

# A SENTIMENT ANALYSIS OF FREE MEAL PLANS ON SOCIAL MEDIA USING NAÏVE BAYES ALGORITHMS

## ANALISIS SENTIMEN TERHADAP RENCANA MAKAN GRATIS DI SOSIAL MEDIA X MENGGUNAKAN ALOGARITMA NAIVE BAYES

Yoga Zaen Vebrian<sup>1</sup>, Kustiyono<sup>2</sup>  
Teknik Informatika, Universitas Ngudi Waluyo, Indonesia  
email: yogazaen@gmail.com<sup>1</sup>, kustiyono@unw.ac.id<sup>2</sup>

**Abstract** - This study analyses public sentiment towards the "Free Meal Plan" initiative introduced by the political pair Prabowo-Gibran. This policy aims to assist underprivileged communities in Indonesia and is a significant issue in the social and political context. Data was collected from the social media platform X (formerly Twitter), gathering 501 relevant comments based on their connection to the topic and high levels of engagement (such as retweets and likes). The comments were then processed using Text Preprocessing and TF-IDF techniques and applied to a Naïve Bayes model. The model achieved an accuracy of 69.3%, a precision of 72%, a recall of 57.05%, and an F1 score of 54.5%. These results indicate that the model is capable of classifying public sentiment, though it has challenges in accurately detecting negative sentiment. These findings provide valuable insights for policymakers to design more effective communication and policy strategies, particularly in addressing criticism or public dissatisfaction. The study highlights the importance of using text processing and machine learning techniques to analyze social media data in a structured way.

**Keywords** - Python, Sentiment Analysis, Naïve Bayes, TF-IDF, Free Meal Plan, Prabowo-Gibran.

**Abstrak** - Studi ini menganalisis sentimen publik terhadap inisiatif "Rencana Makan Gratis" yang diperkenalkan oleh pasangan politik Prabowo-Gibran. Kebijakan ini bertujuan membantu masyarakat kurang mampu di Indonesia dan menjadi isu penting dalam konteks sosial dan politik. Data diambil dari platform media sosial X (sebelumnya Twitter), dengan mengumpulkan 501 komentar yang relevan berdasarkan keterkaitannya dengan topik dan tingkat interaksi tinggi (seperti retweet dan like). Komentar kemudian diproses menggunakan teknik Preprocessing Teks dan TF-IDF untuk diterapkan pada model Naïve Bayes. Model ini menghasilkan akurasi 69,3%, presisi 72%, recall 57,05%, dan skor F1 54,5%. Hasil ini menunjukkan bahwa model mampu mengklasifikasikan sentimen publik, meskipun dengan tantangan dalam mendeteksi sentimen negatif secara tepat. Temuan ini memberikan wawasan yang berguna bagi pembuat kebijakan untuk merancang strategi komunikasi dan kebijakan yang lebih efektif, terutama dalam menangani kritik atau ketidakpuasan masyarakat. Studi ini menunjukkan pentingnya penggunaan teknik pemrosesan teks dan pembelajaran mesin untuk menganalisis data media sosial dengan cara yang lebih terstruktur.

**Kata Kunci** - Python, Analisis Sentimen, Naïve Bayes, TF-IDF, Rencana Makan Gratis, Prabowo-Gibran.

## I. PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi yang pesat mendorong masyarakat semakin aktif menggunakan media sosial [1]. Media sosial, atau sosmed, adalah *platform* berbasis internet yang memungkinkan pengguna untuk berkomunikasi, berinteraksi, berekspresi, dan bekerja sama secara virtual demi membangun hubungan sosial [2]. Awalnya, media sosial dikembangkan dalam bentuk website dengan layanan email sebagai pionir dalam pengiriman pesan melalui internet. Kini, berbagai *platform* media sosial berlomba menawarkan fitur canggih seperti berbagi foto dan video, transaksi daring, periklanan, berita, panggilan suara atau pesan, serta integrasi kecerdasan buatan (AI). Menurut survei Asosiasi Penyelenggara Jasa Internet Indonesia (APJII) tahun 2024, jumlah pengguna internet bertambah 6 juta jiwa dengan tingkat penetrasi mencapai 79,5%, naik 1,31% dibandingkan tahun 2023 [3]. Di Indonesia, *platform* media sosial populer antara lain *WhatsApp*, *Instagram*, *TikTok*, *YouTube*, serta *Twitter* yang kini dikenal sebagai *X* setelah diakuisisi oleh *Elon Musk*. Banyaknya pengguna media sosial menyebabkan berbagai tindakan individu atau kelompok cepat tersebar luas, memicu respons positif maupun negatif. Pada kampanye pemilihan presiden 2024, pasangan Prabowo Subianto dan Gibran Rakabuming Raka memperkenalkan program makan gratis yang memicu kontroversi terkait anggaran dan pelaksanaannya [4]. Respon masyarakat terhadap program ini banyak muncul di media sosial *X*, *platform microblogging* yang memungkinkan pengguna berekspresi secara bebas sejak diluncurkan pada 2006 [5]. Kebebasan tersebut dimanfaatkan pengguna untuk memberikan berbagai komentar.

Penelitian ini bertujuan mengevaluasi tanggapan masyarakat terhadap program makan gratis dengan analisis sentimen di media sosial *X*. Fokus utama adalah menentukan apakah opini masyarakat cenderung positif atau negatif serta mengukur tingkat akurasi algoritma *Naïve Bayes* dalam mengelompokkan sentimen tersebut. Penelitian ini penting karena opini publik dapat mempengaruhi kebijakan dan keputusan politik. Memahami sentimen masyarakat membantu pembuat kebijakan menyusun strategi komunikasi yang lebih efektif dan memastikan kebijakan sesuai kebutuhan publik. Data penelitian diambil dari komentar pengguna *X* di Indonesia, sehingga hasilnya hanya mencerminkan opini dalam konteks geografis dan waktu tertentu. Analisis sentimen adalah metode yang tepat untuk mengevaluasi penerimaan kebijakan seperti makan gratis. Metode ini mengelompokkan dokumen teks berdasarkan kecenderungan opini terhadap suatu isu [6]. Penelitian ini menggunakan bahasa pemrograman *Python* untuk memproses *Text Preprocessing*, TF-IDF (*Term Frequency-Inverse Document Frequency*), dan algoritma *Naïve Bayes*. Proses *Text Preprocessing* mengolah data teks tidak terstruktur menjadi bentuk yang terstruktur agar siap dianalisis [7]. Metode TF-IDF menggabungkan TF (*Term Frequency*) yang menghitung frekuensi kemunculan kata tanpa memperhatikan konteks, dengan IDF (*Inverse Document Frequency*) yang memberikan bobot lebih besar pada kata-kata jarang muncul, sehingga mengatasi kelemahan metode TF [8]. Algoritma *Naïve Bayes* menggunakan pendekatan supervised learning untuk mengklasifikasikan data dengan memberikan label kelas sesuai probabilitas tertentu [9]. Pengujian ulang dilakukan dengan data baru untuk memastikan sistem yang dikembangkan berjalan optimal dan sesuai tujuan.

## II. SIGNIFIKASI STUDI

### 1. Analisis Sentimen

Analisis Sentimen adalah teknik untuk menilai pendapat publik tentang suatu topik dengan melihat apakah komentar di media sosial bersifat positif atau negatif[10]. Proses ini dimulai dengan mengumpulkan data dari media sosial dan mengolahnnya agar lebih terstruktur. TF-IDF digunakan untuk memberikan bobot pada kata-kata, sementara algoritma *Naïve Bayes*, yang berdasarkan pada teorema *Bayes*, mengklasifikasikan data berdasarkan probabilitas[11]. Metode ini disebut "naïve" karena menganggap setiap fitur bersifat independen. *Naïve Bayes* dan TF-IDF dipilih karena efektif mengolah data teks besar dan cepat dalam menganalisis opini media sosial. Meski mengasumsikan fitur independen, metode ini tetap akurat dalam klasifikasi. Penggunaan TF-IDF membantu meningkatkan efisiensi analisis dengan memberikan bobot lebih pada kata-kata yang jarang muncul tetapi sangat relevan, sehingga meningkatkan akurasi analisis sentimen[18]. Analisis sentimen digunakan untuk menilai pendapat publik tentang suatu isu, dengan tujuan untuk meningkatkan pelayanan atau kualitas, serta mendukung perkembangan penelitian dan penerapannya[12]. Metode ini membantu memahami respons masyarakat terhadap kebijakan atau isu, memberikan wawasan untuk pengambilan keputusan yang lebih baik.

### 2. X

*Twitter*, yang sekarang dikenal sebagai *X* setelah diakuisisi oleh *Elon Musk*, pendiri *SpaceX* dan *Tesla*, adalah *platform microblogging* yang diluncurkan pada 2006 dan masih memiliki banyak pengguna aktif. *X* memiliki banyak peminat karena kemampuannya dalam menyebarkan informasi secara cepat dan mudah dipahami. Penggunaan *hashtag* di *platform* ini menjadi cara yang cepat untuk mencari informasi[13]. *X* memungkinkan penggunaannya untuk berkomentar melalui "*tweet*" yang dapat dibalas dengan *like* atau komentar lainnya[14]. *X* memberikan kebebasan dalam berbagai hal, dengan pengguna dari berbagai usia dan topik yang relevan dengan kehidupan sehari-hari serta berita terkini, mencerminkan kemajuan zaman dan kebutuhan pengguna. Pemantauan sentimen di *X* (dulu *Twitter*) penting untuk memahami opini publik, terutama setelah perubahan kepemilikan yang mempengaruhi cara moderasi dan komunikasi. Sebagai tempat orang berbagi pendapat dan diskusi, *tweet* bisa menunjukkan bagaimana orang merespon isu-isu terkini dan perubahan di *platform* ini.

### 3. Text Preprocessing

*Text Preprocessing* bertujuan mendapatkan data bersih dan terstruktur dalam pengolahannya, sehingga memudahkan pengolahan ditahap berikutnya[15]. *Text Preprocessing* memiliki beberapa proses, yaitu *case folding*, *cleansing*, *tokenizing*, *stopword removal*, dan *stemming*[16]. Penjelasan dari proses tersebut diantaranya:

1. *Case Folding* atau mengubah kata yang semula beragam dirubah menjadi huruf kecil[17].
2. *Cleansing* ialah proses pembersihan tanda baca, *hashtag*, emot, dan *url* yang tidak dibutuhkan[17].
3. *Tokenizing* merupakan proses pemotongan kalimat menjadi perkata dengan pembatas menggunakan tanda baca koma(,)[17].
4. *Stopword Removal* atau proses *Filtering* merupakan proses dimana kata-kata yang tidak dibutuhkan akan dihilangkan layaknya kata penghubung[17].
5. *Stemming* ialah pengubahan kata berimbuhan menjadi bentuk kata dasarnya[17].

Proses ini mengubah data yang awalnya acak dengan berbagai jenis kata menjadi data yang seragam, yaitu kata dasar, dan terstruktur. Perbaikan dalam pemrosesan teks penting untuk memastikan data yang digunakan dalam analisis sentimen berkualitas baik, sehingga algoritma dapat bekerja lebih efisien.

#### 4. TF-IDF

Penggunaan TF-IDF (*Term Frequency-Inverse Document Frequency*) bertujuan untuk menghasilkan representasi yang lebih baik dalam proses ekstraksi dibandingkan metode lain[6]. *Term Frequency* (TF) menghitung bobot kata berdasarkan seberapa sering kata tersebut muncul, sedangkan *Inverse Document Frequency* (IDF) mengukur relevansi kata dalam dokumen dengan memprioritaskan kata-kata yang jarang muncul[18]. Nilai IDF semakin tinggi jika kata lebih unik. Metode ini banyak digunakan karena dapat menghasilkan analisis yang lebih akurat dan efisien, terutama untuk keperluan klasifikasi, analisis sentimen, dan pencarian web. Pemilihan TF-IDF sebagai metode ekstraksi kata membantu mengurangi pengaruh kata-kata yang sering muncul dan lebih menekankan kata-kata yang lebih penting serta relevan untuk analisis sentimen. Rumus untuk menghitung *Term Frequency* (TF) adalah[20]:

$$TF = \frac{\text{Jumlah kemunculan term dalam data}}{\text{Total jumlah term dalam data}} \quad [20]$$

Apabila nilai *Term Frequency*(TF) dari data tersebut sudah didapatkan berikutnya ialah menentukan nilai *Inverse Document Frequency* (IDF) terlebih dahulu menggunakan persamaan[21]:

$$IDF = \log\left(\frac{N}{df}\right) \quad [21]$$

$N$  dipersamaan tersebut melambangkan jumlah keseluruhan data tersebut. Langkah berikutnya ialah mengalikan hasil dari persamaan TF dan IDF, sehingga ditemukan hasil TF-IDF seutuhnya. Nilai atau hasil TF-IDF didapatkan dengan menggunakan persamaan diberikut ini[22]:

$$TFIDF = TF \times IDF \quad [22]$$

#### 5. Algoritma Naïve Bayes

Algoritma *Naïve Bayes* adalah metode pengklasifikasian sederhana yang menggunakan probabilitas dan teorema *Bayes*. Meskipun asumsi independensi fitur sering tidak akurat, algoritma ini tetap efisien dan cocok untuk dataset besar, serta sering memberikan hasil yang akurat dalam deteksi spam, analisis opini, dan klasifikasi dokumen. *Multinomial Naïve Bayes* menggunakan *Natural Language Processing* (NLP) dan konsep *term frequency* untuk menghitung frekuensi kata dalam dokumen[24]. *Naïve Bayes* memiliki beberapa keunggulan, seperti aplikasi yang cepat dan mudah, dapat diterapkan pada data kuantitatif dan kualitatif, serta tidak memerlukan data dalam jumlah besar. Namun, kelemahannya termasuk masalah dengan probabilitas nol yang dapat mengurangi akurasi prediksi, serta ketergantungan pada pengetahuan atau data sebelumnya. Algoritma ini juga terbatas pada teks dan tidak dapat digunakan untuk data gambar[26]. Dalam analisis sentimen, *Naïve Bayes* memberikan efisiensi yang sangat baik meskipun dalam skala besar dan sering kali menghasilkan akurasi yang memadai pada tugas klasifikasi sentimen. Beberapa metrik evaluasi yang umum digunakan untuk mengukur kinerjanya adalah akurasi, presisi, *recall*, dan skor F1[27].

### III. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan *Python* untuk menganalisis sentimen komentar masyarakat tentang "Rencana Makan Gratis" di *platform X (Twitter)*. Dilakukan secara WFH, penelitian mencakup persiapan, pengumpulan data, analisis, perancangan, dan pengujian sistem. Sebanyak 501 komentar terkait program tersebut, dari akun yang menyebut Prabowo dan Gibran, dikumpulkan. Komentar dilabeli untuk dikategorikan sebagai positif atau negatif.

**Tabel 1.** Kriteria Pelabelan Data

Komentar Positif	Komentar Negatif
Komentar memiliki unsur mendukung, mendoakan, dan mengharapkan hal baik atas kebijakan atau topik yang dibicarakan.	Komentar memiliki unsur penolakan, pesimis, menghasut, mengolok-olok terhadap kebijakan atau topik yang sedang hangat

#### A. Text Preprocessing

*Text preprocessing* mengubah teks mentah menjadi data terstruktur dengan menghapus elemen tidak relevan dan meningkatkan kualitas data. Langkah ini bertujuan untuk analisis yang lebih akurat dan efisien.

##### 1. Pembersihan Data (*Data Cleaning*) dan Transformasi Huruf (*Case Folding*)

Langkah awal adalah menghapus elemen tidak relevan seperti simbol, tanda baca, dan URL. *Case folding* menyamakan kapitalisasi dengan mengubah huruf besar menjadi kecil, memastikan teks konsisten dan siap untuk analisis.

##### 2. Tokenisasi (*Tokenization*)

Tokenisasi membagi teks menjadi bagian kecil, seperti kata atau frasa, sehingga analisis dapat dilakukan pada level terkecil. Contohnya, kalimat dipecah menjadi "saya," "makan," dan "nasi."

##### 3. *Filtering (Stopword Filtering)*

*Filter stopwords* menghapus kata-kata umum yang tidak relevan seperti "dan" atau "yang." *Filter token* menyaring kata berdasarkan panjang, menghilangkan kata terlalu pendek atau panjang, seperti "di" atau "ke" sehingga hanya kata bermakna signifikan yang dianalisis.

##### 4. *Stemming*

*Stemming* mengubah kata ke bentuk dasar, misalnya "berlari" menjadi "lari," sehingga variasi kata dianggap sebagai satu entitas. Langkah ini memastikan analisis lebih akurat.

Langkah-langkah *preprocessing teks* sangat penting untuk meningkatkan kualitas dan akurasi analisis data. Pembersihan data dan *case folding* bertujuan supaya analisis menjadi lebih konsisten. Tokenisasi memungkinkan analisis yang lebih mendalam. *Filtering* memastikan hanya kata-kata penting yang dianalisis, sementara *stemming* meningkatkan konsistensi analisis. Secara keseluruhan, *preprocessing* ini mempermudah model dalam mengenali pola dan memperoleh wawasan yang lebih akurat dari data teks.

**Tabel 2.** Sampel Text Preprocessing

Text Preprocessing	Hasil
Proses <i>Case Folding</i>	prabowo yakin program makan bergizi gratis ini bisa memberikan dampak yang luas
Proses <i>Tokenization</i>	['prabowo', 'yakin', 'program', 'makan', 'bergizi', 'gratis', 'ini', 'bisa', 'memberikan', 'dampak', 'yang', 'luas']
Proses <i>Filtering</i>	['prabowo', 'program', 'makan', 'bergizi', 'gratis', 'dampak', 'luas']
Proses <i>Stemming</i>	prabowo program makan gizi gratis dampak luas

**B. Pembobotan Kata**

Pembobotan kata menggunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF) memberikan nilai pada setiap kata dalam dokumen berdasarkan kepentingannya. Proses ini menyoroti kata-kata relevan dan mengabaikan kata umum (*stopword*) yang sering muncul di banyak dokumen, sehingga meningkatkan kualitas analisis sentimen. TF-IDF mengukur frekuensi kemunculan kata (TF) dan kelangkaannya (IDF) untuk menentukan bobotnya. Pembobotan dilakukan dalam sistem, sementara perhitungan manual dilakukan menggunakan data sampel hasil stemming untuk mewakili sentimen positif dan negatif.

**Tabel 3.** Sampel Komentar Hasil Stemming

Sampel Hasil Stemming
prabowo program makan gizi gratis dampak luas
ndut kalah ndut psiko aja ngasih makan gratis
gak makan siang gratis kecuali ngomong prabowo pakai uang negara

**Tabel 4.** Hasil Persamaan TF-IDF

Kata (Term)	Term Frequency (TF)			df	D/df	IDF	TF-IDF		
	D1	D2	D3				D1	D2	D3
prabowo	1	0	1	2	1,5	0,17609	0,17609	0	0,17609
program	1	0	0	1	3	0,47712	0,47712	0	0
makan	1	1	1	3	1	0	0	0	0
gizi	1	0	0	1	3	0,47712	0,47712	0	0
gratis	1	0	1	2	1,5	0,17609	0,17609	0	0,17609
dampak	1	0	0	1	3	0,47712	0,47712	0	0
luas	1	0	0	1	3	0,47712	0,47712	0	0
ndut	0	2	0	2	1,5	0,17609	0	0,35218	0
kalah	0	1	0	1	3	0,47712	0	0,47712	0
psiko	0	1	0	1	3	0,47712	0	0,47712	0
aja	0	1	0	1	3	0,47712	0	0,47712	0
ngasih	0	1	0	1	3	0,47712	0	0,47712	0
gak	0	0	1	1	3	0,47712	0	0	0,47712
siang	0	0	1	1	3	0,47712	0	0	0,47712
kecuali	0	0	1	1	3	0,47712	0	0	0,47712
ngomong	0	0	1	1	3	0,47712	0	0	0,47712
pakai	0	0	1	1	3	0,47712	0	0	0,47712
uang	0	0	1	1	3	0,47712	0	0	0,47712
negara	0	0	1	1	3	0,47712	0	0	0,47712

Persamaan di atas menunjukkan hasil perhitungan TF-IDF, yang mengindikasikan bahwa kata yang sering muncul, seperti "makan", memiliki nilai nol (0) karena muncul di setiap dokumen. Sebaliknya, kata "prabowo" dan "gratis" yang muncul dua kali di dokumen 1 dan 3 menghasilkan nilai 0,17609:

$$TF = \frac{\text{Jumlah kemunculan term dalam data}}{\text{Total jumlah term dalam data}} = \frac{2}{3} = 1,5$$

$$IDF = \log\left(\frac{N}{df}\right) = \log\left(\frac{3}{1,5}\right) = 0,17609$$

$$TFIDF = TF \times IDF = 1 \times 0,17609 = 0,17609$$

*Dataset* yang telah diproses dibagi menjadi data pelatihan dan pengujian untuk memastikan evaluasi model yang lebih akurat.  $X_{train}$  memiliki dimensi (400, 1973), yang berarti terdapat 400 sampel dengan masing-masing memiliki 1.973 fitur, sedangkan  $X_{test}$  berukuran (101, 1973) dengan 101 sampel yang memiliki jumlah fitur yang sama. Label target tersimpan dalam  $y_{train}$  dan  $y_{test}$ , yang masing-masing memiliki ukuran (400,) dan (101,), sesuai dengan jumlah sampel pada data pelatihan dan pengujian. Pemisahan ini memungkinkan model untuk dilatih dan diuji secara terpisah, sehingga kinerjanya dapat dievaluasi dengan lebih objektif. Langkah ini sangat penting untuk memastikan model mampu melakukan klasifikasi atau regresi dengan tingkat akurasi yang optimal.

```
X_train : (400, 1973)
X_test  : (101, 1973)
y_train : (400,)
y_test  : (101,)
```

**Gambar 1.** Pembagian *Dataset* untuk diuji

### C. Implementasi Algoritma Naïve Bayes

Setelah proses pembobotan kata selesai, data uji dianalisis menggunakan metode *Naïve Bayes* untuk memprediksi kategori sentimen. Hasil klasifikasi ini divisualisasikan untuk menunjukkan distribusi sentimen yang teridentifikasi. Pada Gambar 2, evaluasi model *Multinomial Naïve Bayes* menunjukkan metrik akurasi sebesar 69,3%, presisi 75%, *recall* 17,1%, dan *F1-score* 27,9%. Dari *confusion matrix*, terlihat bahwa model mengalami kesulitan dalam mengklasifikasikan kelas negatif, dengan *recall* hanya sebesar 17%, mengindikasikan banyak sampel negatif yang diklasifikasikan sebagai positif. Sebaliknya, *recall* untuk kelas positif cukup tinggi, yaitu 97%, menandakan kemampuan model yang lebih baik dalam mengenali sampel positif. Presisi model untuk kelas negatif mencapai 75%, sementara untuk kelas positif 69%, menunjukkan kinerja yang lebih baik dalam mengenali kelas negatif dibandingkan positif. Namun, rendahnya *recall* pada kelas negatif berdampak pada ketidakseimbangan performa keseluruhan. *F1-score* untuk kelas negatif adalah 0,28, jauh lebih rendah dibandingkan kelas positif yang mencapai 0,81. Secara keseluruhan, akurasi model sebesar 69,3% menunjukkan bahwa sekitar 69 dari 101 sampel berhasil diklasifikasikan dengan benar. Rata-rata tertimbang presisi, *recall*, dan *F1-score* masing-masing adalah 71%, 69%, dan 62%. Hal ini mengindikasikan bahwa meskipun model memiliki presisi yang cukup baik, performa keseluruhannya masih terpengaruh oleh rendahnya *recall* pada kelas negatif, yang perlu menjadi perhatian untuk pengembangan model selanjutnya.

```

MultinomialNB Accuracy : 0.693069306930693
MultinomialNB Preccision : 0.75
MultinomialNB Recall : 0.17142857142857143
MultinomialNB F1 Score : 0.27906976744186046
Confusion Matrix :
[[ 6 29]
 [ 2 64]]
=====
                precision    recall  f1-score   support

negative         0.75         0.17         0.28         35
positive         0.69         0.97         0.81         66

accuracy                    0.69         101
macro avg                 0.72         0.57         0.54         101
weighted avg              0.71         0.69         0.62         101
    
```

**Gambar 2.** Hasil klasifikasi dengan *Naïve Bayes*

D. Evaluasi

Pengujian dilakukan untuk mengevaluasi keberhasilan sistem dalam memprediksi dan mengklasifikasikan sentimen. Metode evaluasi menggunakan *Confusion Matrix* yang menunjukkan jumlah data positif dan negatif yang diklasifikasikan secara benar maupun salah dengan berordo 2x2 memiliki bentuk yang terbaca sistem sebagai berikut:

$$\begin{bmatrix} 6 & 29 \\ 2 & 64 \end{bmatrix}$$

Matrik diatas berisi 64 komentar positif diklasifikasikan dengan benar atau *True Positive* (TP), 6 komentar negatif diklasifikasikan dengan benar atau *True Negative* (TN), 29 komentar negatif yang salah diklasifikasikan sebagai positif atau *False Positive* (FP). 2 komentar positif yang salah diklasifikasikan sebagai negatif atau *False Negative* (FN).

1. Perhitungan *Accuracy*

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{64 + 6}{64 + 6 + 29 + 2} = \frac{70}{101} = 0,693$$

2. Perhitungan *Precision*

$$Precision\ Negative(PN) = \frac{TN}{TN + FN} = \frac{6}{6 + 2} = 0,75$$

$$Precision\ Positive(PP) = \frac{TP}{TP + FP} = \frac{64}{64 + 29} = 0,69$$

3. Perhitungan *Recall*

$$Recall\ Negative(RN) = \frac{TN}{TN + FN} = \frac{6}{6 + 29} = 0,171$$

$$Recall\ Positive(RP) = \frac{TP}{TP + FP} = \frac{64}{64 + 2} = 0,97$$

4. Perhitungan *F1-Score*

$$F1 - Score\ Negative = \frac{2 \times PN \times RN}{PN + RN} = \frac{2 \times 0,75 \times 0,171}{0,75 + 0,171} = 0,28$$

$$F1 - Score\ Positive = \frac{2 \times PP \times RP}{PP + RP} = \frac{2 \times 0,69 \times 0,97}{0,69 + 0,97} = 0,81$$

```
Confusion Matrix :
[[ 6 29]
 [ 2 64]]
=====
              precision    recall  f1-score   support

negative     0.75         0.17         0.28         35
positive     0.69         0.97         0.81         66

accuracy          0.69         101
macro avg         0.72         0.57         0.54         101
weighted avg      0.71         0.69         0.62         101
```

**Gambar 3.** Hasil Confusion Matrix

Berdasarkan perhitungan, sistem ini memiliki akurasi 69,3%, dengan presisi 72% (75% untuk positif dan 69% untuk negatif) serta *recall* 57,05% (17,1% untuk positif dan 97% untuk negatif). *F1-score* mencapai 54,5% (28% untuk positif dan 81% untuk negatif), mencerminkan performa keseluruhan. *Accuracy* sebesar 69% menunjukkan model mengklasifikasikan 69 dari 101 sampel dengan benar. *Macro average*, yang menghitung rata-rata tanpa mempertimbangkan jumlah sampel, memiliki presisi 72%, *recall* 57%, dan *F1-score* 54%, menunjukkan ketidakseimbangan antar kelas. *Weighted average*, yang mempertimbangkan jumlah sampel, menunjukkan presisi 71%, *recall* 69%, dan *F1-score* 62%, yang lebih mewakili performa keseluruhan. *Weighted recall* lebih tinggi dari *macro recall*, menunjukkan model lebih mudah mengenali kelas positif dibanding negatif.

```
dt_pred = "Semangat dan selalu berinovasi pak"

dt_pred_clean = casefolding(dt_pred)
dt_pred_clean = token(dt_pred_clean)
dt_pred_clean = stopwords_removal(dt_pred_clean)
dt_pred_clean = stemming(dt_pred_clean)

list_pred = [dt_pred_clean]
dt_pred_tfidf = TfidfTransformer().transform(list_pred)
my_pred = clf.predict(dt_pred_tfidf)

print("Komentar : ", dt_pred)
print("Komentar bersih : ", dt_pred_clean)
print("Sentimen : ", my_pred[0])

✓ 0.6s Python
```

Komentar : Semangat dan selalu berinovasi pak  
Komentar bersih : semangat inovasi  
Sentimen : positive

**Gambar 4.** Pengujian dengan Hasil Positif

```

dt_pred = "dut lu kerjanya ngemis aja"

dt_pred_clean = casefolding(dt_pred)
dt_pred_clean = token(dt_pred_clean)
dt_pred_clean = stopwords_removal(dt_pred_clean)
dt_pred_clean = stemming(dt_pred_clean)

list_pred = [dt_pred_clean]
dt_pred_tfidf = Tfidf.transform(list_pred)
my_pred = clf.predict(dt_pred_tfidf)

print("Komentar : ", dt_pred)
print("Komentar bersih : ", dt_pred_clean)
print("Sentimen : ", my_pred[0])

```

✓ 2.2s Python

Komentar : dut lu kerjanya ngemis aja  
Komentar bersih : dut lu kerja ngemis aja  
Sentimen : negative

**Gambar 5.** Pengujian dengan Hasil Negatif

Gambar 4 dan gambar 5 menampilkan implementasi prediksi sentimen pada teks menggunakan preprocessing seperti *casefolding*, *tokenisasi*, *stopword removal*, dan *stemming*, kemudian dikonversi dengan TF-IDF sebelum diprediksi menggunakan model. Hasil yang ditunjukkan bahwa gambar 4 bersifat sentimen positif dan gambar 5 bersifat sentimen negatif, yang merupakan pencerminan kinerja model berdasarkan evaluasi sebelumnya.

#### IV. KESIMPULAN

Penelitian ini menganalisis opini publik tentang program "Rencana Makan Gratis" di platform X menggunakan algoritma Naïve Bayes, Text Preprocessing, dan TF-IDF. Dari 501 komentar, sistem mencapai akurasi 69,3%, precision 72%, recall 57,05%, dan F1-score 54,5%. Hasil ini menunjukkan sistem mampu mengidentifikasi opini masyarakat secara seimbang antara sentimen positif dan negatif. Hasil penelitian mendukung tujuan utama untuk memahami sentimen publik terhadap kebijakan ini. Temuan ini memberikan wawasan penting yang dapat membantu pembuat kebijakan dalam menyusun komunikasi publik yang lebih efektif. Sebagai contoh, hasil analisis dapat digunakan untuk menyoroti aspek kebijakan yang mendapat dukungan publik atau menangani isu yang memicu kritik. Wawasan ini juga relevan untuk merancang strategi komunikasi yang lebih baik dalam program serupa di masa mendatang. Rekomendasi pengembangan meliputi:

1. Menggunakan teknik preprocessing yang lebih mendalam, seperti stemming dan filtering.
2. Mengintegrasikan algoritma canggih seperti Support Vector Machine (SVM) untuk meningkatkan akurasi.
3. Memperluas dataset dengan melibatkan platform media sosial lain untuk analisis yang lebih menyeluruh.

Penelitian ini diharapkan dapat menjadi acuan untuk memahami opini masyarakat dan membantu penyusunan kebijakan yang lebih efektif di masa depan.

**REFERENSI**

- [1] D. Wiryany, S. Natasha, and R. Kurniawan, “Perkembangan Teknologi Informasi dan Komunikasi terhadap Perubahan Sistem Komunikasi Indonesia,” *J. Nomosleca*, vol. 8, no. 2, pp. 242–252, 2022, doi: 10.26905/nomosleca.v8i2.8821.
- [2] Y. Afandi, “Gereja dan Pengaruh Teknologi Informasi ‘Digital Ecclesiology,’” *Fidei J. Teol. Sist. dan Prakt.*, vol. 1, no. 2, pp. 270–283, 2019, doi: 10.34081/270033.
- [3] (Asosiasi Penyelenggara Jasa Internet Indonesia)APJII, “Internet Indonesia,” *Survei Penetrasi Internet Indones.*, pp. 1–90, 2024, [Online]. Available: <https://survei.apjii.or.id/survei/group/9>
- [4] P. Ardelia Maharani, A. Riyani Namira, and T. Viony Chairunnisa, “Peran Makan Siang Gratis Dalam Janji Kampanye Prabowo Gibran Dan Realisasinya,” *Jolasos J. Law Soc. Soc.*, pp. 1–10, 2024.
- [5] N. B. Putri and N. A. Romli, “Analisis Dampak Adiksi Internet Pada Media Sosial Twitter Di Indonesia Dengan Pendekatan Teori Komunikasi,” *J. Komun. Univ. Garut Has. Pemikir. dan Penelit.*, vol. 7, no. 1, p. 582, 2021, doi: 10.52434/jk.v7i1.905.
- [6] I. M. Karo Karo, J. A. Karo Karo, Y. Yuniyanto, H. Hariyanto, M. Falah, and M. Ginting, “Analisis Sentimen Ulasan Aplikasi Info BMKG di Google Play Menggunakan TF-IDF dan Support Vector Machine,” *J. Inf. Syst. Res.*, vol. 4, no. 4, pp. 1423–1430, 2023, doi: 10.47065/josh.v4i4.3943.
- [7] A. H. Lubis and Y. F. Harahap, “Analisis Sentimen Masyarakat Terhadap Resesi Ekonomi Global 2023 Menggunakan Algoritma Naïve Bayes Classifier,” vol. 16, no. 2, pp. 442–450, 2023.
- [8] E. D. Harahap, R. Kurniawan, U. Islam, N. Sumatera, K. Deli, and S. Utara, “Analisis Sentimen Komentar Terhadap Kebijakan Pemerintah Mengenai Tabungan Perumahan Rakyat ( TAPERA ) Pada Aplikasi X Menggunakan Metode Naïve Bayes,” vol. 09, 2024.
- [9] N. S. Fauzia and R. D. Dana, “Implementasi Algoritma Naive bayes dalam Klasifikasi Status Kesejahteraan Masyarakat Desa Gunungsari,” 2023.
- [10] J. Supriyanto, D. Alita, and A. R. Isnain, “Penerapan Algoritma K-Nearest Neighbor (K-NN) Untuk Analisis Sentimen Publik Terhadap Pembelajaran Daring,” *J. Inform. dan Rekayasa Perangkat Lunak*, vol. 4, no. 1, pp. 74–80, 2023, doi: 10.33365/jatika.v4i1.2468.
- [11] N. Bayes, S. Kasus, P. T. As, and S. Sukses, “Naïve bayes,” vol. 4, no. 2, 2024.
- [12] Y. Nurtikasari, S. Alam, T. I. Hermanto, T. Informatika, S. Tinggi, and T. Wastukancana, “Analisis Sentimen Opini Masyarakat Terhadap Film Pada Platform Twitter Menggunakan Algoritma Naive Bayes,” vol. 1, no. 4, pp. 411–423, 2022, doi: 10.55123/insologi.v1i4.770.
- [13] M. D. Alizah, A. Nugroho, U. Radiyah, and W. Gata, “Sentimen Analisis Terkait Lockdown pada Sosial Media Twitter,” *Indones. J. Softw. Eng.*, vol. 6, no. 2, pp. 223–229, 2020, doi: 10.31294/ijse.v6i2.8991.
- [14] I. Zahra and A. Voutama, “Rancangan User Persona Dan Customer Journey Map Sebagai Representasi Kebutuhan Pengguna Media Sosial X Pada Fitur Pencarian,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 3, pp. 2686–2691, 2024, doi: 10.36040/jati.v8i3.9531.
- [15] Y. H. Id, D. M. Id, and Y. Yigal, “The influence of preprocessing on text classification using a bag-of-words representation,” pp. 1–22, 2020, doi: 10.1371/journal.pone.0232525.

- [16] T. Ridwansyah, "Implementasi Text Mining Terhadap Analisis Sentimen Masyarakat Dunia Di Twitter Terhadap Kota Medan Menggunakan K-Fold Cross Validation Dan Naïve Bayes Classifier," vol. 2, no. 5, pp. 178–185, 2022.
- [17] R. Sistem, "Jurnal resti," vol. 5, no. 10, pp. 820–826, 2021.
- [18] I. Widaningrum, D. Mustikasari, R. Arifin, S. L. Tsaqila, and D. Fatmawati, "Algoritma Term Frequency – Inverse Document Frequency ( TF-IDF ) dan K-Means Clustering Untuk Menentukan Kategori Dokumen," pp. 145–149.
- [19] L. Annisa, A. D. Kalifia, B. Humaniora, and U. T. Yogyakarta, "Gudang Jurnal Multidisiplin Ilmu Analisis Teknik TF-IDF Dalam Identifikasi Faktor-Faktor Penyebab Depresi Pada Individu," vol. 2, pp. 302–307, 2024.
- [20] D. Ananda and R. R. Suryono, "Analisis Sentimen Publik Terhadap Pengungsi Rohingya di Indonesia dengan Metode Support Vector Machine dan Naïve Bayes," *J. Media Inform. Budidarma*, vol. 8, no. 2, p. 748, 2024, doi: 10.30865/mib.v8i2.7517.
- [21] S. Tabuk and K. Banjar, "3 1,2,3," vol. 2, pp. 349–365, 2023.
- [22] C. H. Yutika, A. Adiwijaya, and S. Al Faraby, "Analisis Sentimen Berbasis Aspek pada Review Female Daily Menggunakan TF-IDF dan Naïve Bayes," *J. Media Inform. Budidarma*, vol. 5, no. 2, p. 422, 2021, doi: 10.30865/mib.v5i2.2845.
- [23] Syahril Dwi Prasetyo, Shofa Shofiah Hilabi, and Fitri Nurapriani, "Analisis Sentimen Relokasi Ibukota Nusantara Menggunakan Algoritma Naïve Bayes dan KNN," *J. KomtekInfo*, vol. 10, pp. 1–7, 2023, doi: 10.35134/komtekinfo.v10i1.330.
- [24] G. Singh, B. Kumar, L. Gaur, and A. Tyagi, "Comparison between Multinomial and Bernoulli Naïve Bayes for Text Classification," *2019 Int. Conf. Autom. Comput. Technol. Manag. ICACTM 2019*, no. May 2020, pp. 593–596, 2019, doi: 10.1109/ICACTM.2019.8776800.
- [25] C. D. Angelina and Painem, "Penerapan Algoritma Naive Bayes Classifier Pada Analisis Sentimen Masyarakat Indonesia Terhadap Childfree Pada Twitter," *Semin. Nas. Mhs. Fak. Teknol. Inf.*, vol. 2, no. 2, pp. 398–407, 2023.
- [26] Rayuwati, Husna Gemasih, and Irma Nizar, "IMPLEMENTASI AIGORITMA NAIVE BAYES UNTUK MEMPREDIKSI TINGKAT PENYEBARAN COVID," *Jural Ris. Rumpun Ilmu Tek.*, vol. 1, no. 1, pp. 38–46, 2022, doi: 10.55606/jurritek.v1i1.127.
- [27] D. Nisrina and K. Kustiyono, "Analisis Kepuasan Konsumen Menggunakan Metode Algoritma C4.5 Berbasis Rapidminer Pada PT. Adeaksa Indo Jayatama," *MEANS (Media Inf. Anal. dan Sist.*, vol. 9, no. 1, pp. 26–33, 2024, doi: 10.54367/means.v9i1.3710.