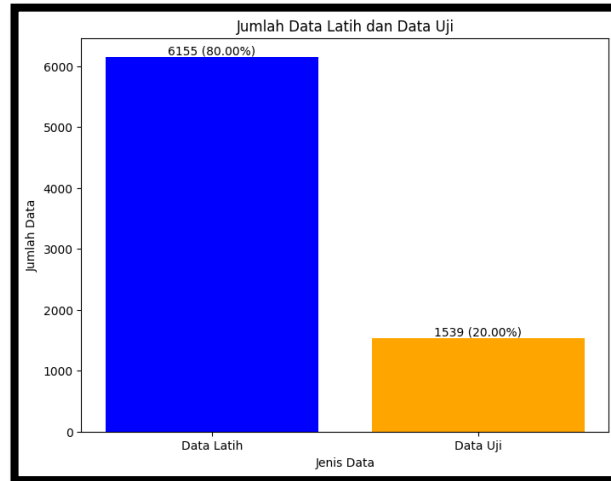
Gambar 3 Visualisasi hasil sentiment keseluruhan data

Menghadapi tantangan ketidakseimbangan data ini, penelitian ini tidak menerapkan teknik penyeimbangan data seperti SMOTE (*Synthetic Minority Over-sampling Technique*). Sebaliknya, penelitian ini secara murni bertujuan untuk menguji dan membandingkan ketangguhan algoritma *Support Vector Machine* (SVM) dan *Naïve Bayes* dalam menghadapi kondisi data yang tidak seimbang secara alami. Pendekatan ini dipilih untuk dapat mengevaluasi secara langsung kemampuan setiap algoritma dalam menangani skenario data yang realistis, di mana distribusi opini publik seringkali tidak merata. Untuk memfokuskan analisis perbandingan, kelas sentimen netral tidak diikutsertakan dalam tahap pemodelan, sehingga klasifikasi hanya ditujukan untuk sentimen positif dan negatif.

4.4. Klasifikasi algoritma

Dalam proses ini, klasifikasi dilakukan terbatas pada dua kategori sentimen, yaitu positif dan negatif. Data dengan label netral tidak disertakan dalam analisis, karena dianggap memiliki kecenderungan polaritas yang mirip dengan sentimen positif sehingga berpotensi mengurangi ketepatan hasil penelitian. Dataset dibagi dengan proporsi 80% sebagai data latih dan 20% sebagai data uji. Dari total keseluruhan data, sebanyak 6.155 data digunakan untuk pelatihan,

sementara 1.539 data lainnya dimanfaatkan sebagai data uji. Data latih dimanfaatkan untuk melatih model agar mampu mengenali pola-pola sentimen, sementara data uji berfungsi untuk mengukur performa model serta menilai kemampuan generalisasinya terhadap data baru yang belum pernah diproses sebelumnya.




Gambar 4 Visualisasi data latih dan data uji

Pada tahap selanjutnya, proses training dilakukan dengan menerapkan algoritma *Support Vector Machine* (SVM) dan *Naïve Bayes*. Setelah model berhasil dibangun, evaluasi dilakukan menggunakan data uji dengan mengacu pada metrik kinerja seperti *accuracy*, *precision*, *recall*, dan *F1-score*.

SVM Classification Report:				
	precision	recall	f1-score	support
Negatif	0.83	0.33	0.48	75
Positif	0.97	1.00	0.98	1464
accuracy			0.96	1539
macro avg	0.90	0.66	0.73	1539
weighted avg	0.96	0.96	0.96	1539

Gambar 5 Klasifikasi SVM




Gambar 6 Confusion matrix SVM

Model klasifikasi *Support Vector Machine* (SVM) menunjukkan performa yang cukup baik dengan akurasi mencapai 96% dari total 1539 data uji. Berdasarkan *confusion matrix*, presisi untuk kelas negatif tercatat 83% dan kelas positif 97%. Sementara itu, nilai *recall* memperlihatkan perbedaan cukup mencolok, yakni 33% untuk kelas negatif dan 100% untuk kelas positif. Hasil ini menghasilkan *F1-score* sebesar 48% pada kelas negatif dan 98% pada kelas positif, dengan distribusi data uji masing-masing 75 data negatif dan 1464 data positif.

Classification Report (GaussianNB):				
	precision	recall	f1-score	support
Negatif	0.07	0.41	0.12	75
Positif	0.96	0.71	0.81	1464
accuracy			0.69	1539
macro avg	0.51	0.56	0.46	1539
weighted avg	0.92	0.69	0.78	1539

Gambar 7 Klasifikasi GaussianNB

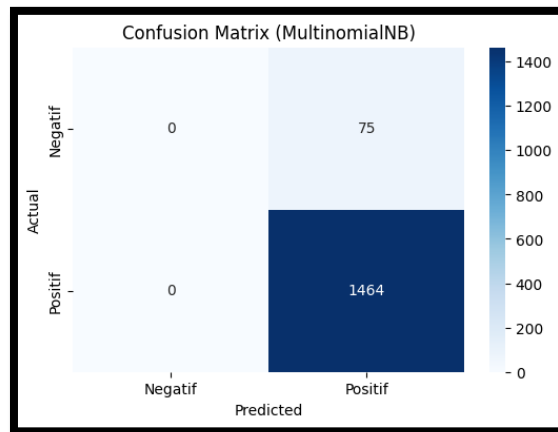


Gambar 8 Confusion matrix GaussianNB

Hasil Berbeda dengan SVM, model *Naïve Bayes* Gaussian menghasilkan akurasi yang lebih rendah, yaitu 69% dengan jumlah data uji yang sama (1539 data). Presisi yang diperoleh untuk kelas negatif hanya 0,7%, sedangkan kelas positif mencapai 96%. Pada aspek *recall*, kelas negatif berada di angka 41%, sementara kelas positif sebesar 71%. Kombinasi nilai tersebut menghasilkan *F1-score* yang cukup timpang, yaitu 12% pada kelas negatif dan 81% pada kelas positif, dengan support masing-masing 75 data negatif dan 1464 data positif.

Classification Report (MultinomialNB):				
	precision	recall	f1-score	support
Negatif	0.00	0.00	0.00	75
Positif	0.95	1.00	0.98	1464
accuracy			0.95	1539
macro avg	0.48	0.50	0.49	1539
weighted avg	0.90	0.95	0.93	1539

Gambar 9 Klasifikasi MultinomialNB

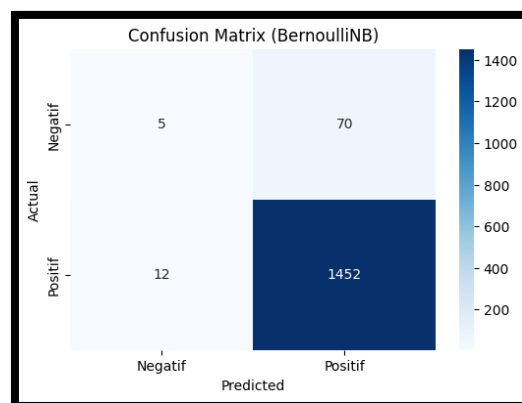


Gambar 10 Confusion matrix MultinomialNB

Hasil Selanjutnya, model *Naïve Bayes* Multinomial memperlihatkan akurasi tinggi sebesar 95% pada 1539 data uji. Namun, hasil evaluasi menunjukkan kelemahan signifikan pada kelas negatif, di mana nilai presisi, *recall*, dan *F1-score* sama-sama berada di angka 0%. Sebaliknya, performa pada kelas positif sangat kuat, dengan presisi 95%, *recall* 100%, serta *F1-score* 98%. Hal ini terjadi karena distribusi data yang tidak seimbang, yakni hanya 75 data negatif dibandingkan dengan 1464 data positif.

	precision	recall	f1-score	support
Negatif	0.29	0.07	0.11	75
Positif	0.95	0.99	0.97	1464
accuracy			0.95	1539
macro avg	0.62	0.53	0.54	1539
weighted avg	0.92	0.95	0.93	1539

Gambar 11 Klasifikasi BernoulliNB



Gambar 12 Confusion matrix BernoulliNB

Hasil Adapun model *Naïve Bayes* Bernoulli menghasilkan akurasi serupa, yakni 95% dari 1539 data uji. Berbeda dengan Multinomial, model ini masih memberikan nilai presisi pada kelas negatif sebesar 29%, meskipun *recall*-nya sangat rendah yaitu hanya 0,7%, sehingga *F1-score* negatif hanya 11%. Sementara itu, performa untuk kelas positif jauh lebih stabil, dengan presisi

95%, *recall* 99%, dan *F1-score* 97%. Sama seperti model lainnya, hasil ini dipengaruhi oleh distribusi data uji yang tidak seimbang antara kelas negatif (75 data) dan kelas positif (1464 data).

4.5. Evaluasi *confusion matrix*


Evaluasi kinerja model dilakukan dengan menganalisis hasil dari *confusion matrix* untuk menentukan model klasifikasi terbaik antara *Support Vector Machine* (SVM) dan tiga varian *Naïve Bayes*. Hal ini penting karena *confusion matrix* tidak hanya menampilkan akurasi keseluruhan, tetapi juga menunjukkan secara detail distribusi prediksi benar maupun salah pada masing-masing kelas. Mengingat kondisi dataset yang sangat tidak seimbang—di mana sentimen positif mendominasi sebesar 84,94% sementara sentimen negatif hanya 5,37%—penilaian performa model tidak dapat bergantung pada metrik akurasi semata. Akurasi pada dataset yang tidak seimbang berpotensi menyesatkan, karena model dapat memperoleh nilai akurasi tinggi hanya dengan memprediksi mayoritas kelas. Oleh sebab itu, analisis lebih menitikberatkan pada metrik *precision*, *recall*, dan *F1-score*, khususnya pada performa terhadap kelas minoritas (Negatif). Dengan pendekatan ini, evaluasi model menjadi lebih objektif dan mampu menunjukkan seberapa baik model dalam mendeteksi opini negatif yang jumlahnya sedikit namun memiliki nilai informasi yang penting.

Tabel 6 Metrik Algoritma

Metrik	SVM	Multinomial NB	Bernoulli NB	Gaussian NB
Akurasi	96%	95%	95%	69%
<i>Precision</i> (Negatif)	0.83	0.00	0.29	0.07
<i>Recall</i> (Negatif)	0.33	0.00	0.07	0.41
<i>F1-score</i> (Negatif)	0.48	0.00	0.11	0.12
Macro Avg <i>F1-score</i>	0.73	0.49	0.54	0.46

Analisis terhadap model *Naïve Bayes* menunjukkan adanya fenomena paradoks akurasi (*accuracy paradox*), yaitu kondisi di mana akurasi tinggi tidak mencerminkan kinerja model yang sebenarnya. Model Multinomial NB dan Bernoulli NB sama-sama mencatatkan akurasi tinggi sebesar 95%. Namun, angka ini bersifat menipu (*misleading*) karena jika ditinjau lebih dalam melalui *confusion matrix*, model Multinomial NB memiliki nilai *recall* 0.00 pada kelas Negatif. Artinya, model ini sepenuhnya gagal mengenali data sentimen negatif. Hal ini terjadi karena model cenderung mengklasifikasikan hampir semua data ke dalam kelas Positif, mengikuti dominasi kelas mayoritas dalam dataset. Bernoulli NB sedikit lebih baik, namun tetap menunjukkan kelemahan serupa dengan nilai *recall* kelas Negatif hanya sebesar 0.07. Kondisi ini menegaskan bahwa model *Naïve Bayes* tidak mampu memberikan hasil yang representatif pada dataset yang sangat tidak seimbang. Sementara itu, Gaussian NB memperlihatkan kinerja paling rendah di antara semua varian, dengan akurasi hanya 69% serta kesalahan klasifikasi yang signifikan, sehingga dinilai kurang sesuai untuk permasalahan analisis sentimen berbasis teks pada penelitian ini.

Sebaliknya, algoritma *Support Vector Machine* (SVM) mampu memberikan kinerja yang jauh lebih baik dan seimbang dalam menghadapi dataset yang tidak seimbang. SVM tidak hanya mencapai akurasi keseluruhan tertinggi sebesar 96%, tetapi juga menghasilkan *F1-score* kelas Negatif sebesar 0.48—nilai tertinggi dibandingkan seluruh model yang diuji. Capaian ini menunjukkan kemampuan SVM dalam menyeimbangkan *precision* dan *recall* ketika mengidentifikasi kelas minoritas. Hal yang lebih penting lagi, nilai *Macro Average F1-score* SVM sebesar 0.73 memperkuat kesimpulan bahwa model ini lebih andal karena mampu menjaga keseimbangan performa di semua kelas, bukan hanya pada kelas mayoritas. Dengan demikian, SVM dinilai sebagai algoritma yang paling efektif dan robust dalam tugas klasifikasi sentimen pada penelitian ini, khususnya ketika berhadapan dengan dataset yang cenderung tidak seimbang.



Gambar 13 Perbandingan Akurasi Algoritma

Berdasarkan analisis komparatif tersebut, Dapat disimpulkan bahwa algoritma *Support Vector Machine* (SVM) terbukti menjadi model yang paling optimal dalam melakukan klasifikasi sentimen pada dataset yang digunakan dalam penelitian ini. Keunggulannya tidak hanya terletak pada akurasi tertinggi, tetapi juga pada kemampuannya yang paling efektif dalam mengidentifikasi kelas minoritas (Negatif) dan menghasilkan model yang paling seimbang dalam menghadapi tantangan dataset yang tidak seimbang.

4.6. Pembahasan

Hasil pengujian menunjukkan bahwa algoritma *Support Vector Machine* (SVM) mencapai performa terbaik dengan tingkat akurasi sebesar 96% dan nilai *F1-score* pada kelas negatif sebesar 0,48. Capaian ini lebih tinggi dibandingkan seluruh varian *Naïve Bayes* (Multinomial, Bernoulli, Gaussian). Meskipun Multinomial dan Bernoulli NB mencatatkan akurasi 95%, hasil tersebut tidak sebanding dengan kemampuannya dalam mengenali kelas minoritas. Multinomial NB bahkan sama sekali gagal mendeteksi sentimen negatif (*recall* = 0), sedangkan Bernoulli NB hanya mampu mengenali sebagian kecil dengan *recall* 0,07. Gaussian NB memperlihatkan performa terlemah dengan akurasi 69% dan distribusi kesalahan klasifikasi yang besar.

Temuan ini memperlihatkan adanya fenomena *accuracy paradox*, yaitu kondisi ketika nilai akurasi tinggi tidak merepresentasikan kinerja model yang sebenarnya pada dataset tidak seimbang. Algoritma *Naïve Bayes* menunjukkan kecenderungan bias terhadap kelas mayoritas, yaitu kelas positif. sehingga meskipun akurasinya tampak tinggi, model tersebut gagal mendeteksi opini negatif. Sebaliknya, SVM terbukti lebih tangguh karena tetap mampu menangkap sebagian pola pada kelas minoritas, meskipun *recall* negatifnya masih terbatas.

Hasil penelitian ini konsisten dengan studi sebelumnya oleh Febriyani dan Elisa Februariyanti [4] terkait kebijakan “Kampus Merdeka” yang juga menemukan bahwa SVM lebih akurat dibandingkan *Naïve Bayes*. Tren yang sama juga dilaporkan oleh Maulana dan Bagas Akbar Fahmi [5] yang melakukan analisis sentimen pada ulasan aplikasi Pluang di Play Store, serta oleh Widia Ningsih, Baginda Alfianda, Rahmadden, dan Denok Wulandari [6], yang menganalisis sentimen publik di X terhadap penggunaan mobil listrik di Indonesia, di mana SVM lebih unggul dalam klasifikasi sentimen. Namun, temuan ini berbeda dengan penelitian Septian & Sarimole [7] pada isu penundaan pemilu yang melaporkan *Naïve Bayes* dapat mencapai akurasi hingga 98,8%. Perbedaan tersebut menegaskan bahwa kinerja algoritma sangat dipengaruhi oleh karakteristik dataset, khususnya pada kasus dengan distribusi sentimen yang tidak seimbang.

Kontribusi utama penelitian ini adalah memberikan bukti empiris bahwa SVM lebih andal dibanding *Naïve Bayes* untuk analisis sentimen kebijakan publik pada dataset dengan distribusi kelas tidak seimbang. Temuan ini memperkaya pemahaman di bidang analisis sentimen, khususnya dalam konteks pengolahan opini publik di media sosial yang cenderung memiliki distribusi data tidak merata. Selain itu, hasil penelitian ini juga menegaskan pentingnya penggunaan metrik evaluasi yang lebih komprehensif, seperti *precision*, *recall*, dan *F1-score*, untuk menilai kinerja model secara menyeluruh, bukan hanya bergantung pada akurasi semata.

5. Simpulan

Dari hasil penelitian dan analisis yang telah dilakukan, dapat disimpulkan bahwa sentimen publik di media sosial X terhadap program makan bergizi gratis bersifat sangat positif, yang tercermin dari 84,94% data terklasifikasi sebagai sentimen positif, yang pada akhirnya menciptakan kondisi dataset yang tidak seimbang. Dalam menjawab tujuan penelitian untuk membandingkan kinerja algoritma, *Support Vector Machine* (SVM) terbukti menjadi model dengan kinerja terbaik dan paling andal. SVM tidak hanya berhasil mencapai akurasi tertinggi sebesar 96%, tetapi juga menunjukkan kemampuan terbaik dalam mengenali kelas minoritas (Negatif) dengan nilai *F1-score* 0.48, jauh mengungguli varian *Naïve Bayes*. Model *Naïve Bayes*, meskipun memiliki akurasi tinggi (95%), terbukti tidak efektif karena mengalami bias yang ekstrem terhadap kelas mayoritas dan hampir sepenuhnya gagal mengidentifikasi sentimen negatif, yang menegaskan bahwa akurasi dapat menipu pada dataset yang tidak seimbang. Untuk pengembangan penelitian di masa depan, dianjurkan untuk menggunakan teknik penanganan ketidakseimbangan data, seperti *Synthetic Minority Over-sampling Technique* (SMOTE), agar dapat meningkatkan performa model dalam mendeteksi sentimen negatif. Selain itu, eksplorasi algoritma klasifikasi yang lebih canggih dari ranah *Deep Learning*, seperti LSTM atau arsitektur Transformer (BERT), berpotensi menghasilkan performa yang lebih baik lagi.

Daftar Referensi

- [1] P. K. Sari and R.R. Suryono, "Komparasi Algoritma *Support Vector Machine* Dan Random Forest Untuk Analisis Sentimen Metaverse," *J. Mnemon.*, vol. 7, no. 1, pp. 31–39, Feb. 2024.
- [2] B. A. Maulana, M. J. Fahmi, A. M. Imran, and N. Hidayati, "Analisis Sentimen Terhadap Aplikasi Pluang Menggunakan Algoritma Naive Bayes dan *Support Vector Machine* (SVM)," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 2, pp. 375–384, Feb. 2024, doi: 10.57152/malcom.v4i2.1206.
- [3] A. Zidna, M. Ali, M. Sri, and S. Joko Dwi, "Penerapan Metode *Support Vector Machine* Untuk Analisis Sentimen Pengguna Twitter," *J. Inf. Syst. Manag.*, vol. 3, no. 1, pp. 16–21, 2021.
- [4] E. Febriyani and H. Februariyanti, "Analisis Sentimen Terhadap Program Kampus Merdeka Menggunakan Algoritma Naive Bayes Classifier Di Twitter," *J. Tekno Kompak*, vol. 17, no. 1, p. 25, 2023, doi: 10.33365/jtk.v17i1.2061.
- [5] B. A. Maulana, M. J. Fahmi, A. M. Imran, and N. Hidayati, "Sentiment Analysis of Pluang Applications With Naive Bayes and *Support Vector Machine* (SVM)," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 2, pp. 375–384, 2024.
- [6] W. Ningsih, B. Alfianda, R. Rahmaddeni, and D. Wulandari, "Comparison of Naive Bayes and SVM Algorithms in Twitter Sentiment Analysis on Electric Car Use in Indonesia," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 2, pp. 556–562, 2024.
- [7] F. M. Sarimole and W. Septian, "Analisis Sentimen Masyarakat Terhadap Isu Penundaan Pemilu 2024 Pada Twitter Dengan Metode Naive Bayes Dan *Support Vector Machine*," *J. Sains dan Teknol.*, vol. 5, no. 3, pp. 890–899, 2024, [Online]. Available: <http://ejournal.sisfokomtek.org/index.php/saintek/article/view/1359>
- [8] M. E. Apriyani, A. Fikri Nur, and E. S. Astuti, "Comparison of *Naïve Bayes* and SVM Algorithms in Sentiment Analysis on JKN Application Data," *Int. J. Knowl. Database*, vol. 04, no. 02, pp. 180–188, 2024.
- [9] S. George and V. Srividhya, "Performance Evaluation of Sentiment Analysis on Balanced and Imbalanced Dataset Using Ensemble Approach," *Indian J. Sci. Technol.*, vol. 15, no. 17, pp. 790–797, 2022, doi: 10.17485/ijst/v15i17.2339.
- [10] B. Satya, S. J. Muhammad Hasan, M. Rahardi, and F. F. Abdulloh, "Sentiment Analysis of Review Sestyc Using *Support Vector Machine*, Naive Bayes, and Logistic Regression Algorithm," *ICOIACT 2022 - 5th Int. Conf. Inf. Commun. Technol. A New W. to Make AI Useful Everyone New Norm. Era, Proceeding*, no. February 2025, pp. 188–193, 2022, doi: 10.1109/ICOIACT55506.2022.9972046.
- [11] M. Raharjo, J. L. Putra, S. Heristian, and M. Napih, "Sentiment Analysis of Video Editing Applications Using *Support Vector Machine* on Google Colab," *JIKA (Jurnal Inform.)*, vol. 9, no. 2, p. 192, 2025, doi: 10.31000/jika.v9i2.13699.
- [12] F. Panjaitan, W. Ce, H. Oktafiandi, G. Kanugrahan, Y. Ramdhani, and V. H. C. Putra, "Evaluation of Machine Learning Models for Sentiment Analysis in the South Sumatra

- Governor Election Using Data Balancing Techniques,” *J. Inf. Syst. Informatics*, vol. 7, no. 1, pp. 461–478, 2025, doi: 10.51519/journalisi.v7i1.1019.
- [13] M. F. N. Fathoni, E. Y. Puspaningrum, and A. N. Sihananto, “Perbandingan Performa Labeling Lexicon InSet dan VADER pada Analisa Sentimen Rohingya di Aplikasi X dengan SVM,” *Modem J. Inform. dan Sains Teknol.*, vol. 2, no. 3, pp. 62–76, 2024.
- [14] A. Putri *et al.*, “Komparasi Algoritma K-NN, Naive Bayes dan SVM untuk Prediksi Kelulusan Mahasiswa Tingkat Akhir,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 1, pp. 20–26, 2023, doi: 10.57152/malcom.v3i1.610.
- [15] T. Puspa, R. Sanjaya, A. Fauzi, A. Fitri, and N. Masruriyah, “Analisis sentimen ulasan pada e-commerce shopee menggunakan algoritma naive bayes dan *Support Vector Machine* Analysis of review sentiment on shopee e-commerce using the naive bayes algorithm and *Support Vector Machine*,” vol. 4, No. 2, pp. 16–26, 2023, doi: 10.37373/infotech.v4i1.422.