

# ANALISIS PROGRAM MAKAN BERGIZI GRATIS DENGAN SUPPORT VECTOR MACHINE (SVM) PADA APLIKASI X

Sekar Cinta Amaria<sup>1</sup>, Nurtriana Hidayati<sup>2</sup>

<sup>1,2</sup> Jurusan Teknologi Informasi Fakultas Teknologi Informasi dan Komunikasi Universitas Semarang  
Jln. Soekarno-Hatta RT7/RW7 – Kota Semarang

<sup>1</sup>G111220085@student.usm.ac.id

<sup>2</sup>anna@usm.ac.id

## Abstract

The Free Nutritious Meal Program (MBG), which represents a priority program of President Prabowo Subianto, has garnered widespread attention from Indonesian society. This program has received sympathy from various groups, including students and informal workers, and has been extensively discussed through social media, particularly on platform X. This research aims to analyze public response in the form of positive and negative sentiment toward the MBG Program based on data from platform X. A total of 1,378 tweets were collected using crawling methods, followed by preprocessing, sentiment labeling using the InSet lexicon dictionary, and feature extraction using three techniques: Term Presence, Bag of Words (BoW), and Term Frequency-Inverse Document Frequency (TF-IDF). Subsequently, sentiment classification was performed using the Support Vector Machine (SVM) algorithm for each feature extraction technique. Classification results demonstrate that the TF-IDF technique achieved the highest accuracy of 77.5%, compared to Term Presence (76.2%) and BoW (75.3%). Validation using K-Fold Cross Validation with five iterations was conducted with imbalanced data handling through the Synthetic Minority Over-sampling Technique (SMOTE) method. In this validation, TF-IDF consistently demonstrated superior performance with an average accuracy of 75.54%, precision of 74.31%, recall of 73.86%, and f1-score of 73.98%. Despite a slight decrease in accuracy following data synthesis, the TF-IDF technique proved to be stable and effective in handling data variation. The superiority of the TF-IDF feature extraction technique is suitable for combination with the SVM algorithm.

**Keywords:** Free Nutritious Meal Program, SVM algorithm, TF-IDF, Platform X, SMOTE Method

## I. PENDAHULUAN

Program Makan Bergizi Gratis (MBG) merupakan salah satu program prioritas nasional yang diluncurkan oleh Presiden Prabowo Subianto [1]. Program ini resmi dimulai pada 6 Januari 2025 yang diimplementasikan mencakup seluruh jenjang pendidikan, dari tingkat Paud hingga SMA/sederajat di berbagai kabupaten/kota seluruh Indonesia. Program ini bertujuan menyediakan asupan gizi seimbang berupa makanan bergizi dan susu bagi peserta didik, serta nutrisi tambahan bagi ibu hamil dan balita, sebagai upaya strategis untuk mendukung perkembangan kognitif anak, menurunkan prevalensi stunting, dan meningkatkan partisipasi pendidikan [2]. Mengacu pada data BPS tahun 2024, sebanyak 8,53 persen anak di Indonesia masih mengalami kekurangan asupan gizi. Sehingga adanya program ini diharapkan dapat menjadi solusi permasalahan tersebut. Di kutip dari laman Tempo.co, hingga bulan Maret, jumlah penerima manfaat Program Makan Bergizi Gratis baru mencapai sekitar 2,05 juta orang, sedangkan target yang ditetapkan yaitu 82,9 juta penerima.

Dalam pelaksanaan Program MBG, pemerintah juga berkolaborasi dengan lintas sektor yaitu Kementerian PANRB, Badan Gizi Nasional (BGN), Kementerian Pendidikan Dasar dan Menengah (Kemendikdasmen), Kementerian Koordinator Bidang Pangan (Kemenko Pangan), serta Kementerian Kependudukan dan Pembangunan Keluarga/Badan Kependudukan dan Keluarga Berencana Nasional (BKKBN), guna menjamin efektivitas program.

Seiring peluncuran Program MBG, platform media sosial seperti X menjadi arena utama bagi masyarakat untuk menyuarakan pendapatnya [3]. Perdebatan di media sosial ini memperlihatkan dinamika opini publik yang kompleks, di mana informasi positif dan kritik tajam saling beriringan yang mana menjadi barometer sentimen publik [4][5]. Kekhawatiran juga muncul terkait pelaksanaan program, terutama terhadap kemungkinan terjadinya penyimpangan anggaran dan tindakan korupsi [6].

Hal tersebut memunculkan respon masyarakat yang beragam melalui komentar atau ulasan yang muncul pada platform X. Dinamika ini mencerminkan bagaimana media sosial telah berkembang menjadi ruang diskusi publik yang aktif, di mana masyarakat mengekspresikan pandangannya terhadap berbagai kebijakan, termasuk isu-isu sosial-politik seperti program pemerintah, sistem hukum, dan kebijakan publik lainnya [7]. Berdasarkan komentar tersebut dapat dilakukan analisis sentimen dengan pendekatan pengolahan *Natural Language Processing* (NLP). NLP merupakan cabang dari kecerdasan buatan/*Artificial Intelligent* (AI) yang berfokus pada interaksi antara komputer dan bahasa manusia [8]. NLP dapat dimanfaatkan untuk mengenali dan mengklasifikasikan sentimen dalam teks, seperti komentar, ke dalam kategori positif, negatif, maupun netral [9]. Kemudian kita dapat mengklasifikasikan komentar tersebut bernilai positif atau negatif melalui algoritma *machine learning*, seperti algoritma *Support Vector Machine* (SVM). Algoritma SVM adalah merupakan algoritma *machine learning* yang dapat

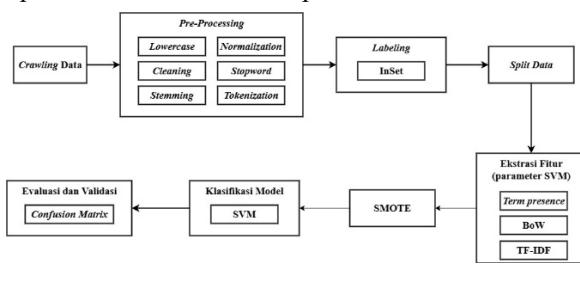
dimanfaatkan untuk melakukan tugas klasifikasi maupun regresi serta dapat membentuk sebuah model pemisah dua kelas data dengan menentukan *hyperplane* optimal dari masing-masing kelas dalam analisa sentimen publik pada X [10].

Dalam riset "Analisis Sentimen Wacana Pemindahan Ibu Kota Indonesia Menggunakan Algoritma *Support Vector Machine* (SVM)", pada 1.236 data tweet menunjukkan bahwa model SVM memberikan mencapai akurasi (96,68%), dengan negatif sebesar 832, dan positif 404 [11], dan pada riset yang berjudul "Analisis Sentimen Tanggapan Di Twitter Terkait Program Kerja Makan Siang Gratis Prabowo-Gibran Menggunakan *Algoritma Naïve Bayes Classifier* dan *Support Vector Machine*", dilakukan analisis terhadap 1.028 tweet yang menunjukkan bahwa sentimen negatif mendominasi dengan persentase 44,84%, sentimen positif sebesar 32,39%, dan netral sebesar 22,76%, serta menghasilkan akurasi sebesar 75,39%, lebih tinggi dibandingkan algoritma NBC yang memperoleh akurasi 68,97% [10], serta riset yang berjudul "Analisis Sentimen Untuk Memprediksi Hasil Calon Pemilu Presiden Menggunakan Lexicon Based dan Random Forest", dengan menggunakan metode Lexicon Based dan Random Forest menghasilkan tingkat sentimen negatif sebesar 48%, sentimen positif sebesar 96%, dan sentimen netral sebesar 97%, dengan akurasi total model mencapai 88% [12].

Berdasarkan permasalahan diatas, maka dalam riset ini bertujuan untuk menganalisis komentar mengenai Program MBG pada platform X dengan menerapkan algoritma SVM. Penggunaan algoritma *Support Vector Machine* (SVM) telah menunjukkan kinerja yang cukup baik dalam tugas klasifikasi sentimen, dengan tingkat akurasi yang optimal. Oleh karena itu, riset ini bertujuan untuk memodifikasi pendekatan yang telah dikembangkan sebelumnya dengan menerapkan metode SVM dalam mengevaluasi performa leksikon serta teknik ekstraksi fitur. Analisis sentimen dilakukan melalui pembelajaran supervisi yang mengintegrasikan pendekatan berbasis leksikon guna meningkatkan akurasi dan efektivitas klasifikasi.

## II. METODOLOGI PENELITIAN

Riset ini menerapkan pendekatan hibrida dengan mengintegrasikan metode pembelajaran supervisi dan pendekatan berbasis leksikon. Pendekatan pembelajaran supervisi menggunakan algoritma SVM yang dilatih menggunakan dataset berlabel, sedangkan pendekatan berbasis leksikon memanfaatkan kamus sentimen [13]. Dalam melakukan pengolahan data menggunakan Google Colab sebagai *tools* utama. Riset ini meliputi beberapa tahapan yang diperlukan untuk mendapatkan hasil klasifikasi yang ditampilkan secara keseluruhan pada Gambar 1.



Gambar 1. Tahapan Riset

### A. Crawling Data

Pengumpulan data menggunakan teknik *crawling* pada platform X.com, yaitu mengumpulkan data dengan mengekstrak data secara otomatis melalui bantuan API X menggunakan *script tweet-harvest* oleh Helmi Satria [14]. Data dikumpulkan melalui dua metode *crawling*, sebagaimana ditampilkan pada Tabel 1. Metode pertama menggunakan pencarian kata kunci "program mbg", "makan bergizi gratis", dan "mbg" dalam periode 1 Januari - 30 Mei 2025, menghasilkan 1.044 thread. Metode kedua memperoleh sebanyak 334 komentar dengan melakukan ekstraksi komentar dari *thread* akun @prabowo pada tanggal 12 Februari 2025.



Gambar 2. Postingan Thread akun @prabowo

Postingan *Thread* tersebut dipilih karena memperoleh interaksi yang tinggi, khususnya dalam bentuk komentar yang mencerminkan berbagai respons masyarakat terhadap program MBG. Banyak komentar dalam thread tersebut menjadikannya sumber data akan opini publik, baik yang bersifat mendukung, netral, maupun kritis. Oleh karena itu, komentar dari unggahan ini dipilih sebagai data tambahan untuk memperkuat representasi sentimen masyarakat secara aktual dan kontekstual terhadap kebijakan yang sedang dibahas. Tabel 1 menyajikan data hasil crawling dari sumber yang telah ditentukan.

Tabel 1. Hasil Crawling Data

...	created_at	favorite_count	full_text	...	username
...	Wed Jan 01 17:15:42	169	Makan Siang Bergizi Gratis klo berhasil keren...	...	
...	Fri Jan 03 12:39:50	151	Konsesi tambang - jasa program MBG otaknya bisnis dan bisnis terus kawan ini.. https://t.co/YLtzib v24	...	BosPurwa
...	...	...	...	...	...

### B. Preprocessing

*Preprocessing* merupakan tahapan awal pengolahan data yang bertujuan untuk membersihkan, mengubah, dan mempersiapkan data mentah agar siap untuk dianalisis atau diproses lebih lanjut [15]. Dataset dalam riset ini awalnya terdiri dari 1.378 baris, namun setelah melalui tahap *preprocessing*, jumlah data menjadi 1.151 baris.

*Preprocessing* difokuskan pada kolom *fulltext*, yang berisi teks asli dari tweet maupun komentar.

Dalam riset ini, *preprocessing* dilakukan melalui beberapa langkah berurutan, yaitu *lowercase*, *normalization*, *cleaning*, *stopwords removal*, *stemming*, dan *tokenization*. Tahapan *preprocessing* yang dilakukan adalah sebagai berikut:

1) *Lowercase*: Tahap *lowercase* bertujuan mengubah seluruh karakter huruf dalam teks menjadi huruf kecil untuk menyeragamkan format penulisan [16]. Proses ini menggunakan fungsi *.lower()* yang merupakan fungsi bawaan Python.

Tabel 2. Hasil Preprocessing Lowercase

No	Full_text	lowercase
1.	Makan Siang Bergizi Gratis klo berhasil keren...	makan siang bergizi gratis klo berhasil keren...
2.	Konsesi tambang - jasa program MBG otaknya...	konsesi tambang - jasa program mba otaknya...
...	...	...

2) *Normalization*: Proses untuk memperbaiki kata tidak baku dengan membuat kamus kata tidak baku secara manual.

Tabel 3. Hasil Preprocessing Normalization

No	lowercase	normalization
1.	makan siang bergizi gratis klo berhasil keren...	makan siang bergizi gratis klo berhasil keren...
2.	konsesi tambang - jasa program mba otaknya...	konsesi tambang - jasa program makan bergizi gratis otaknya...
...	...	...

3) *Cleaning*: Membersihkan teks dari berbagai elemen yang tidak diperlukan, seperti *mention* (@username), hashtag (#hashtag), kata "RT" penanda retweet, URL/link, karakter khusus, mengubah multiple spasi menjadi single spasi dan menghapus line break serta meghapus baris data yang kosong maupun duplikasi data [17]. Proses ini menggunakan modul operasi *Regular Expression* (RegEx) dari Python.

Tabel 4. Hasil Preprocessing Cleaning

No	normalization	cleaning
1.	makan siang bergizi gratis klo berhasil keren...	makan siang bergizi gratis klo berhasil keren...
2.	konsesi tambang - jasa program makan bergizi gratis otaknya...	konsesi tambang jasa program makan bergizi gratis otaknya...
...	...	...

4) *Stopwords Removal*: Menghapus kata yang tidak informatif dan tidak memiliki makna pada dokumen, seperti "yang", "dan", "untuk", dan sebagainya menggunakan kamus ID-Stopwords [17].

Tabel 5. Hasil Preprocessing Stopwords Removal

No	cleaning	no_stopwords
1.	makan siang bergizi gratis kalo berhasil keren...	makan siang bergizi gratis kalo berhasil keren...
2.	konsesi tambang jasa program makan bergizi gratis otaknya...	konsesi tambang jasa program makan bergizi gratis otaknya...
...	...	...

5) *Stemming*: Proses ini mengkonversi kata-kata dalam tweet menjadi bentuk dasar menggunakan *library Sastrawi* yang cocok untuk teks berbahasa Indonesia [18].

Tabel 6. Hasil Preprocessing Stemming

No	no_stopwords	stemming
1.	makan siang bergizi gratis kalo berhasil keren...	makan siang gizi gratis kalo hasil keren...
2.	konsesi tambang jasa program makan bergizi gratis otaknya...	konsesi tambang jasa program makan gizi gratis otak...
...	...	...

6) *Tokenization*: Proses *tokenization* yaitu mengonversi teks tweet menjadi kumpulan token (kata) individual untuk memudahkan pemrosesan selanjutnya dengan menggunakan modul *nltk.tokenize*.

Tabel 7. Hasil Preprocessing Tokenization

No	stemming	tokenization
1.	makan siang gizi gratis kalo hasil keren...	["makan", "siang", "gizi", "gratis", "kalo", "hasil", "keren"]
2.	konsesi tambang jasa program makan gizi gratis otak...	["konsesi", "tambang", "jasa", "program", "makan", "gizi", "gratis", "otak"]
...	...	...

### C. Labelling

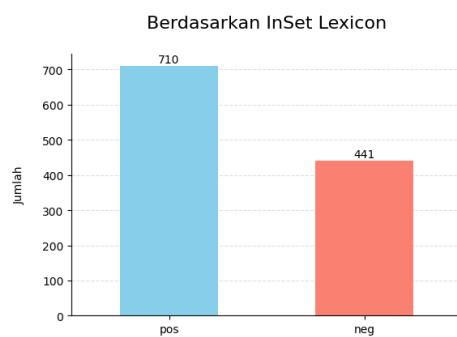
*Labelling* dilakukan otomatis dengan menggunakan kamus InSet (*Indonesia Sentiment Lexicon*) merupakan kamus yang memuat bahasa Indonesia berbasis pendekatan leksikon [19]. Setiap kata akan diberikan nilai berdasarkan polaritasnya untuk mengukur respons masyarakat terhadap suatu topik [14]. InSet

mencakup 3.609 kata dengan polaritas positif dan 6.609 kata dengan polaritas negatif, masing-masing memiliki rentang skor antara -5 hingga +5 [19]. Analisis sentimen berbasis leksikon pada riset ini menghasilkan label sentimen yang dikategorikan sebagai positif, dan negatif.

Setelah dilakukan *preprocessing*, menghasilkan data yang berjumlah 1.151 baris. Dalam proses ini berdasarkan kamus *InSet Lexicon*, menggunakan modul *nltk.sentiment.vader* dengan class *SentimentIntensityAnalyzer*.

Tabel 8. Sampel Labeling Dataset

No	Text	Label
1.	['makan', 'siang', 'gizi', 'gratis', 'kalo', 'hasil', 'keren', 'tuh', 'hidup', 'orang', 'nelayan', 'tani', 'ternak', 'tukang', 'masak', 'pokok', 'brhubungan', 'buocor', 'aje', 'awas', 'ati', 'ati', 'awas', 'molotot', 'nih', 'molotot', 'kalo', 'kalo', 'ya', 'main', 'gaplok']	pos
2.	['konsesi', 'tambang', 'jasa', 'program', 'makan', 'gizi', 'gratis', 'otak', 'bisnis', 'bisnis', 'kawan']	pos
...	...	...



Gambar 3. Grafik Perbandingan Label Positif dan Label Negatif

Berdasarkan grafik yang ditampilkan pada Gambar 3, terlihat bahwa jumlah teks dengan label positif mencapai 710 label, sedangkan teks dengan label negatif sebanyak 441 label. Hasil ini menunjukkan distribusi sentimen pada data.

#### D. Split Data

Pembagian data dilakukan dengan menggunakan teknik *stratified split*. Proses pembagian data menggunakan *library train-test split* dengan rasio 80% untuk data pelatihan dan 20% untuk data pengujian. Implementasi pembagian ini menghasilkan 920 sampel data yang digunakan dalam tahap *training* model dan 231 sampel data untuk tahap *testing* guna mengevaluasi kinerja model yang telah dilatih. Distribusi hasil *splitting* data dapat dilihat pada Tabel 9 berikut ini.

Tabel 9. Sampel Split Data

Sampel Data Latih		
Index	Text	Label
100	anak indonesia hak makan sehat tingkat cerdas otak suasana program makan ...	pos
662	efisiensi program megaprojek modal ngutang ambisi ikn amp kcic kabinet gemuk 2x ...	neg

Sampel Data Uji		
Index	Text	Label
887	menteri ppn makan gizi gratis desak ketimbang rakyat lapang kerja	pos

681 orang tua kasih makan anak miskin sekolah anak makan gratis usaha ... neg

#### E. Ekstraksi Fitur

Setelah proses *labelling* selesai, tahap berikutnya adalah **ekstraksi fitur**, di mana setiap baris data dikonversi menjadi vektor agar dapat diklasifikasikan oleh model. Konversi ini dilakukan dengan memberikan bobot pada setiap fitur melalui proses **pembobotan fitur**, sehingga karakteristik teks dapat direpresentasikan secara numerik untuk analisis lebih lanjut [18]. Pada riset ini akan menggunakan tiga teknik ekstraksi fitur yaitu *Term Presence*, *TF-IDF*, dan *Bag of Words*.

*Term Presence* (TP) adalah teknik yang mengelompokkan dokumen teks berdasarkan keberadaan kata atau fitur dalam suatu korpus, tanpa memperhitungkan jumlah kemunculannya. Sebaliknya, jika fitur tersebut tidak terhitung [20]. Sedangkan, teknik *TF-IDF* menghitung frekuensi kemunculan suatu kata dalam sebuah dokumen lalu membandingkannya dengan kemunculannya di seluruh dokumen yang tersedia. Semakin sering kata muncul dalam dokumen tertentu, semakin tinggi bobotnya dalam analisis teks [14]. Dan teknik *Bag of Words* (BoW) mengabaikan tata bahasa, sintaksis, dan urutan kata, tetapi mempertimbangkan frekuensi kemunculan kata dalam dokumen [21]. Pemilihan ketiganya didasarkan pada kekuatan representasi masing-masing dalam mengonversi data teks menjadi bentuk numerik yang dapat diolah oleh model klasifikasi seperti model SVM. Komparatif ini digunakan untuk mengetahui metode mana yang paling optimal dalam menangkap karakteristik sentimen.

#### F. Klasifikasi Model

Setelah diperoleh nilai pembobotan dari hasil *labeling* melalui tahap ekstraksi fitur sebagai parameter klasifikasi, langkah selanjutnya yaitu melakukan klasifikasi menggunakan metode *Support Vector Machine* (SVM). Proses klasifikasi SVM memerlukan nilai bobot untuk setiap kata dalam dataset pelatihan, dan klasifikasi dilaksanakan menggunakan skenario pemodelan dengan *Linear Kernel* SVM [22]. Dalam riset ini, klasifikasi sentimen dilakukan dengan memanfaatkan fungsi *Support Vector Classifier* (SVC) yang tersedia dalam *library scikit-learn* (*sklearn*) pada Python. SVM dapat digunakan untuk mengklasifikasikan ulasan atau teks ke dalam kategori sentimen positif atau negatif. Dengan belajar dari data pelatihan berlabel, SVM dapat memahami pola pada model [23]. Parameter yang relevan, seperti jenis *Linear Kernel* yang digunakan, telah disesuaikan dengan kebutuhan dan karakteristik data riset. Penggunaan *Linear Kernel* berada dalam dimensi tinggi dan sparse yang memisahkan dua kelas secara linier dalam ruang fitur berdimensi tinggi [24]. Persamaan (1) menunjukkan rumusan dari Kernel Linear [24].

$$K(x_i, x_j) = x_i^T \cdot x_j \quad (1)$$

#### G. Evaluasi Model

Terakhir menguji performa dari algoritma SVM sebagai klasifikasi model pada riset ini. Tahap pertama menggunakan metode *Confusion Matrix* dengan pendekatan *single train-test split* untuk menghasilkan nilai akurasi, *precision*, *recall*, dan *F1-Score* berdasarkan perbandingan antara hasil prediksi dan

data aktual dari model yang dilatih [22]. Implementasi pengujian akan dilakukan dengan membandingkan tiga metode ekstraksi fitur yang berbeda, yaitu *Term Presence*, *Bag of Words*, dan TF-IDF. Proses evaluasi dimulai dengan encoding label kategorikal menjadi format numerik menggunakan *LabelEncoder* untuk memastikan konsistensi dalam proses klasifikasi. *Confusion Matrix* yang menampilkan distribusi hasil klasifikasi dalam bentuk *true positive*, *true negative*, *false positive*, dan *false negative* [25].

Tabel 10. Confusion Matrix

		Prediksi	
		Prediksi Benar	Prediksi Salah
Aktual	Aktual Benar	TP (True Positive)	FN (False Negative)
	Aktual Salah	FP (False Positive)	TN (True Negative)

Dengan persamaan *Accuracy* (2), *Precision* (3), *Recall* (4), dan *F1-Score* (5) berikut.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2)$$

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (4)$$

$$\text{F1 - Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \times 100\% \quad (5)$$

Tahap kedua, evaluasi lanjutan model yang lebih robust dalam mengatasi permasalahan *class imbalance*, riset ini menerapkan teknik *Synthetic Minority Oversampling Technique* (SMOTE) yang dikombinasikan dengan validasi *K-Fold Cross Validation* sebanyak 5 iterasi.

Teknik *Synthetic Minority Oversampling Technique* (SMOTE) merupakan metode yang digunakan untuk mengatasi masalah ketidakseimbangan (*imbalance*) kelas dalam dataset dengan menciptakan sampel sintetis dari kelas minoritas, yang tidak hanya menambah jumlah data, tetapi juga memperkaya variasi representasi untuk meningkatkan kualitas pembelajaran model [26]. *K-Fold Cross Validation* adalah metode validasi yang membagi dataset secara acak menjadi *K* partisi. Setiap partisi bergiliran digunakan sebagai data uji, sementara sisanya sebagai data latih, dan proses ini diulang sebanyak *K* kali [27]. Pada riset ini, menggunakan skema *5-Fold Cross Validation*, jadi dataset dibagi menjadi 5 bagian, dan proses pelatihan serta pengujian dilakukan sebanyak 5 iterasi. SMOTE diterapkan hanya pada data latih di setiap iterasi, untuk memastikan tidak terjadi data *leakage* ke data uji.

### III. HASIL DAN PEMBAHASAN

Pada riset ini, proses *crawling* data menghasilkan sebanyak 1.378 data. Selanjutnya dilakukan *preprocessing* sehingga tersisa 1.151 baris data yang layak digunakan. Setelah itu, dilakukan proses *labelling* yang menghasilkan 710 data berlabel positif dan 441 data berlabel negatif. Dataset tersebut kemudian dibagi menjadi data latih dan data uji dengan proporsi 80:20, sehingga diperoleh 920 sampel untuk data latih dan 231 sampel untuk data uji.

#### A. Ekstraksi Fitur

Setelah dilakukan *split* data dengan proporsi 80:20 antara data latih berjumlah 920 sampel dan data uji berjumlah 231 sampel, tahap berikutnya adalah ekstraksi fitur, yang dilakukan menggunakan modul *CountVectorizer* dan *TfidfVectorizer* dari *scikit-learn* [19].

Penggunaan tiga teknik ekstraksi fitur bertujuan untuk mengeksplorasi serta membandingkan berbagai kombinasi metode ekstraksi fitur guna memperoleh pendekatan yang menghasilkan tingkat akurasi terbaik dalam klasifikasi sentimen. Hasil dari setiap metode ekstraksi fitur digunakan dalam proses pengklasifikasian, dan perhitungan dari masing-masing teknik disajikan pada Tabel 10 berikut.

Tabel 11. Sampel Nilai Fitur dari Setiap Teknik Ekstraksi

Sampel	ana k	indonesia	maka n	progra m	...
<i>Term Presence</i>					
S1	1	1	1	1	...
S2	1	0	1	0	...
S3	1	0	1	0	...
S4	0	0	1	0	...
...	...	...	...	...	...
<i>Bag of Words</i>					
S1	1	1	2	1	...
S2	1	0	5	0	...
S3	1	0	1	0	...
S4	0	0	1	0	...
...	...	...	...	...	...
<i>TF-IDF</i>					
S1	0.19 1	0.202	0.144	0.124	...
S2	0.11 3	0	0.212	0	...
S3	0.18 3	0	0.070	0	...
S4	0	0	0.039	0	...
...	...	...	...	...	...

Proses ekstraksi fitur menghasilkan 3.595 fitur kata unik (*unique features*) dari seluruh *tweet* pada data latih dan data uji.

#### B. Klasifikasi Model

Tahap selanjutnya adalah membangun model klasifikasi untuk mengelompokkan sentimen ke dalam kategori positif, dan negatif. Dalam klasifikasi penulis menggunakan algoritma

SVM yang memiliki kemampuan baik dalam menangani data hasil ekstraksi fitur. Implementasi model menggunakan *library sklearn.metrics* dengan fungsi *accuracy\_score*. Proses pelatihan model dilakukan menggunakan data latih yang telah melalui proses ekstraksi fitur, baik dari teknik *Term Presence*, *Bag of Words* (BoW) maupun TF-IDF. Hasil prediksi dari klasifikasi sentimen menggunakan model SVM disajikan pada Tabel 12. Parameter regularisasi pada classifier tidak diatur secara khusus, melainkan dibiarkan menggunakan nilai default yaitu C = 1.0.

Tabel 12. Sampel Hasil Prediksi Klasifikasi

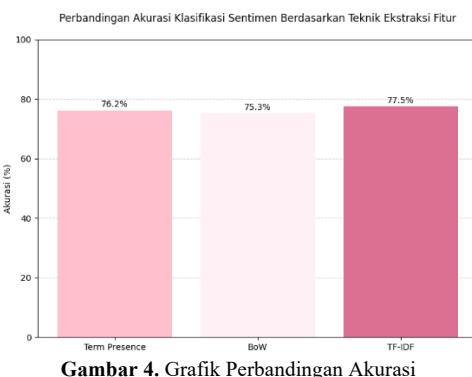
Ekstraksi Fitur	Indeks Data Uji								
	17	76	47	24	68	21	88	42	...
Term Presence	4	8	0	0	1	8	3	2	
BoW	1	1	1	1	0	0	0	0	...
TF-IDF	1	1	1	1	0	0	0	0	...

Sementara itu, Tabel 13 berikut menyajikan perbandingan skor akurasi klasifikasi sentimen berdasarkan masing-masing teknik ekstraksi fitur.

Tabel 13. Perbandingan Skor Klasifikasi Sentimen

Ekstraksi Fitur	Akurasi (%)
Term Presence	76.2%
BoW	75.3%
TF-IDF	77.5%

Dari Tabel 13, hasil akurasi klasifikasi sentimen menggunakan SVM dari masing-masing ekstraksi fitur menunjukkan bahwa menggabungkan dengan teknik TF-IDF memiliki skor akurasi tertinggi sebesar 77.5%. Teknik *Term Presence* menghasilkan akurasi sebesar 76,2%, dan teknik BoW menghasilkan akurasi sedikit lebih rendah sebesar 75.3%. Berikut gambaran grafik perbandingan skor akurasi klasifikasi sentimen yang disajikan pada Gambar 4.

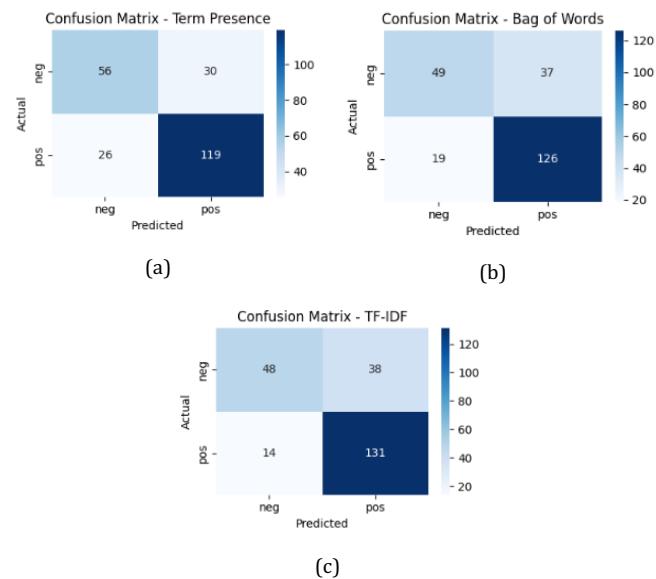


Gambar 4. Grafik Perbandingan Akurasi

### C. Evaluasi Model

Setelah melakukan klasifikasi sentimen menggunakan algoritma SVM, langkah selanjutnya adalah melakukan evaluasi kinerja model dengan menggunakan metode *confusion matrix* dengan pendekatan *single train-test split* berdasarkan masing-masing teknik ekstraksi fitur. Gambar 5 di bawah ini menyajikan visualisasi *confusion matrix* dari hasil klasifikasi yang menunjukkan jumlah prediksi benar (*true positive* dan

*true negative*) serta prediksi salah (*false positive* dan *false negative*).

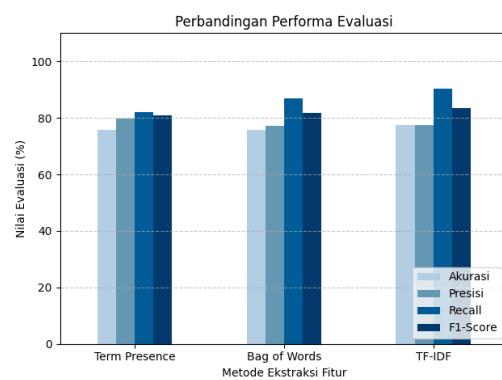


Gambar 5. Visualisasi *Confusion Matrix*  
(a) Term Presence, (b) BoW, (c) TF-IDF

Selanjutnya, dilakukan perhitungan metrik evaluasi berupa *Accuracy*, *Precision*, *Recall*, dan *F1-Score* dengan menggunakan modul *classification\_report*. Nilai-nilai tersebut dirangkum dalam Tabel 14 berikut.

Tabel 14. Hasil Perhitungan *classification report*

Ekstraksi Fitur	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Term Presence	75.76%	79.87%	82.07%	80.95%
BoW	75.76%	77.30%	86.90%	81.82%
TF-IDF	77.49%	77.51%	90.34%	83.44%



Gambar 6. Perbandingan Performa Evaluasi *Confusion Matrix*

Berdasarkan hasil evaluasi, dapat disimpulkan bahwa metode TF-IDF menghasilkan performa terbaik dalam klasifikasi sentimen dibandingkan dengan dua metode ekstraksi fitur lainnya. Hal ini terlihat dari nilai *Accuracy*, *Recall*, dan *F1-Score* yang lebih tinggi. Pada tahap evaluasi model selanjutnya, akan dilakukan proses sintesis dan analisis kesalahan klasifikasi, untuk mengidentifikasi potensi *false positive* dan *false negative* yang mungkin disebabkan oleh ketidakseimbangan kelas (*class imbalance*) pada data teks hasil *preprocessing*.

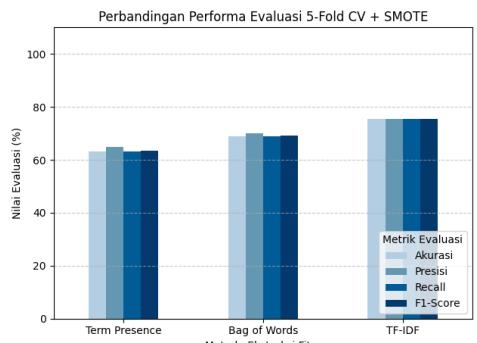
Selanjutnya, melakukan evaluasi lanjutan menggunakan metode *5-Fold Cross Validation* untuk memperoleh hasil evaluasi yang lebih akurat dan stabil. Teknik ini dibangun menggunakan fungsi *StratifiedKFold* dari *library scikit-learn*. Dengan membagi data latih menjadi 5 bagian, di mana setiap bagian secara bergiliran digunakan sebagai data uji, sementara 4 bagian lainnya sebagai data latih.

Evaluasi ini diterapkan pada data latih dari pengujian awal yang berjumlah 1.378 data, dengan skema pembagian 80% untuk pelatihan dan 20% untuk pengujian pada setiap iterasi. Namun, dataset sebelumnya menunjukkan ketidakseimbangan kelas (*class imbalance*), model cenderung bias terhadap kelas mayoritas. Untuk mengatasi masalah tersebut, diterapkan teknik *oversampling* menggunakan pendekatan SVM-SMOTE yang diimplementasikan melalui *library imbalanced-learn*. SVM-SMOTE menghasilkan data sintetis pada area perbatasan antar kelas, sehingga meningkatkan sensitivitas model terhadap kelas minoritas dan memperbaiki performa klasifikasi secara keseluruhan.

Tabel 15. Rata-Rata Nilai Performa Evaluasi 5-Fold CV

Ekstraksi Fitur	Rata-Rata Nilai Performa			
	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Term Presence	63.04%	64.93%	63.04%	63.49%
BoW	68.91%	70.15%	68.91%	69.20%
TF-IDF	75.54%	75.49%	75.54%	75.42%

Berdasarkan Tabel 15, hasil evaluasi model klasifikasi menggunakan pendekatan *5-Fold CV* menunjukkan bahwa metode ekstraksi fitur TF-IDF memberikan performa terbaik dibandingkan dengan metode lainnya. Rata-rata nilai akurasi yang diperoleh dengan TF-IDF mencapai 75,54%, diikuti oleh BoW sebesar 68,91%, dan *Term Presence* sebesar 63,04%.



Gambar 7. Perbandingan Performa Evaluasi SMOTE + 5-Fold CV

Gambar 7 menyajikan perbandingan dari hasil evaluasi performa model klasifikasi SVM menggunakan teknik *5-Fold CV* yang dikombinasikan dengan SMOTE. Metode TF-IDF menghasilkan performa terbaik di antara ketiganya. Seluruh metrik evaluasi mencapai nilai sekitar 75%, menunjukkan bahwa pemberian bobot berdasarkan frekuensi kata relatif terhadap seluruh dokumen memberikan informasi yang lebih representatif dan diskriminatif bagi model.

#### D. Perbandingan Akurasi Evaluasi

Setelah dilakukan evaluasi model menggunakan dua pendekatan berbeda, yaitu metode evaluasi awal melalui *confusion matrix* dan evaluasi lanjutan menggunakan *5-Fold*

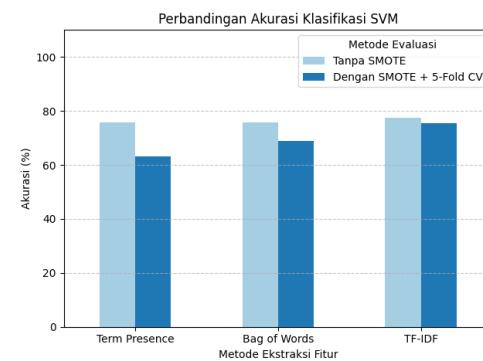
*CV* yang dikombinasikan dengan SMOTE, diperoleh hasil performa yang dapat dibandingkan untuk menilai efektivitas masing-masing pendekatan dalam klasifikasi sentimen. Tabel 15 menampilkan perbandingan akurasi dari kedua evaluasi tersebut.

Tabel 16. Perbandingan Nilai Akurasi

Ekstraksi Fitur	Accuracy(%)	
	Confusion Matix + single train-test	Rata-Rata 5-fold cv + SMOTE
Term Presence	75.76%	63.04%
BoW	75.76%	68.91%
TF-IDF	77.49%	75.54%

Hasil evaluasi menunjukkan bahwa pada pendekatan *single train-test split*, metode ekstraksi fitur TF-IDF memperoleh akurasi tertinggi sebesar 77,49%, diikuti oleh *Term Presence* dan BoW yang keduanya menghasilkan nilai akurasi sebesar 75,76%. Namun, ketika evaluasi dilakukan menggunakan *5-Fold CV* dengan SMOTE, terjadi penurunan akurasi pada metode *Term Presence* dan BoW menjadi masing-masing 63,04% dan 68,91%, sedangkan TF-IDF tetap menunjukkan kinerja yang stabil dengan nilai akurasi 75,54%.

Perbedaan hasil ini mengindikasikan teknik TF-IDF lebih tahan terhadap perubahan distribusi data saat dilakukan *cross validation*, serta lebih mampu memanfaatkan hasil *oversampling* dari SMOTE dengan baik. Penurunan akurasi pada *Term Presence* dan BoW setelah dilakukan SMOTE dan *K-Fold CV* menunjukkan bahwa kedua metode tersebut kurang stabil jika dibandingkan dengan TF-IDF, terutama saat menghadapi data yang diubah strukturnya melalui *oversampling*. Untuk memperjelas perbandingan performa akurasi dari masing-masing metode ekstraksi fitur dalam dua pendekatan evaluasi tersebut, dapat dilihat pada Gambar 8.



Gambar 8. Grafik Perbandingan Nilai Akurasi Evaluasi

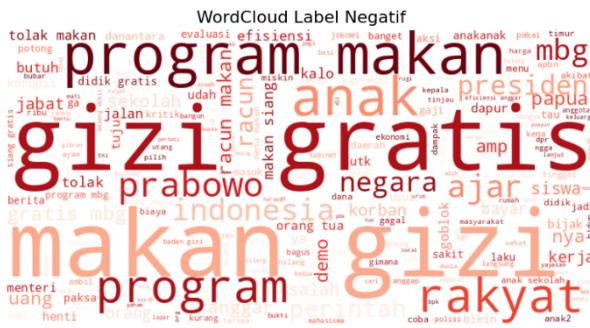
#### E. Analisis Visualisasi Data

Untuk mengidentifikasi kata-kata yang paling sering muncul dalam data riset ini, dibuat visualisasi dalam bentuk *wordcloud*. *Wordcloud* ini menampilkan kata-kata dengan ukuran font yang lebih besar sesuai dengan frekuensi kemunculannya. Visualisasi ini dibuat secara terpisah untuk setiap label sentimen, sehingga memberikan gambaran mengenai distribusi kata berdasarkan sentimen yang dianalisis.



**Gambar 9.** Wordcloud Label Positif

Gambar 9 menampilkan *wordcloud* label sentimen positif, berdasarkan analisis terdapat beberapa topik yang sering dibahas pada Program MBG, diantaranya, "makan gizi", "gizi gratis", "program makan", "presiden", dan "program". Hal ini menunjukkan bahwa topik-topik tersebut mencerminkan perhatian masyarakat terhadap ketersediaan makanan bergizi dan dukungan program pemerintah dalam menyediakan gizi gratis. Penyebutan kata "presiden" juga mengindikasikan bahwa peran pemerintah pusat atau pimpinan negara cukup mendapat sorotan dalam pelaksanaan program ini.



**Gambar 10.** Wordcloud Label Negatif

Gambar 10 menampilkan *wordcloud* label sentimen negatif, berdasarkan analisis terdapat beberapa topik yang sering dibahas pada Program MBG, diantaranya, "makan gizi", "gizi gratis", "program makan", "anak", dan "rakyat". Hal ini menunjukkan bahwa meskipun kata-kata yang muncul terlihat serupa dengan sentimen positif, kemunculannya dalam sentimen negatif dapat menunjukkan adanya kekhawatiran atau kritik masyarakat terhadap pelaksanaan program. Dapat diasosiasikan juga kemungkinan terdapat keluhan mengenai kualitas makanan, keterlambatan, atau ketidaksesuaian dengan harapan publik.

Misalnya, istilah “anak” dan “rakyat” dalam konteks negatif bisa mencerminkan persepsi bahwa kelompok sasaran utama program belum menerima manfaat secara merata atau maksimal. Dengan demikian, sentimen negatif ini tidak selalu menolak program, melainkan lebih mengarah pada evaluasi terhadap implementasi di lapangan.

## **IV. KESIMPULAN**

Berdasarkan hasil yang diperoleh, penggunaan *labelling* menggunakan kamus leksikon InSet dan klasifikasi sentimen menggunakan algoritma SVM yang dikombinasikan dengan teknik ekstraksi fitur TF-IDF memperoleh hasil yang tinggi dibanding menggunakan teknik ekstraksi fitur lainnya, yaitu

*Term Presence* dan BoW. Skor akurasi yang diperoleh menggunakan TF-IDF sebesar 77.5%, sedangkan *Term Presence* sebesar 76.2% dan BoW sebesar 75.3%. Evaluasi lebih lanjut menggunakan *confusion matrix* serta metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score* menunjukkan bahwa TF-IDF tetap unggul, meskipun selisihnya tidak terlalu jauh.

Pada proses validasi menggunakan *5-Fold Cross Validation*, dilakukan sintesis data latih menggunakan SMOTE untuk mengatasi masalah ketidakseimbangan kelas (*imbalanced data*). Hasil validasi menunjukkan bahwa TF-IDF tetap mempertahankan performa terbaik dengan rata-rata akurasi sebesar 75,54%, sementara BoW hanya mencapai 68,91% dan *Term Presence* sebesar 63,04%. Hal ini menunjukkan bahwa meskipun ada penurunan akurasi setelah sintesis data, TF-IDF tetap lebih stabil dan efektif dalam menangani variasi data.

Secara keseluruhan, hasil ini menunjukkan bahwa teknik TF-IDF lebih unggul karena mampu memberikan representasi fitur yang lebih kaya dan informatif dibandingkan teknik lainnya. TF-IDF tidak hanya memperhatikan keberadaan kata dalam dokumen (seperti *Term Presence* atau BoW), tetapi juga memperhitungkan frekuensi kata secara global dalam seluruh korpus, sehingga mampu menekan bobot kata-kata umum dan memperkuat kata-kata yang lebih bermakna secara kontekstual. TF-IDF mampu mengekstraksi fitur yang lebih diskriminatif, sehingga memperkuat kemampuan SVM dalam membedakan kelas sentimen secara lebih akurat.

V. SARAN

Namun, penggunaan kamus leksikon InSet masih memiliki keterbatasan karena beragamnya variasi kata, penggunaan bahasa gaul, kesalahan penulisan (*typo*), dan proses *preprocessing* yang belum optimal. Banyak kata tidak terdapat dalam kamus sentimen sehingga mempengaruhi akurasi klasifikasi. Untuk mengatasi hal ini, diperlukan ekspansi kamus InSet dengan menambahkan kata-kata baru, mengintegrasikan kamus bahasa gaul (*slang*), atau menyertakan kamus bahasa gaul pada tahap *preprocessing* untuk menambahkan bobot sentimen kata-kata informal yang sering muncul dalam komentar media sosial.

## REFERENSI

- [1] Tundo and D. N. Rachmawati, "Implementasi Algoritma Naive Bayes untuk Analisis Sentimen Terhadap Program Makan Siang Gratis," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 2925–2939, 2024.
  - [2] M. Ilham and B. Priambodo, "Analisis Sentimen Publik Terhadap Program Makan Siang Gratis Menggunakan BERT Neural Network Pada Platform X," *JEMSI J. Ekon. Manahemen Sist. Inf.*, vol. 6, no. 2, pp. 1039–1047, 2024.
  - [3] E. Y. Hidayat, R. W. Hardiansyah, and Affandy, "Analisis Sentimen Twitter untuk Menilai Opini Terhadap Perusahaan Publik Menggunakan Algoritma Deep Neural Network," *J. Nas. Teknol. dan Sist. Inf.*, vol. 02, no. 2, pp. 108–118, 2021.
  - [4] J. Anggraini and D. Alita, "Implementasi Metode SVM

- Pada Sentimen Analisis Terhadap Pemilihan Presiden (Pilpres ) 2024 Di Twitter,” *J. Inform. J. Pengemb. IT*, vol. 9, no. 2, pp. 102–111, 2024, doi: 10.30591/jpit.v9i2.6560.
- [5] Z. Jianqiang, G. U. I. Xiaolin, and Z. Xuejun, “Deep Convolution Neural Networks for Twitter Sentiment Analysis,” *IEEE Access*, vol. 6, pp. 23253–23260, 2018, doi: 10.1109/ACCESS.2017.2776930.
- [6] D. T. Attaullah and D. Soyusiwaty, “Analisis Sentimen Program Makan Siang Gratis di Twitter / X menggunakan Metode BI-LSTM,” *Edumatic J. Pendidik. Inform.*, vol. 9, no. 1, pp. 294–303, 2025, doi: 10.29408/edumatic.v9i1.29725.
- [7] R. N. Muhammad, L. W. S, and B. Tanggahma, “Pengaruh Media Sosial Pada Persepsi Publik Terhadap Sistem Peradilan: Analisis Sentimen di Twitter,” *UNES LAW Rev.*, vol. 7, no. 1, pp. 507–516, 2024, doi: <https://doi.org/10.31933/unesrev.v7i1>.
- [8] T. R. Gatla, “A Groundbreaking Research in Breaking Language Barriers: NLP And Linguistics Development,” *Int. J. Adv. Res. Interdiscip. Sci. Endeav.*, vol. 1, no. 1, pp. 1–7, 2024, doi: 10.61359/11.2206-2401.
- [9] A. Monika, L. Toruan, B. M. Panjaitan, E. Malum, and K. Tumangger, “Penggunaan NLP dalam Analisis Sentimen untuk Meningkatkan Kepuasan Pelanggan pada Pengguna E-commerce : Lazada,” *SAINTEK J. Sains, Teknol. Komput.*, vol. 1, no. 1, pp. 18–20, 2024.
- [10] A. Ramadhani, I. Permana, M. Afdal, and M. Fronita, “Analisis Sentimen Tanggapan Publik di Twitter Terkait Program Kerja Makan Siang Gratis Prabowo – Gibran Menggunakan Algoritma Naïve Bayes Classifier dan Support Vector Machine,” *Build. Informatics, Technol. Sci.*, vol. 6, no. 3, pp. 1509–1516, 2024, doi: 10.47065/bits.v6i3.6188.
- [11] P. Arsi and R. Waluyo, “Analisis Sentimen Wacana Pemindahan Ibu Kota Indonesia Menggunakan Algoritma Support Vector Machine (SVM),” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 1, pp. 147–156, 2021, doi: 10.25126/jtiik.202183944.
- [12] O. Manullang, C. Prianto, and N. H. Harani, “Analisis Sentimen Untuk Memprediksi Hasil Calon Presiden Menggunakan Lexicon Based dan Random Forest,” no. 54, 2023.
- [13] K. Taha, “Semi-supervised and un-supervised clustering: A review and experimental evaluation,” *Inf. Syst.*, vol. 114, p. 102178, 2023, doi: <https://doi.org/10.1016/j.is.2023.102178>.
- [14] M. Daffa, A. Fahreza, A. Luthfiarta, M. Rafid, M. Indrawan, and A. Nugraha, “Analisis Sentimen: Pengaruh Jam Kerja Terhadap Kesehatan Mental Generasi Z,” *J. Appl. Comput. Sci. Technol. (JACOST)*, vol. 5, no. 1, pp. 16–25, 2024.
- [15] I. K. N. Ananda, N. Putu, N. Puspa, N. W. Marti, L. Joni, and E. Dewi, “Klasifikasi Multilabel Pada Gaya Belajar Siswa Sekolah Dasar Menggunakan Algoritma Machine Learning,” *J. Appl. Comput. Sci. Technol. (JACOST)*, vol. 5, no. 2, pp. 144–154, 2024.
- [16] P. H. Prastyo, A. S. Sumi, A. W. Dian, and A. E. Permanasari, “Tweets Responding to the Indonesian Government’s Handling of COVID-19: Sentiment Analysis Using SVM with Normalized Poly Kernel,” *J. Inf. Syst. Eng. Bus. Intell.*, vol. 6, no. 2, pp. 112–122, 2020.
- [17] S. A. Nugraha, “Penerapan Lexicon Based Untuk Analisis Sentimen Masyarakat Indonesia Terhadap Danantara,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 3, pp. 4949–4957, 2025.
- [18] M. F. Firdaus, D. E. Ratnawati, and N. Y. Setiawan, “Analisis Sentimen Berbasis Aspek Pada Ulasan Pelanggan Restoran Menggunakan Algoritma Support Vector Machine (Studi Kasus : Depot Bamara),” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 6, pp. 1265–1272, 2024, doi: 10.25126/jtiik.2024117564.
- [19] W. F. Abdillah, “Analisis Sentimen Penanganan Covid-19 Dengan Support Vector Machine : Evaluasi Leksikon Dan Metode Ekstraksi Fitur,” *J. Ilm. Intech Inf. Technol. J. UMUS*, vol. 3, no. 2, pp. 160–170, 2021.
- [20] N. L. P. R. Dewi, I. N. S. W. Wijaya, I. K. Purnamawan, and N. W. Marti, “Model Classifier Judul Berita Pariwisata Indonesia,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 1, pp. 117–124, 2024, doi: 10.25126/jtiik.20241117617.
- [21] R. A. Husen, S. Erlinda, and T. Perumal, “Sentiment Analysis of Societal Attitudes Toward the Childfree Lifestyle Using Latent Dirichlet Allocation (LDA) and Support Vector Machines (SVM),” *Innov. Res. Informatics (Innov.)*, vol. 1, pp. 1–8, 2025.
- [22] F. M. Lubis and M. Ikhsan, “Analisis Sentimen Terhadap Program Kampanye Tabrak Prof Pada Media Sosial X Dengan Menggunakan Metode Support Vector Machine,” *J. Sist. Inf.*, vol. 12, no. 1, pp. 86–92, 2025, doi: 10.30656/jsii.v11i2.9065.
- [23] Suryanto and W. Andriyani, “Sentiment Analysis of X Platform on Viral ‘Fufufafa’ Account Issue in Indonesia Using SVM,” *IJCCS (Indonesian J. Comput. Cybern. Syst.)*, vol. 19, no. 1, pp. 95–104, 2025.
- [24] K. Bagaskara, H. Perdana, and S. Aprizkiyandari, “Penerapan Support Vector Regression Kernel Linier,” *Equator J. Math. Stat. Sci.*, vol. 3, no. 2, pp. 74–83, 2024.
- [25] D. R. Nurqotimah, A. N. Khudori, and R. S. Pradini, “Implementasi Algoritma Support Vector Machine (SVM) Untuk Klasifikasi Penyakit Stroke,” *J. Appl. Comput. Sci. Technol. (JACOST)*, vol. 5, no. 2, pp. 179–185, 2024.
- [26] N. Fajriyah, N. T. Lapatta, D. W. Nugraha, and R. Laila, “Implementasi svm dan smote pada analisis sentimen media sosial x terhadap pelantikan agus harimurti yudhoyono,” *JIPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 10, no. 2, pp. 1359–1370, 2025.
- [27] R. R. R. Arisandi, B. Warsito, and A. R. Hakim, “Aplikasi naïve bayes classifier (nbc) pada klasifikasi status gizi balita stunting dengan pengujian k-fold cross validation,” *J. GAUSSIAN*, vol. 11, pp. 130–139, 2022.