

Analisis Sentimen Opini Masyarakat di *Platform X (Twitter)* terhadap Program Makanan Bergizi Gratis Menggunakan Metode *Support Vector Machine (SVM)*

Rangga adedio¹, Muhammad Husni Rifqo² Yulia Darmi³ Ardi Wijaya⁴
^{1 2 3 4} Teknik Informatika, Fakultas, Teknik, Universitas Muhammadiyah Bengkulu

ranggado12@gmail.com, mhrifqo@umb.ac.id, yuliadarmi10juli@gmail.com, ardiwijaya@umb.ac.id

Abstract

The increasing use of social media as a public space has encouraged the emergence of various opinions on government policies, including the Free Nutritious Food Program which is widely discussed on Platform X (Twitter). However, unstructured text data and diverse user perspectives pose challenges in accurately identifying sentiment. This study aims to analyze public sentiment using the Support Vector Machine (SVM) method with Term Frequency – Inverse Document Frequency (TF-IDF) weighting. Data were collected through web scraping from August to November 2025 totaling 4,002 tweets, which were then processed through labeling and preprocessing to obtain 3,129 data. Testing was carried out with three classification scenarios, namely three classes, two classes, and positive and non-positive. The results show that the highest accuracy obtained in the positive vs. non-positive scenario is 90.57%, followed by two classes at 90.34%, and three classes at 80.67%. These findings indicate that simplifying the number of classes can improve model performance. The SVM method with TF-IDF has proven effective in sentiment analysis on social media data.

Keywords: sentiment analysis, free nutritious meal program, X platform (twitter), support vector machine, TF-IDF.

Abstrak

Meningkatnya penggunaan media sosial sebagai ruang publik mendorong munculnya berbagai opini terhadap kebijakan pemerintah, termasuk Program Makanan Bergizi Gratis yang banyak dibahas di Platform X (Twitter). Namun, data berbentuk teks tidak terstruktur dan beragamnya sudut pandang pengguna menjadi tantangan dalam mengidentifikasi sentimen secara akurat. Penelitian ini bertujuan menganalisis sentimen masyarakat menggunakan metode *Support Vector Machine (SVM)* dengan pembobotan *Term Frequency–Inverse Document Frequency (TF-IDF)*. Data dikumpulkan melalui *web scraping* pada periode Agustus hingga November 2025 sebanyak 4.002 *tweet*, yang kemudian diproses melalui pelabelan dan preprocessing hingga diperoleh 3.129 data. Pengujian dilakukan dengan tiga skenario klasifikasi, yaitu tiga kelas, dua kelas, serta positif dan non-positif. Hasil menunjukkan bahwa akurasi tertinggi diperoleh pada skenario positif vs non-positif sebesar 90,57%, diikuti dua kelas sebesar 90,34%, dan tiga kelas sebesar 80,67%. Temuan ini menunjukkan bahwa penyederhanaan jumlah kelas dapat meningkatkan kinerja model. Metode SVM dengan TF-IDF terbukti efektif dalam analisis sentimen pada data media sosial.

Kata kunci: analisis sentimen, program makanan bergizi gratis, platform X (twitter), support vector machine, TF-IDF.

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International License

1. Pendahuluan

Penggunaan media sosial untuk komunikasi dan opini publik tentang berbagai topik publik telah berkembang sebagai hasil dari kemajuan teknologi informasi. Media sosial kini menjadi forum bagi publik untuk menyuarakan pendapat, mengkritik, dan mendukung inisiatif pemerintah, di samping digunakan untuk komunikasi antarpribadi [1]. Platform X (Twitter) adalah salah satu situs media sosial yang sering digunakan dalam percakapan publik. Fitur-fitur platform ini, yang memungkinkan pengguna untuk mengkomunikasikan ide secara ringkas dan cepat, menjadikannya media yang responsif terhadap berbagai isu baru. Reaksi publik terhadap berbagai inisiatif pemerintah sering kali diungkapkan melalui unggahan dan komentar di situs tersebut [2].

Analisis sentimen adalah pendekatan penambangan teks yang mengklasifikasikan kecenderungan opini suatu teks ke dalam kategori positif, negatif, atau netral [3]. Metode *Support Vector Machine (SVM)* berkinerja

baik dalam proses kategorisasi teks berbasis sentimen, menurut sejumlah penelitian sebelumnya. Penelitian [4] membandingkan beberapa jenis kernel pada implementasi SVM dalam pengelompokan opini publik terkait vaksinasi COVID-19. Penelitian tersebut menggunakan pendekatan text mining dengan tahapan *preprocessing* sebelum proses klasifikasi. Kernel *linear* menghasilkan akurasi maksimum sebesar 83,06%, menurut data, sedangkan kernel *polynomial* dan *sigmoid* memiliki nilai yang sedikit lebih rendah. Hal ini menunjukkan bahwa kinerja model klasifikasi dapat dipengaruhi oleh pilihan kernel.

Selanjutnya, [5] melakukan penelitian terhadap ulasan aplikasi Shopee menggunakan algoritma SVM dengan tahapan *preprocessing* dan pembobotan fitur. Temuan studi menunjukkan bahwa model tersebut berkinerja sangat baik dalam klasifikasi, mencapai akurasi 98% dengan nilai *F1-score* yang tinggi. [6] Algoritma SVM juga digunakan untuk menganalisis sentimen evaluasi aplikasi Al-Quran digital, dengan akurasi 85,11%. Model ini memiliki tingkat stabilitas yang cukup baik

dalam proses klasifikasi data, berdasarkan nilai presisi dan recall yang diperoleh. Jelas dari beberapa penelitian ini bahwa algoritma SVM berkinerja cukup baik dalam kategorisasi teks berbasis sentimen.

Teknik mengubah data teks yang tidak terstruktur menjadi informasi yang dapat diperiksa secara metodis dikenal sebagai penambahan teks. Pra-pemrosesan, ekstraksi fitur, dan klasifikasi adalah tiga langkah utama penambahan teks dalam penelitian analisis sentimen berbasis media sosial [1]. Tahapan tersebut bertujuan untuk meningkatkan kualitas data serta mentransformasikan teks menjadi vektor numerik yang selanjutnya digunakan dalam proses klasifikasi menggunakan algoritma SVM. Hal ini juga diterapkan dalam penelitian Ananda dan [7] serta Husada dan [8] yang menunjukkan bahwa text mining menjadi tahap penting dalam mempersiapkan data sebelum proses klasifikasi dilakukan.

Langkah pertama dalam memproses data teks disebut praproses teks, dan tujuannya adalah untuk mempersiapkan dan membersihkan data sebelum mengklasifikasikannya. Data media sosial biasanya mencakup berbagai macam *noise* yang dapat memengaruhi temuan analisis, termasuk URL, simbol, tanda baca, singkatan, dan variasi ejaan. Pembersihan, pengubahan huruf besar/kecil, tokenisasi, normalisasi, penghapusan *stopword*, dan stemming adalah langkah-langkah praproses yang digunakan dalam penelitian ini. Langkah-langkah ini konsisten dengan penelitian yang dilakukan oleh Timilah dan [9] dan [6], yang juga menggunakan prosedur pembersihan teks sebelum ekstraksi fitur.

Penelitian [10] menggunakan algoritma *Support Vector Machine* (SVM) sebagai teknik klasifikasi untuk mempelajari analisis sentimen evaluasi pengguna terhadap aplikasi dompet digital DANA di *Google Play Store*. Sebelum prosedur klasifikasi, penelitian ini mencakup banyak fase pemrosesan data teks, termasuk pra-pemrosesan dan ekstraksi fitur menggunakan TF-IDF. Pendekatan SVM dianggap bermanfaat untuk analisis sentimen data ulasan aplikasi karena temuan menunjukkan bahwa pendekatan ini mampu mengklasifikasikan sentimen ulasan pengguna dengan baik.

2. Metode Penelitian

Kajian dalam penelitian ini menitikberatkan pada perbandingan hasil klasifikasi pada setiap skenario pengujian, yaitu klasifikasi dua kelas, tiga kelas, serta penggabungan sentimen, untuk mengetahui konfigurasi yang menghasilkan performa terbaik berdasarkan metrik evaluasi *accuracy*, *precision*, *recall*, dan *F1-score*.

2.1 Pengumpulan Data

Data penelitian diperoleh dari cuitan publik tentang Program Makanan Bergizi Gratis di *Platform X* (*Twitter*). Teknik *web scraping* digunakan untuk memperoleh data menggunakan kata kunci yang terkait

dengan objek penelitian. Dari Agustus hingga November 2025, sebanyak 4.002 cuitan berhasil dikumpulkan. Data yang dianalisis dibatasi pada tweet berbahasa Indonesia untuk menjaga konsistensi analisis serta mempermudah proses pengolahan sentimen.

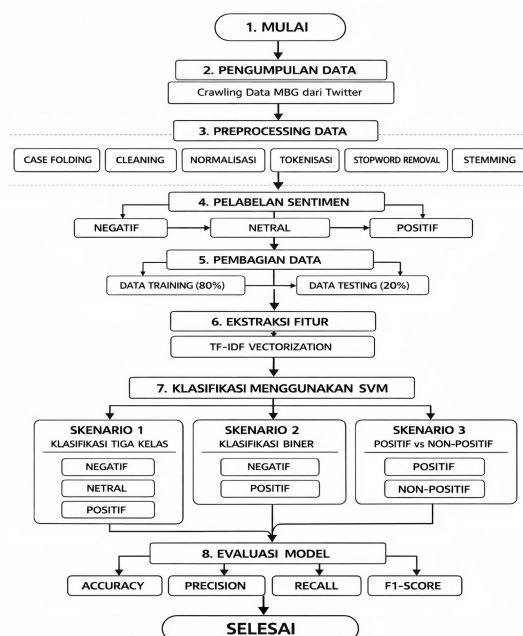
2.2 Instrumen Penelitian

Alat untuk memproses dan menganalisis data disebut instrumen penelitian. Perangkat lunak *Python* digunakan dalam penelitian ini dengan menggunakan *Google Colab*, sebuah platform berbasis cloud, sehingga tidak memerlukan instalasi tambahan dan mendukung berbagai *library machine learning*. Data yang digunakan adalah *tweet* yang telah melalui proses pelabelan dan prapemrosesan. Selain itu, penelitian ini menggunakan perangkat keras berupa *MacBook Air* dengan *chip Apple M4* dan RAM 16 GB untuk mendukung proses analisis

2.3 Tahapan Penelitian

Tahapan penelitian analisis sentimen ini dilakukan secara metodis melalui sejumlah proses yang saling terkait. Setiap tahapan disusun secara berurutan untuk memastikan proses pengolahan data berjalan dengan terstruktur, mulai dari pengumpulan data hingga evaluasi hasil klasifikasi sentimen. Adanya tahapan penelitian ini bertujuan agar proses analisis dapat dilakukan secara terarah serta menghasilkan keluaran yang sesuai dengan tujuan penelitian.

Distribusi tahapan penelitian analisis sentimen yang dilakukan dalam penelitian ini dapat dilihat pada Gambar 1 berikut.



Gambar 1. Alur tahapan penelitian

2.4 Pelabelan Data

Setelah itu, data yang terkumpul diklasifikasikan secara manual berdasarkan sentimen positif, negatif, atau

netral sesuai dengan konteks dan makna kalimat tersebut.

2.5 Text Preprocessing

Sebelum data teks digunakan dalam proses klasifikasi sentimen, data tersebut harus dibersihkan dan dipersiapkan melalui pra-pemrosesan teks. Untuk membantu proses ekstraksi fitur dan evaluasi kinerja model berjalan semulus mungkin, data diatur dan distrukturkan agar lebih relevan dan terorganisir. Kinerja model dan kualitas ekstraksi fitur dapat ditingkatkan dengan pendekatan metodis ini.

Teknik mengubah setiap huruf dalam teks menjadi huruf kecil dikenal sebagai "case folding." Tujuannya adalah untuk memastikan bahwa variasi kapitalisasi tidak memengaruhi temuan analisis. Pembersihan melibatkan penggunaan ekspresi reguler untuk menghilangkan item yang tidak perlu seperti URL, penyebutan, tagar, angka, tanda baca, dan karakter non-huruf. Untuk membuat teks lebih mudah dibaca, spasi tambahan juga dihilangkan.

Setelah dilakukan proses Proses membagi teks menjadi kata-kata disebut tokenisasi. Dalam studi ini, fungsi *Python* digunakan untuk melakukan pemisahan berdasarkan spasi. Langkah selanjutnya adalah melakukan normalisasi, tujuannya adalah untuk mengubah istilah non-standar menjadi bentuk standar. Prosedur ini menggunakan kamus yang menghubungkan istilah non-standar dengan padanan standarnya. Jika sebuah kata ditemukan dalam kamus, maka kata tersebut akan dimodifikasi.

Untuk memfokuskan teks pada istilah-istilah kunci, kata-kata penghenti (*stopwords*) yang sering digunakan tetapi memiliki sedikit pengaruh pada analisis sentimen dihilangkan. Selanjutnya, dilakukan pengubahan kata-kata yang terlampir menjadi kata-kata dasar yang disebut *stemming*. Untuk mendapatkan bentuk yang konsisten sebelum langkah analisis, tujuannya adalah untuk menyederhanakan varian kata.

2.6 Ekstraksi Fitur menggunakan TF-IDF

Setiap kata dalam sebuah dokumen diberi bobot sesuai dengan signifikansinya menggunakan pendekatan Frekuensi Istilah-Frekuensi Dokumen Terbalik (TF-IDF). Frekuensi Istilah (TF) dan Frekuensi Dokumen Terbalik (IDF) adalah dua bagian utama dari TF-IDF.

Frekuensi Istilah (TF) menunjukkan seberapa sering suatu istilah muncul dalam sebuah dokumen:

$$TF(t, d) = \frac{f(t, d)}{\sum f(d)} \quad (1)$$

Keterangan:

$f(t, d)$ adalah jumlah kemunculan istilah "t" dalam dokumen "d."

Tingkat keunikan suatu kata di semua teks ditunjukkan oleh Frekuensi Dokumen Terbalik (IDF):

$$IDF(t) = \log \left(\frac{N}{df(t)} \right) \quad (2)$$

Keterangan:

N adalah jumlah total dokumen, sedangkan jumlah dokumen yang mengandung istilah t dilambangkan dengan $df(t)$.

Bobot TF-IDF diperoleh dari hasil perkalian TF dan IDF:

$$TF-IDF(t, d) = TF(t, d) \times IDF(t) \quad (3)$$

2.7 Klasifikasi Sentimen menggunakan Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah metode klasifikasi yang menemukan hyperplane atau garis pemisah yang mengoptimalkan margin, atau jarak, antar kelas.

Fungsi keputusan SVM secara umum dapat dinyatakan sebagai berikut:

$$f(x) = w \cdot x + b \quad (4)$$

Keterangan:

w adalah vektor bobot,

x adalah vektor fitur hasil ekstraksi TF-IDF,

b adalah nilai bias.

Menemukan pengaturan nilai w dan b yang memaksimalkan margin antar kelas sekaligus mengurangi kesalahan klasifikasi adalah tujuan utama SVM. Dalam penelitian ini, karakteristik teks yang diperoleh digunakan untuk mengidentifikasi kelas sentimen menggunakan SVM.

2.8 Pembagian Data Latih dan Data Uji

Setelah pra-pemrosesan dan ekstraksi fitur, data dipisahkan menjadi set pengujian dan pelatihan. Tujuan pembagian data ini adalah untuk menguji kemampuan model klasifikasi dalam mengkategorikan data yang belum pernah dilihat sebelumnya. Data yang digunakan dalam penelitian ini dibagi menjadi 20% data pengujian dan 80% data pelatihan. Tujuan pembagian ini adalah untuk memperoleh hasil pengujian yang representatif dan objektif.

2.9 Skenario Pengujian Sentimen

Penelitian ini menggunakan beberapa skenario pengujian untuk melihat kinerja model secara menyeluruh dalam berbagai kondisi. Skenario yang digunakan meliputi dua kelas (positif dan negatif), tiga kelas (positif, negatif, dan netral), serta positif vs non-positif. Skenario dua kelas bertujuan menguji kemampuan model dalam membedakan opini yang mendukung dan tidak mendukung, sedangkan tiga kelas digunakan untuk memberikan gambaran sentimen yang lebih rinci. Sementara itu, skenario positif vs non-positif digunakan untuk melihat kemampuan model dalam membedakan opini positif dengan selain positif. Penerapan beberapa skenario ini bertujuan untuk menganalisis pengaruh jumlah dan pembagian kelas terhadap performa algoritma *Support Vector Machine* (SVM), sehingga dapat diketahui

bagaimana perubahan konfigurasi kelas mempengaruhi hasil klasifikasi sentimen.

2.10 Evaluasi Kinerja Model

Efektivitas algoritma *Support Vector Machine* dalam mengkategorikan sentimen tweet publik dinilai menggunakan evaluasi kinerja model. *Confusion matriks* digunakan untuk evaluasi dengan membandingkan prediksi model dengan data aktual. Kriteria evaluasi termasuk akurasi, presisi, recall, dan skor F1 diperoleh dari matriks kebingungan. Kinerja model dalam setiap skenario pengujian dievaluasi menggunakan ukuran-ukuran ini.

Metrik Evaluasi dan Rumus

Berikut ini adalah langkah-langkah penilaian yang digunakan dalam penelitian ini:

1. Accuracy

Akurasi digunakan untuk mengukur seberapa baik model mengklasifikasikan semua data secara bersamaan.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

2. Precision

Precision digunakan untuk mengukur tingkat ketepatan model dalam memprediksi suatu kelas sentimen tertentu.

$$Precision = \frac{TP}{TP+FP} \quad (6)$$

3. Recall

Kemampuan model untuk menemukan setiap bagian data yang termasuk dalam kelas sentimen tertentu diukur menggunakan recall.

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

4. F1-Score

Skor F1 digunakan untuk mengukur seberapa baik keseimbangan antara recall dan akurasi.

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (8)$$

Keterangan:

Jumlah item data yang diproyeksikan positif dan sesuai dengan kondisi aktual dikenal sebagai TP (*True Positive*).

Jumlah item data yang diproyeksikan negatif dan sesuai dengan kondisi aktual dikenal sebagai TN (*True Negative*).

Jumlah item data yang diharapkan positif tetapi tidak sesuai dengan kondisi aktual dikenal sebagai FP (*False Positive*). Jumlah item data yang diantisipasi negatif tetapi tidak sesuai dengan kondisi aktual dikenal sebagai FN (*False Negative*).

3. Hasil dan Pembahasan

3.1. Hasil Preprocessing Data

Kata kunci yang terkait dengan program Makanan Bergizi Gratis digunakan dalam operasi pengumpulan data di Platform X untuk mengumpulkan data untuk investigasi ini. Sebanyak 4.002 tweet yang memenuhi parameter pencarian ditemukan selama periode pengumpulan data, yang berlangsung dari 4 Agustus hingga 27 November 2025. Dataset tersebut menjalani langkah pembersihan data (pra-pemrosesan) sebelum analisis sentimen menggunakan teknik *Support Vector Machine* (SVM). Untuk mempersiapkan data agar dapat digunakan dalam prosedur pembobotan dan klasifikasi, langkah ini berupaya untuk menghilangkan data yang tidak perlu, menangani nilai kosong, dan menormalisasi bahasa.

Data dalam penelitian ini diperoleh melalui proses crawling menggunakan API *Twitter* dengan bantuan *tools Tweet Harvest*, menghasilkan 4.002 tweet berdasarkan kata kunci yang telah ditentukan. Data dikumpulkan secara bertahap hingga membentuk satu dataset utuh. Selanjutnya, data diberi label secara manual ke dalam kategori positif, negatif, dan netral berdasarkan konteks kalimat. Setelah proses verifikasi, data yang tidak memenuhi kriteria dihapus sehingga diperoleh 3.129 data yang digunakan dalam penelitian. Distribusi data menunjukkan bahwa sentimen negatif berjumlah 1.573 data, positif 1.065 data, dan netral 491 data. Dominasi sentimen negatif menunjukkan adanya ketimpangan distribusi kelas yang berpotensi memengaruhi kinerja model, khususnya pada klasifikasi multikelas.

Distribusi proses pengambilan data mentah di tunjukkan pada Gambar 2 di bawah.

No	ID Tweet	Waktu	ID Penulis	Tweet
1	1932229499074122496.0	2025-08-04 04:45:57+00:00	1638811009082347520.0	Apa jadinya jika calon presiden Anda mengkampana...
2	1952266284152016896.0	2025-08-04 07:12:08+00:00	99197373986784864.0	Lock 13 Sep ini, Jemson dan ramal lagi bakal m...
...
4001	1994125394793220736.0	2025-11-27 19:25:17+00:00	894483993.0	Yaa gini negara kalo salah proyeksi fiskal dan...
4002	1994052329485688320.0	2025-11-27 14:34:57+00:00	985506103772364800.0	pemerintah gak takut apa ya kena hisab nanti d...

Gambar 2. Data mentah

Gambar 2 diatas menampilkan data mentah hasil crawling dari Platform X yang terdiri atas ID Tweet, waktu, ID penulis, dan isi tweet. Data pada gambar masih mengandung berbagai bentuk noise, seperti huruf kapital, tanda baca, singkatan, dan kata tidak baku. Selanjutnya, data diproses melalui tahap *preprocessing* yang mencakup *cleaning*, *case folding*, *normalisasi*, *stopword removal*, *tokenisasi*, dan I agar kualitas data menjadi lebih baik sebelum dilakukan klasifikasi.

Cleaning dan Casefolding

Distribusi proses *Cleaning* dan *Casefolding* di tunjukkan pada Gambar 3 di bawah.

No	clean_text	label_manual
1	penolakan impor food tray untuk mbg menunjukka...	positif
2	permintaan kamu bagus dek tapi sayang makanan ...	negatif
...
3128	yaa gini negara kalo salah proyeksi fiskal dan...	negatif
3129	pemerintah gak takut apa ya kena hisab nanti d...	negatif

Gambar 3. Proses Cleaning dan Casefolding

Hasil proses *Cleaning* dan *Casefolding* dapat dilihat pada Tabel 1 berikut.

Tabel 1. Hasil *Cleaning* dan *Casefolding*

Data Mentah	Setelah <i>Cleaning</i> dan <i>Casefolding</i>
Semisal 1 sekolahan sepatat ga ikut program mbg kira ² nanti dpt sanksi atau ga dipermasalahkan ya? Mending nolak aja ga sih. Buat anak kok coba-coba	semisal sekolahan sepatat ga ikut program mbg kira nanti dpt sanksi atau ga dipermasalahkan ya mending nolak aja ga sih buat anak kok coba coba

Tabel 1 diatas menunjukkan hasil proses *cleaning* dan *case folding* pada data tweet yang telah disimpan pada kolom `clean_text` beserta label sentimennya. Pada tahap ini, karakter yang tidak diperlukan seperti tanda baca, simbol, dan tautan dihapus, kemudian seluruh huruf diubah menjadi huruf kecil agar penulisan data menjadi lebih seragam. Proses tersebut dilakukan untuk memudahkan sistem dalam mengolah data pada tahap berikutnya.

Normalisasi Teks

Distribusi proses normalisasi teks di tunjukan pada Gambar 4 dibawah.

Gambar 4. Proses Normalisasi

Hasil proses Normalisasi dapat dilihat pada Tabel 2 berikut

Tabel 2. Hasil Normalisasi

Sebelum Normalisasi	Setelah Normalisasi
semisal sekolahan sepatat ga ikut program mbg kira nanti dpt sanksi atau ga dipermasalahkan ya mending nolak aja ga sih buat anak kok coba coba	semisal sekolahan sepatat tidak ikut program mbg kira nanti dpt sanksi atau tidak dipermasalahkan ya mending nolak saja tidak sih buat anak kok coba cobas

Tabel 2 diatas menampilkan hasil proses normalisasi teks pada data tweet. Pada kolom hasil normalisasi terlihat bahwa beberapa kata tidak baku, singkatan, dan variasi penulisan telah diubah menjadi bentuk kata yang lebih sesuai dan konsisten. Tahap normalisasi dilakukan agar kata yang memiliki makna sama dapat dikenali sebagai satu bentuk penulisan yang seragam sehingga data menjadi lebih terstruktur dan siap digunakan dalam proses analisis sentimen.

Stopword Removall

Distribusi proses *Stopword Removall* ditunjukkan pada Gambar 5 di bawah

Gambar 5. Proses *Stopword Removeall*

Prosedur penghapusan stopword berlanjut setelah fase normalisasi data. Stopword adalah penghapusan kata-kata populer seperti "yang," "dan," "di," "ke," dan "untuk" yang sering digunakan dalam frasa tetapi tidak berpengaruh pada penilaian sentimen. Penghapusan stopword digunakan untuk memfokuskan teks pada istilah-istilah yang relevan.

Hasil dari *Stopword* dapat dilihat dari Tabel 3 berikut.

Tabel 3. Hasil *Stopword Removeal*

Sebelum Stopword Removeal	Setelah Stopword Removeal
semisal sekolahan sepatat tidak ikut program mbg kira nanti dpt sanksi atau tidak dipermasalahkan ya mending nolak saja tidak sih buat anak kok coba coba	semisal sekolahan sepatat ikut program mbg kira dpt sanksi tidak dipermasalahkan mending nolak tidak sih buat anak kok coba coba

Steming

Langkah selanjutnya setelah penghapusan *stopword*. Tindakan mereduksi kata ke bentuk paling dasar dengan menghilangkan imbuhan seperti prefiks, sufiks, dan konfiks dikenal sebagai *stemming*. Untuk mencegah istilah dengan arti yang sama dianggap sebagai entitas yang berbeda, tahap ini membantu menyederhanakan standardisasi kosakata.

Distribusi proses *steming* ditunjukkan pada Gambar 6 dibawah.

Gambar 6. Proses *Steming*

Hasil dari proses *Steming* dapat dilihat dari Tabel 4 berikut.

Tabel 4. Hasil *Steming*

Sebelum Steming	Setelah Steming
semisal sekolahan sepatat tidak ikut program mbg kira nanti dpt sanksi atau tidak dipermasalahkan ya mending nolak saja tidak sih buat anak kok coba coba	misal sekolah sepatat ikut program mbg kira dpt sanksi tidak masalah mending nolak tidak sih buat anak kok coba coba

Tokenisasi

Dalam penelitian ini, tahap tokenisasi dilakukan secara otomatis selama konstruksi fitur dengan memanfaatkan pendekatan TF-IDF (*Term Frequency-Inverse Document Frequency*) dan bukan sebagai prosedur terpisah dalam bentuk kolom tertentu. Sebelum menghitung bobot setiap kata dalam dokumen,

algoritma membagi teks menjadi kata-kata. Hasilnya adalah data numerik (matriks fitur) yang kemudian dimasukkan ke dalam algoritma *Support Vector Machine* (SVM) untuk klasifikasi emosi.

Distribusi proses tokenisasi ditunjukkan pada Gambar 7 dibawah



Gambar 7. Proses Tokenisasi

Setelah menjalani tahap *preprocessing*, teks diubah menjadi daftar kata yang dipisahkan berdasarkan spasi, seperti [tolak, impor, food, tray, mbg, tunjuk, bijak]. Kolom No. menunjukkan nomor urut data, sedangkan kolom tokenisasi berisi daftar kata hasil pemecahan teks.

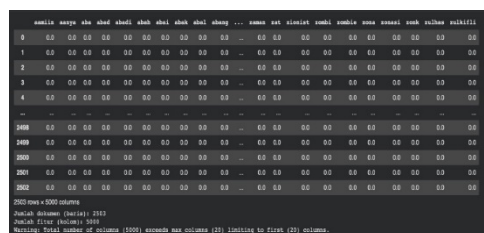
Hasil Tokenisasi dapat dilihat dari Tabel 5 berikut.

Tabel 5 Hasil Tokenisasi

Sebelum Tokenisasi	Setelah Tokenisasi
misal sekolah sepatat	'misal' 'sekolah' 'sepatat'
ikut program mbg kira	'ikut' 'program' 'mbg' 'kira'
dpt sanksi tidak masalah	'dpt' 'sanksi' 'tidak' 'masalah'
mending nolak tidak sih	'mending' 'nolak' 'tidak' 'sih'
buat anak kok coba coba	'buat' 'anak' 'kok' 'coba' 'coba'

Proses TF-IDF

Distribusi proses TF-IDF di tunjukkan pada Gambar 8 di bawah.



Gambar 8. Proses TF-IDF

Meskipun telah melalui tahap *preprocessing*, data teks masih berupa kumpulan kata sehingga belum dapat langsung digunakan dalam proses klasifikasi. Oleh karena itu, dilakukan ekstraksi fitur menggunakan metode TF-IDF (*Term Frequency-Inverse Document Frequency*) untuk mengubah teks menjadi representasi numerik. Metode ini memberikan bobot pada setiap kata berdasarkan frekuensi kemunculannya dalam dokumen (TF) dan tingkat keunikannya dalam keseluruhan dokumen (IDF). Hasilnya berupa matriks fitur numerik, di mana setiap dokumen direpresentasikan sebagai baris dan setiap kata sebagai kolom yang digunakan dalam proses klasifikasi.

Klasifikasi SVM

Pengujian model SVM pada data pengujian dilakukan setelah prosedur pelatihan selesai menggunakan data pelatihan. Pada tahap ini, kelas sentimen diprediksi oleh model yang telah dibangun menggunakan pola

yang ditemukan dari representasi numerik data TF-IDF. Akurasi model kemudian ditentukan dengan membandingkan prediksi ini dengan label sebenarnya.

3.2 Pembagian Data

Pembagian data dilakukan dengan scenario 80%: 20%. 80% dari dataset yang telah diproses dan diberi label digunakan untuk pelatihan, sedangkan 20% sisanya digunakan untuk pengujian. Untuk memastikan konsistensi temuan ketika pemrosesan diulang, prosedur pengacakan yang menggunakan parameter keadaan acak digunakan untuk melakukan pemisahan. Sebanyak 3.129 tweet digunakan dalam situasi kategorisasi pertama, kedua, dan ketiga.

Data pelatihan dan pengujian diperoleh setelah pembagian tersebut. Untuk memastikan representasi yang lebih objektif dari kinerja model, pembagian ini berupaya menilai kapasitas model untuk melakukan generalisasi pada data yang belum pernah dipelajari sebelumnya.

3.3 Hasil Klasifikasi dan Evaluasi Model

Dalam penelitian ini, digunakan klasifikasi *Support Vector Machine* (SVM) kernel linier. Pendekatan TF-IDF digunakan untuk menerjemahkan teks ke dalam representasi numerik sebelum pelatihan guna mengevaluasi pentingnya sebuah kata dalam dokumen. Ukuran akurasi, presisi, recall, dan F1-score digunakan untuk mengevaluasi kinerja keseluruhan model serta keseimbangan kinerja dalam setiap kelas.

3.3.1 Skenario Klasifikasi 1 (Negatif, Netral, Positif)

Data dalam Skenario 1 dipisahkan menjadi tiga kelompok: positif, netral, dan negatif. Kinerja model dinilai menggunakan matriks kebingungan, presisi, recall, dan f1-score, dan diskusi berpusat pada fitur kata-kata di setiap kelas menggunakan word cloud. Situasi ini digunakan untuk melihat lebih dekat variasi opini publik, termasuk sudut pandang informatif (netral)

```

Accuracy: 0.8067092651757188
Classification Report:

```

	precision	recall	f1-score	support
Negatif	0.80	0.94	0.87	314
Netral	0.64	0.43	0.51	110
Positif	0.89	0.81	0.84	202
accuracy			0.81	626
macro avg	0.77	0.72	0.74	626
weighted avg	0.80	0.81	0.80	626

Gambar 9. Klasifikasi report 1

Berdasarkan hasil pengujian Skenario 1 dengan 626 data uji, model memperoleh akurasi sebesar 0,81 yang mengindikasikan bahwa 81% data berhasil diklasifikasikan dengan benar.

Analisis Wordcloud Skenario 1

Tiga kelompok sentimen negatif, netral, dan positif diidentifikasi dalam Skenario 1.



Gambar 10. Wordcloud Positif

Pada sentimen Positif, kata yang paling dominan seperti “makan”, “gizi”, “mbg”, dan “gratis” tetap muncul karena merupakan inti pembahasan program. Dominasi kata-kata tersebut menunjukkan bahwa percakapan masyarakat berfokus pada substansi utama kebijakan yang dibahas. Namun, arah sentimen positif lebih terlihat dari kemunculan kata pendukung seperti “sehat”, “dukung”, “anak”, “masa depan”, dan “baik”.



Gambar 11. Wordcloud Netral

Pada sentimen Netral, kata yang paling dominan dan berukuran paling besar seperti “makan”, “gizi”, “mbg”, dan “gratis” tetap muncul karena merupakan inti pembahasan program. Frekuensi kemunculan suatu kata dalam data meningkat seiring dengan besarnya pengaruh kata tersebut, menunjukkan bahwa wacana masih berpusat pada program tersebut. Konten pada kelas Netral lebih menekankan pada penyampaian fakta atau informasi terkait pelaksanaan program tanpa menunjukkan dukungan maupun kritik secara tegas. Karakteristik ini menyebabkan kosakata pada kelas Netral cenderung mirip dengan kelas sentimen lainnya, namun tidak mengandung muatan emosional yang kuat.




Gambar 12. Wordcloud Negatif

Pada sentimen Negatif, kata yang paling dominan seperti “makan”, “gizi”, “mbg”, dan “gratis” tetap muncul karena merupakan inti pembahasan program. Ukuran kata yang besar menunjukkan bahwa pembahasan tetap berfokus pada topik utama. Namun, arah sentimen negatif lebih terlihat dari kemunculan kata seperti “tidak”, “racun”, “kalau”, “buat”, dan

“banyak”. Kata-kata tersebut mencerminkan adanya kritik, kekhawatiran, atau evaluasi terhadap pelaksanaan program. Penggunaan kata yang bernuansa penolakan dan bersifat evaluatif menunjukkan adanya respons yang lebih emosional, sehingga membuat kelas Negatif lebih mudah dikenali oleh model dibandingkan teks yang bersifat informatif.

Analisis *Confusion Matrix* Skenario 1 ditunjukkan pada Gambar 13 berikut.



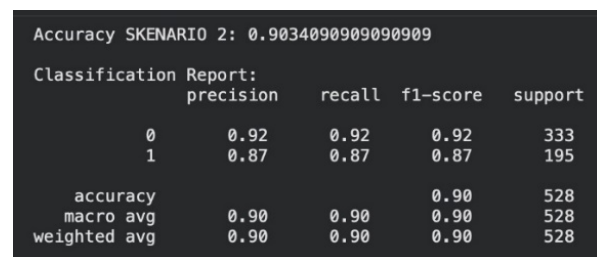
Gambar 13. Confusion Matrix Skenario 1

Hasil *confusion matrix* yang dihasilkan dalam Skenario 1 konsisten dengan temuan word cloud. 295 dari 314 set data dalam kelas Negatif dari 626 set data uji dikategorikan dengan benar. Temuan ini menunjukkan bahwa model cukup baik dalam mengidentifikasi sentimen negatif, yang sering didefinisikan oleh penggunaan istilah yang memiliki implikasi penolakan atau evaluasi yang kuat.

Secara keseluruhan, temuan *word cloud* dan matriks kebingungan menunjukkan bahwa model lebih baik dalam mengenali perasaan dengan ciri linguistik dan konten emosional yang berbeda, seperti pada kelas Negatif dan Positif, dibandingkan sentimen Netral yang cenderung ambigu dan bersifat informatif. Dengan demikian, Skenario 1 telah mampu memetakan perbedaan sentimen secara umum dengan baik, meskipun masih terdapat keterbatasan dalam membedakan kelas Netral secara optimal.

3.3.2 Skenario Klasifikasi 2 (Positif vs Negatif)

Pada Skenario 2, proses klasifikasi dilakukan menggunakan dua label numerik, yaitu 0 dan 1. Label 0 merepresentasikan sentimen Negatif, sedangkan label 1 merepresentasikan sentimen Positif. Penggunaan label angka bertujuan untuk mempermudah proses pengolahan data dalam model klasifikasi. Hasil pengujian pada skenario ini ditunjukkan pada Gambar 14 berikut.



Gambar 14. Klasifikasi report 2

Berdasarkan hasil pengujian terhadap 528 data uji, model memperoleh akurasi sebesar 0,90 yang menunjukkan bahwa 90% data berhasil diklasifikasikan dengan benar.

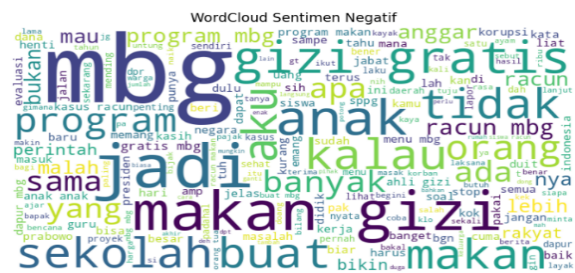
Analisis Wordcloud Skenario 2 :

Pada Skenario 2, klasifikasi dilakukan berdasarkan dua kategori sentimen, yaitu Negatif (0) dan Positif (1). Pendekatan ini digunakan untuk menyederhanakan proses analisis dengan hanya membedakan opini yang bersifat mendukung dan yang bersifat mengkritik. Dengan klasifikasi biner, model diharapkan dapat lebih fokus dalam mengenali perbedaan karakteristik bahasa antara kedua sentimen tersebut. Visualisasi wordcloud digunakan untuk melihat distribusi dan dominasi kata pada masing-masing kelas sentimen berdasarkan frekuensi kemunculannya.



Gambar 15. WordCloud Positif

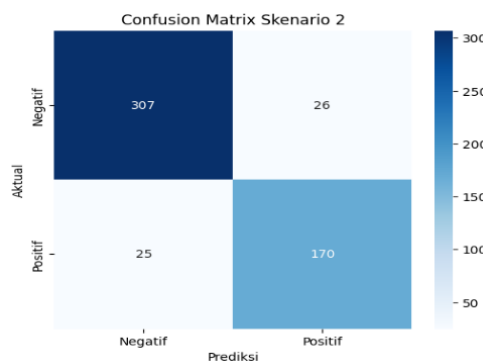
Berdasarkan wordcloud sentimen Positif, terlihat bahwa kata-kata yang paling dominan antara lain “gizi”, “makan”, “program”, “gratis”, dan “mbg”. Selain itu, muncul pula kata seperti “anak”, “sehat”, “dukung”, dan “masa depan”. Dominasi kata-kata tersebut menunjukkan bahwa opini positif masyarakat berfokus pada inti program sekaligus manfaat yang dirasakan. Kemunculan kata bernuansa apresiatif



Gambar 16. WordCloud Negatif

Di sisi lain, pada wordcloud sentimen Negatif terlihat kata-kata yang cukup menonjol seperti “tidak”, “kalau”, “buat”, “racun”, dan “banyak”. Kemunculan kata “racun” mengindikasikan adanya pembahasan terkait isu keamanan makanan atau kasus tertentu yang menimbulkan kekhawatiran. Selain itu, kata seperti “tidak” dan “kalau” menunjukkan adanya kritik atau evaluasi terhadap pelaksanaan program, baik dari sisi kualitas maupun implementasinya.

Analisis Confusion Matrix Skenario 2 :



Gambar 17. Confusion Matrix Skenario 2

Berdasarkan confusion matrix pada Skenario 2 yang menggunakan klasifikasi biner (0 = Negatif dan 1 = Positif), terlihat bahwa dari total 528 data uji, model mampu mengklasifikasikan sebagian besar data dengan benar. Hasil confusion matrix ini sejalan dengan nilai akurasi sebesar 0,90 yang diperoleh pada Skenario 2. Dengan hanya dua kategori sentimen yang memiliki karakteristik lebih kontras, model dapat memisahkan kelas Negatif dan Positif secara lebih jelas dibandingkan skenario multi-kelas.

Secara umum, pada Skenario 2 menunjukkan bahwa model memiliki tingkat prediksi yang stabil dan tingkat kesalahan yang relatif rendah, sehingga dapat dikatakan bahwa performa klasifikasi biner pada penelitian ini tergolong sangat baik.

3.3.3 Skenario Klasifikasi 3 Positif vs non positif

Pada Skenario 3, proses klasifikasi dilakukan dengan pendekatan biner, yaitu membedakan antara teks Netral dan teks yang mengandung Sentimen (gabungan Positif dan Negatif). Dalam skenario ini, label 0 merepresentasikan sentimen Netral, sedangkan label 1 merepresentasikan Sentimen.

Accuracy SKENARIO 3: 0.9057507987220448

Classification Report:					
	precision	recall	f1-score	support	
0	0.91	0.95	0.93	424	
1	0.89	0.81	0.85	202	
accuracy			0.91	626	
macro avg	0.90	0.88	0.89	626	
weighted avg	0.91	0.91	0.90	626	

Gambar 18. Klasifikasi report 3

Temuan ini secara umum menunjukkan bahwa model tersebut berkinerja sangat baik dalam membedakan antara kedua kelas, dengan kelas 0 berkinerja sedikit lebih baik daripada kelas 1. Kuantitas data yang lebih besar di kelas 0, yang membuat model lebih andal dalam mengidentifikasi pola di kelas tersebut, mungkin merupakan alasan perbedaan ini.

Analisis Wordcloud Skenario 3 :

Pada Skenario 3, klasifikasi dilakukan dengan membedakan antara teks non positif (0) dan positif (1), di mana kelas Snon positif merupakan gabungan dari sentimen Netral dan Negatif. Pendekatan ini bertujuan untuk Pendekatan ini bertujuan untuk memudahkan

model dalam membedakan teks positif dan non positif, dengan menggabungkan netral dan negatif menjadi satu kelas. Dengan dua kelas saja, model lebih fokus mengenali teks yang benar-benar positif dibandingkan yang bukan positif.



Gambar 19. Word cloud Non positif

Sedangkan pada kelas non positif, terlihat kata-kata dominan seperti “gizi”, “makan”, “gratis”, “program”, serta kata-kata bernuansa evaluatif seperti “tidak”, “buat”, “kalau”, “racun”, dan “dukung”. Dominasi kata-kata utama tersebut menunjukkan bahwa pembahasan tetap berfokus pada inti program, yaitu penyediaan makanan bergizi gratis. Karena kelas ini merupakan gabungan dari sentimen Positif dan Negatif, maka muncul kombinasi kata yang mencerminkan dukungan maupun kritik secara bersamaan. Kata seperti “dukung” dan “baik” menunjukkan apresiasi terhadap program, sedangkan kata seperti “tidak” dan “racun” mencerminkan adanya kekhawatiran atau penolakan.

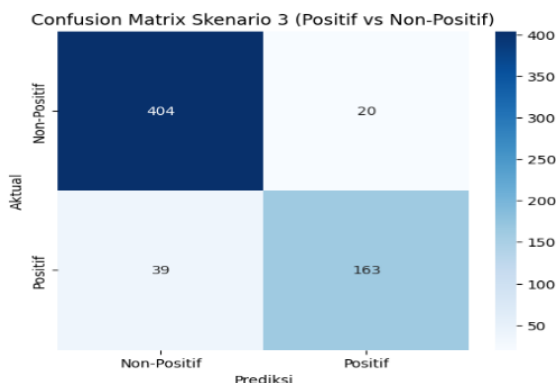


Gambar 20. Wordcloud Positif

Kondisi ini menyebabkan kelas Sentimen memiliki variasi kosakata yang lebih luas dan lebih emosional dibandingkan kelas Netral, karena memuat ekspresi sikap yang lebih tegas terhadap program. Sedangkan Pada kelas positif, kata-kata yang dominan antara lain “program”, “makan”, “gizi”, “gratis”, “mbg”, “sekolah”, dan “pemerintah”. Dominasi kata-kata tersebut menunjukkan bahwa pembahasan tetap berfokus pada inti program yang sedang dibicarakan. Ukuran kata yang besar dalam *wordcloud* menandakan tingginya frekuensi kemunculan dalam data.

Konten pada kelas Netral umumnya mengandung informasi yang bersifat deskriptif tanpa menunjukkan kecenderungan sikap tertentu dalam pelaksanaan program, lokasi kegiatan, instansi yang terlibat, maupun kebijakan yang diterapkan. Unggahan dalam kategori ini umumnya tidak menunjukkan ekspresi dukungan atau kritik yang kuat.

Analisis *Confusion Matrix* Skenario 3:



Gambar 21. *Confusion Matrix* Skenario 3

Berdasarkan *confusion matrix* pada Skenario 3 (Positif vs Non-Positif), model diuji dengan total 626 data yang terdiri dari kelas Non-Positif dan Positif. Hasil matriks menunjukkan distribusi prediksi model terhadap masing-masing kelas. Pada kelas Non-Positif (424 data), sebanyak 404 data berhasil diprediksi dengan benar sebagai Non-Positif, Sementara itu, pada kelas Positif (202 data), sebanyak 163 data teridentifikasi dengan tepat sebagai Positif, dan 39 data salah diklasifikasikan sebagai Non-Positif. Hal ini menunjukkan bahwa masih terdapat beberapa teks positif yang belum terdeteksi secara optimal oleh model. Jika dibandingkan antara kedua kelas, tingkat kesalahan lebih banyak terjadi pada kelas Positif (39 data) dibandingkan kelas Non-Positif (20 data). Namun secara keseluruhan, jumlah prediksi benar jauh lebih dominan, sehingga menghasilkan performa model yang baik.

Secara keseluruhan, confusion matrix pada Skenario 3 memperlihatkan bahwa model memiliki kemampuan yang lebih stabil dalam mengidentifikasi teks Non-Positif, serta cukup baik dalam mendeteksi teks Positif. Hal ini menunjukkan bahwa pemisahan kelas menjadi Positif dan Non-Positif membantu model dalam melakukan klasifikasi dengan tingkat ketepatan yang tinggi.

3.4 Perbandingan Kinerja Model

Untuk mempermudah analisis, hasil evaluasi model pada ketiga Skenario dirangkum pada tabel berikut:


Tabel 6. Perbandingan Kinerja Model

Skenario Klasifikasi	Akurasi	Precision	Recall	F1-Score
Positif vs Negatif vs Netral	0,8067	0,80	0,81	0,80
Positif vs Negatif	0,9034	0,90	0,90	0,90
Positif vs non positif	0,9057	0,90	0,91	0,90

Hasil pengujian menunjukkan bahwa performa model berbeda pada setiap skenario klasifikasi, di mana

skenario tiga kelas cukup baik namun terkendala oleh kelas netral yang cenderung ambigu, sedangkan skenario dua kelas dan positif vs non-positif memberikan hasil yang lebih baik karena jumlah kelas yang lebih sedikit membuat proses pemisahan lebih sederhana, jelas, dan meningkatkan akurasi serta stabilitas model.

Perbandingan akurasi Tiga Skenario



Gambar 22. Grafik Perbandingan Skenario

Perbedaan performa antar skenario klasifikasi dipengaruhi oleh kompleksitas jumlah kelas, di mana skenario dua kelas lebih sederhana karena hanya membedakan dua polaritas sehingga model lebih mudah menemukan batas pemisah yang optimal, sedangkan skenario tiga kelas lebih kompleks akibat adanya kemiripan fitur, terutama pada kelas netral, yang dapat meningkatkan kesalahan prediksi dan menurunkan akurasi, sehingga semakin sedikit jumlah kelas maka performa model cenderung lebih optimal.

4. Kesimpulan

Berdasarkan hasil penelitian, metode *Support Vector Machine* (SVM) dengan pembobotan *Term Frequency-Inverse Document Frequency* (TF-IDF) efektif digunakan untuk analisis sentimen opini masyarakat pada Platform X terkait Program Makanan Bergizi Gratis. Dari 4.002 data awal hasil crawling, setelah melalui tahap *preprocessing* dan pelabelan manual diperoleh 3.129 data yang digunakan dalam klasifikasi, terdiri dari 1.573 sentimen negatif, 1.065 positif, dan 491 netral. Distribusi ini menunjukkan dominasi sentimen negatif dalam pembahasan topik penelitian. Pengujian dilakukan menggunakan tiga

skenario klasifikasi, di mana skenario tiga kelas menghasilkan akurasi 80,67%, skenario dua kelas (positif vs negatif) mencapai 90,34%, dan skenario positif vs non-positif memperoleh akurasi tertinggi sebesar 90,57%. Hasil ini menunjukkan bahwa klasifikasi dengan jumlah kelas yang lebih sedikit memberikan performa yang lebih baik. Secara keseluruhan, metode SVM dengan TF-IDF terbukti efektif, dengan kinerja model yang dipengaruhi oleh skenario klasifikasi yang digunakan.

Daftar Rujukan

- [1] R. Wati and S. Ernawati, "Analisis sentimen persepsi publik mengenai PPKM pada Twitter berbasis support vector machine menggunakan Python," *Jurnal Teknik Informatika Universitas Katolik Santo Thomas*, 2021.
- [2] D. Darwis and E. S. Pratiwi, "Penerapan algoritma support vector machine untuk analisis sentimen pada data Twitter Komisi Pemberantasan Korupsi Republik Indonesia," *Jurnal Ilmiah Edutic*, 2022.
- [3] S. Styawati and N. Handrastuty, "Analisis sentimen masyarakat terhadap program kartu prakerja pada Twitter dengan metode support vector machine," *Jurnal Informatika*, 2021.
- [4] T. M. P. Aulia, N. Arifin, and R. Mayasari, "Perbandingan kernel support vector machine (SVM) dalam penerapan analisis sentimen vaksinasi Covid-19," *SINTECH (Science and Information Technology Journal)*, 2021.
- [5] I. S. K. Idris, Y. A. Mustofa, and J. A. Salihi, "Analisis sentimen terhadap penggunaan aplikasi Shopee menggunakan algoritma support vector machine (SVM)," *Jurnal Ilmiah Komputer dan Informatika (KOMPUTA)*, vol. 2, no. 1, pp. 55–60, 2023.
- [6] I. S. Aisah, B. Irawan, and T. Suprpti, "Algoritma support vector machine (SVM) untuk analisis sentimen ulasan aplikasi Al-Qur'an digital," *Jurnal Mahasiswa Teknik Informatika*, 2023.
- [7] F. D. Ananda and Y. Pristyanto, "Analisis sentimen pengguna Twitter terhadap layanan internet provider menggunakan algoritma support vector machine," *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 2021.
- [8] H. C. Husada and A. Suryaputra, "Analisis sentimen pada maskapai penerbangan di platform Twitter menggunakan algoritma support vector machine (SVM)," *Jurnal Teknik Informatika – TEKNIKA*, 2023.
- [9] T. Tinilah and T. Elizabeth, "Analisis sentimen ulasan aplikasi PrimaKu menggunakan metode support vector machine," *Jurnal Teknik Informatika dan Sistem Informasi*, 2022.
- [10] W. E. Saputro, H. Yuana, and W. D. Puspitasari, "Analisis Sentimen Pengguna Dompot Digital Dana Pada Kolom Komentar Google Play Store Dengan Metode Klasifikasi Support Vector Machine," vol. 7, no. 2, pp. 1151–1156, 2023.