

# Analisis Emosi Pada Live Chat Youtube 'Mata Najwa: 3 Bacapres Bicara Gagasan' Menggunakan Pendekatan Lexicon dan Algoritma Naive Bayes

Fadlan Amrullah<sup>1\*</sup>, Achmad Solichin<sup>2</sup>

<sup>1,2,3</sup>Fakultas Teknologi Informasi, Teknik Informatika, Universitas Budi Luhur, Jakarta, Indonesia

Jl. Raya Ciledug, Petungkang Utara, Pesanggrahan, Jakarta Selatan, 12260

E-mail: <sup>1\*</sup>fadlann420@gmail.com, <sup>2</sup>achmad.solichin@budiluhur.ac.id

(\*: corresponding author)

**Abstrak**—Pada tahun 2023, Indonesia memasuki periode politik krusial dalam ranah politik, menandai persiapan menuju pemilihan Presiden dan Wakil Presiden serta pemilu legislatif 2024. Dalam konteks ini, media sosial, khususnya YouTube, menjadi panggung utama interaksi politik. Mata Najwa, melalui kanal YouTube-nya, menjadi panggung sentral bagi interaksi politik dengan menyelenggarakan acara siaran langsung berjudul "3 Bacapres Bicara Gagasan" pada 19 September 2023. Pada kesempatan tersebut, para bakal calon Presiden berbagi gagasan dan pandangan langsung kepada masyarakat, memanfaatkan kemajuan teknologi komunikasi. Peran YouTube dalam lanskap politik semakin signifikan, dan respons emosional dalam *live chat* menjadi fokus analisis. Penelitian ini bertujuan untuk melakukan analisis emosi terhadap pandangan atau respon masyarakat kepada acara yang diselenggarakan pada kanal youtube Mata Najwa tersebut. Dengan memanfaatkan kamus kata EmoLex, analisis emosi pada dataset yang besar menjadi lebih efisien tanpa memerlukan pelabelan emosi secara manual. Pendekatan machine learning dilakukan melalui ekstraksi fitur TF-IDF dan penerapan Algoritma Multinomial Naive Bayes untuk menganalisis emosi dari teks komentar. *Dataset* yang digunakan bersumber dari *live chat* pada acara inti Mata Najwa, yaitu pada saat para bacapres bicara gagasan mereka (Anies Baswedan, Ganjar Pranowo, dan Prabowo Subianto). Dengan menerapkan ekstraksi fitur TF-IDF dan klasifikasi, model yang dikembangkan mencapai tingkat akurasi sebesar 90.67% berdasarkan *dataset* gabungan ke-tiga bakal calon Presiden.

**Kata Kunci**—Youtube, Pemilu, EmoLex, TF-IDF, Multinomial Naive Bayes.

**Abstract**—In 2023, Indonesia enters a crucial political period in the realm of politics, marking preparations for the 2024 Presidential and Vice Presidential and legislative elections. In this context, social media, particularly YouTube, became the main stage for political interaction. Mata Najwa, through its YouTube channel, became a central platform for political interaction by organizing a live broadcast event entitled "3 Bacapres Bicara Gagasan" on September 19, 2023. On this occasion, the presidential candidates shared their ideas and views directly with the public, utilizing advances in communication technology. YouTube's role in the political landscape is increasingly significant, and emotional responses in live chats are the focus of analysis. This study aims to conduct an emotional analysis of the views or responses of the public to the event organized on the Mata Najwa YouTube channel. By utilizing the EmoLex word dictionary, emotion analysis on large datasets becomes more efficient without the need for manual

*emotion labeling. The machine learning approach is carried out through TF-IDF feature extraction and the application of Multinomial Naive Bayes Algorithm to analyze emotions from comment texts. The dataset used is sourced from the live chat on Mata Najwa's core program, which is when the vice presidential candidates talk about their ideas (Anies Baswedan, Ganjar Pranowo, and Prabowo Subianto). By applying TF-IDF feature extraction and classification, the developed model achieved an accuracy rate of 90.67% based on the combined dataset of the three presidential candidates.*

**Keyword**— Youtube, Election, EmoLex, TF-IDF, Multinomial Naive Bayes.

## I. PENDAHULUAN

Setelah Orde Baru, Indonesia telah mengadakan lima pemilu sejak tahun 1999, yaitu pada tahun 1999, 2004, 2009, 2014, dan 2019. Sejak 2015, pemilu diadakan serentak untuk memilih anggota legislatif, Presiden, dan Wakil Presiden, menjadi syarat penting dalam membangun sistem politik yang demokratis [1]. Pada tahun 2023, Indonesia memasuki periode politik penting menjelang pemilihan Presiden, Wakil Presiden, dan pemilu legislatif tahun 2024. Bakal calon Presiden menggunakan berbagai platform komunikasi, khususnya YouTube, sebagai panggung utama interaksi publik. Melalui acara "3 Bacapres Bicara Gagasan" di kanal YouTube Mata Najwa, para kandidat dapat langsung berbagi pandangan mereka. Analisis respons emosional dalam *live chat* YouTube memberikan wawasan tentang komunikasi politik saat ini, mencerminkan preferensi, sensitivitas, dan kecenderungan masyarakat terhadap isu-isu politik serta efektivitas pesan komunikasi dari para calon Presiden.

Pengamat sosial dan politik semakin memperhatikan pentingnya respons emosional dalam *live chat* acara politik di YouTube sebagai indikator keselarasan, keberagaman, dan intensitas pemikiran masyarakat terhadap isu-isu yang dibahas. Analisis terhadap emosi dalam interaksi online menjadi kunci untuk memahami peran komunikasi politik di era digital, terutama di platform yang memungkinkan partisipasi langsung. Perbedaan respons emosional, dari antusiasme hingga ketidaksetujuan, mengungkap preferensi dan kecenderungan masyarakat terhadap isu-isu serta merefleksikan efektivitas pesan komunikasi dari para calon Presiden.

Sari dan Wibowo melakukan studi sebelumnya tentang analisis emosi teks menggunakan Naive Bayes *Classifier* (NBC) dengan TF-IDF dan *emoticon* untuk menilai sentimen *tweet* terkait JD.id. Tanpa fitur tambahan, NBC mencapai akurasi 96,44%. Namun, dengan tambahan fitur TF-IDF dan *emoticon*, akurasi meningkat menjadi 98% [2]. Dalam studi oleh Ariyanti dan Iswardani tentang sentimen terkait keluhan dari penduduk Kota Probolinggo, mereka menggunakan algoritma Naive Bayes yang mencapai akurasi 95% [3]. Pada penelitian lainnya, Nugraha melakukan analisis emosi terhadap komentar di media sosial Instagram menggunakan metode Naive Bayes [4]. Hasil pengujian menunjukkan nilai akurasi yang cukup tinggi, sebesar 96,3%, namun sayangnya penelitian hanya mengklasifikasi emosi negatif dan positif.


Berdasarkan studi terdahulu serta permasalahan yang terjadi, maka penelitian ini bertujuan untuk melakukan analisis respons emosional masyarakat dalam acara Mata Najwa "3 Bacapres Bicara Gagasan". Metode yang digunakan adalah dengan melakukan analisis sentimen melalui pendekatan machine learning disertai dengan kamus leksikon emosi NRC *Word-Emotion Association Lexicon* (EmoLex) dengan delapan kata emosi dasar (antisipasi, gembira, jijik, kejutan, marah, percaya, sedih dan takut) [5]. Menggunakan ekstraksi fitur TF-IDF dan membuat model dengan algoritma Naive Bayes.

Analisis sentimen, atau *opinion mining*, adalah proses mengekstraksi dan menganalisis opini dalam teks untuk mengidentifikasi arah sentimen, emosi, dan penilaian. Meskipun emosi penting dalam komunikasi sehari-hari, sering kali diabaikan dalam interaksi manusia dengan computer [6]. Analisis sentimen juga dapat digunakan untuk memahami reaksi masyarakat terhadap konten video di YouTube [7]. *Text mining*, sebagai proses penggalian informasi dari teks melalui analisis statistik, melibatkan langkah-langkah pembobotan kata untuk mengidentifikasi pola dan tren, seperti TF, IDF, RF, TF-IDF, dan lainnya [8]. EmoLex, sebuah daftar kata dan frasa yang diklasifikasikan berdasarkan ekspresi emosi, penting dalam membedakan antara pengaruh dan emosi dalam psikologi [9]. Kamus EmoLex yang digunakan dapat diakses secara publik pada link <https://saifmohammad.com/WebDocs/Lexicons/NRC-Emotion-Lexicon.zip> yang didapat pada *website* dengan alamat <https://saifmohammad.com/WebPages/NRC-Emotion-Lexicon.htm>.

## II. METODE PENELITIAN

### A. Penerapan Metode

Dalam pengembangan aplikasi untuk analisis emosi dalam penelitian ini, dilakukan serangkaian langkah-langkah terstruktur dari perencanaan hingga implementasi untuk mencapai kinerja optimal. Tahapan-tahapan ini direpresentasikan secara visual dalam Gambar 1.



Gambar 1. Penerapan Metode

Pada Gambar 1, data *live chat* YouTube dari acara "Mata Najwa: 3 Bacapres Bicara Gagasan" diambil melalui pustaka GitHub, kemudian tahap *preprocessing*, data dibersihkan dan disimpan dalam format *.csv*. Setelah *preprocessing*, pesan-pesan diberi label emosi dengan kamus EmoLex. Data dibagi menjadi data latih dan uji. Data latih diolah dengan TF-IDF dan dipelajari dengan Multinomial Naive Bayes. Data uji digunakan untuk menguji akurasi model. Hasil dievaluasi dalam bentuk nilai persentase.

### B. Data Penelitian

Penelitian ini menggunakan dataset dari data live chat YouTube pada acara "Mata Najwa: 3 Bacapres Bicara Gagasan". Data dikumpulkan menggunakan pustaka *chat-downloader* yang tersedia di GitHub setelah berakhirnya siaran langsung YouTube. *Dataset* disimpan dalam format *.csv* dan mengandung berbagai atribut, termasuk beberapa yang tidak relevan seperti *image\_url*, *message\_id*, dan *emoticon*. Dalam penelitian ini, hanya atribut-atribut yang relevan yang digunakan.

### C. Preprocessing

*Preprocessing* pada *text mining* adalah proses awal yang mempersiapkan data mentah untuk analisis dengan metode tertentu. Tahap ini menerapkan konsep dan teknik data mining untuk menemukan pola dalam teks, dengan tujuan menghasilkan informasi yang relevan. Tujuan utama *preprocessing* adalah membersihkan data dari *noise*, standarisasi kata, dan mengurangi kosa kata. Proses *preprocessing* melibatkan langkah-langkah seperti *tokenization*, *case folding*, *cleansing*, dan penghapusan *stop word*. Penelitian ini juga menambahkan langkah untuk mengubah *slang word* sebelum melakukan penghapusan *stop word* untuk hasil yang lebih optimal [10], [11].

1) *Tokenization*: Langkah awal dalam *preprocessing* data dalam bidang *information retrieval* dan NLP. Tujuannya adalah membagi teks menjadi token-token individu, mempermudah analisis dan pemrosesan. Hal ini memungkinkan teks untuk dipahami dan diproses lebih efisien oleh mesin [12].

2) *Case Folding*: Proses mengubah kata menjadi huruf kecil menggunakan metode *lower* dalam Python. Tujuannya adalah agar semua kata dalam teks memiliki format yang seragam, yaitu huruf kecil, sehingga mempermudah pemrosesan data [13].

3) *Cleansing*: Langkah untuk menghapus angka, URL, HTML, *emoticon*, *hashtag*, dan *mention username* dari teks, mengurangi gangguan sehingga teks menjadi bersih [14].

4) *Convert Slang Word*: proses mengubah istilah tidak resmi atau *singkatan* menjadi kata baku dalam komunikasi [15]. Kamus kata berasal dari repositori GitHub yang merupakan hasil pengumpulan dari berbagai sumber penelitian dan repositori GitHub lainnya ([https://github.com/louisowen6/NLP\\_bahasa\\_resources/blob/master/combined\\_slang\\_words.txt](https://github.com/louisowen6/NLP_bahasa_resources/blob/master/combined_slang_words.txt)).

5) *Stop Word Removal*: proses menghapus kata-kata yang tidak relevan atau tidak memiliki makna tersendiri, serta kata-kata yang sering muncul dan dianggap tidak penting, seperti "dan", "pada", "pula", "saat", dan lainnya yang terdaftar

dalam *list Stop Word* [15]. Kamus kata berasal dari repositori GitHub yang merupakan gabungan beberapa daftar *Stop Word* dari penelitian dan repositori GitHub lainnya ([https://github.com/louisowen6/NLP\\_bahasa\\_resources/blob/master/combined\\_stop\\_words.txt](https://github.com/louisowen6/NLP_bahasa_resources/blob/master/combined_stop_words.txt)).

#### D. Labeling

Dalam langkah ini, teks pesan yang telah melalui tahapan *preprocessing* akan diberi label berdasarkan kelas emosi yang telah ditentukan. Tujuan dari langkah ini adalah untuk menelusuri apakah kata-kata dalam teks pesan ada dalam kamus EmoLex. Teks pesan akan diklasifikasikan ke dalam delapan kategori emosi, termasuk antisipasi, gembira, jijik, kejutan, marah, percaya, sedih dan takut.

#### E. Split Data

Dalam tahap ini, teks pesan yang telah diberi label akan dibagi menjadi dua kelompok, yaitu data uji dan data latih. Karena *dataset* yang tersedia cukup besar, pembagian data akan dilakukan dengan rasio 90:10, di mana 90% akan digunakan sebagai data latih dan 10% sebagai data uji.

#### F. TF-IDF

Dalam metode TF-IDF, hasil dari perkalian nilai *Term Frequency* (TF) dan *Inverse Document Frequency* (IDF) digunakan untuk menentukan bobot kata (*term weight*) untuk setiap kata dalam sebuah dokumen. Bobot ini menggambarkan seberapa pentingnya kata tersebut dalam dokumen tersebut dibandingkan dengan seluruh koleksi dokumen yang lebih besar [16]. Persamaan (1) menunjukkan rumus untuk menghitung *Term Frequency* (TF), sementara persamaan (2) menggambarkan perhitungan *Inverse Document Frequency* (IDF). Persamaan (3) adalah rumus untuk menghitung nilai TF-IDF, yang merupakan hasil dari perkalian antara TF dan IDF.

$$TF(t, d) = \frac{\text{jumlah kemunculan kata dalam dokumen}}{\text{total jumlah kata dalam dokumen}} \quad (1)$$

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

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

Keterangan:

$N$  : jumlah total dokumen dalam koleksi.  
 $df(t, D)$  : jumlah dokumen dalam koleksi yang mengandung *term* (t).  
 $W(t, d)$  : bobot *term* (t) dalam suatu dokumen  
 $TF(t, d)$  : *Term Frequency* dari *term* (t) dalam dokumen (d)  
 $IDF(t, D)$  : *Inverse Document Frequency* dari *term* (t) dalam seluruh dokumen (D)

#### G. Multinomial Naive Bayes

Naive Bayes memiliki beberapa versi klasik, termasuk multinomial, Bernoulli, dan Gaussian [17]. Skala multinomial membantu algoritma mengenali kontribusi relatif setiap kata atau frase terhadap kelas yang diprediksi. Contohnya, jika sebuah kata sering muncul dalam dokumen dari kelas tertentu, kata tersebut dianggap lebih relevan atau berkontribusi lebih signifikan terhadap kelas tersebut. Metode Multinomial Naive

Bayes sering diterapkan dalam analisis klasifikasi teks karena kemudahannya dan efektivitasnya. Metode ini memanfaatkan prinsip probabilitas yang dikombinasikan dari kata-kata serta kategori untuk memperkirakan probabilitas kategori dalam sebuah dokumen [18]. Dalam Metode Multinomial Naive Bayes, tahap awalnya adalah menghitung probabilitas prior atau kemungkinan munculnya suatu kategori pada seluruh dataset latih, seperti yang dinyatakan dalam Persamaan (4).

$$P(c) = \frac{N_c}{N_{doc}} \quad (4)$$

Keterangan:

$c$  : Kategori atau kelas  
 $doc$  : Dokumen  
 $N_c$  : Jumlah kategori c dalam dokumen latih  
 $N_{doc}$  : Total jumlah dokumen latih yang digunakan

Langkah berikutnya dalam Metode Multinomial Naive Bayes adalah menghitung probabilitas sebuah kata tertentu masuk ke dalam suatu kategori atau kelas, yang dapat dilakukan dengan menggunakan Persamaan 5.

$$P(w_i, c) = \frac{\text{count}(w_i, c) + 1}{\sum w \text{count}(w_i, c) + 1} \quad (5)$$

Keterangan:

$w_i$  : Kata ke-i dalam semua dokumen yang terkategori sebagai c  
 $\text{count}(w_i, c)$ : Jumlah kemunculan kata tertentu dalam suatu kategori atau kelas  
 $\sum w \text{count}(w_i, c)$ : Jumlah kemunculan semua kata dalam kelas tersebut  
 $|V|$ : Jumlah total kata unik pada kelas

Penambahan nilai satu diperlukan untuk mencegah probabilitas yang bernilai nol, sebuah modifikasi yang disebut *smoothing*. Setelah proses pembelajaran selesai, langkah berikutnya adalah melakukan klasifikasi data baru berdasarkan informasi yang telah dipelajari sebelumnya. Dalam proses klasifikasi ini, perhitungan dilakukan menggunakan Persamaan 6.

$$P(c, d) = P(c) \prod_{1 \leq i \leq \text{count}(v, d)} P(w_i, c) \quad (6)$$

Keterangan:

$\text{count}(v, d)$  : Jumlah kata unik pada dokumen

#### H. Rancangan Pengujian

Pada tahap pengujian ini, peneliti melakukan evaluasi kinerja model yang telah dilatih menggunakan Metode Multinomial Naive Bayes. Evaluasi ini melibatkan pengukuran tingkat akurasi, presisi, *recall*, dan *F1-score*. Dalam konteks penelitian ini, pengujian dilakukan dengan membandingkan hasil prediksi dari data uji (data pada tahap klasifikasi) dengan *dataset* asli (data pada tahap *labeling*). Hasil prediksi merujuk pada hasil pemrosesan *dataset* menggunakan Metode Multinomial Naive Bayes. Persamaan (7) menyajikan rumus untuk menghitung akurasi, sedangkan Persamaan (8) menguraikan perhitungan presisi. Persamaan (9) menjelaskan rumus untuk nilai *recall*, dan Persamaan (10) menampilkan rumus untuk menghitung *F1-score*.

$$Akurasi = \frac{TTP+TTN}{TTP+TTN+TFP+TFN} \quad (7)$$

$$Presisi = \frac{TTP_{all}}{TTP_{all}+TFP_i} \quad (8)$$

$$Recall = \frac{TTP_{all}}{TTP_{all}+TFN_i} \quad (9)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (10)$$

**Keterangan:**

**Total True Positive (TTP):** Total data yang terklasifikasi dengan benar.

**Total True Negative (TTN):** Total data yang terklasifikasi negative dengan benar.

**Total False Positive (TFP):** Total data yang diprediksi benar, namun salah.

**Total False Negative (TFN):** Total data yang diprediksi salah, namun benar.

**III. HASIL DAN PEMBAHASAN**

**A. Pengumpulan Data**

Data penelitian berasal dari obrolan langsung YouTube selama acara Mata Najwa dengan tema "3 Bacapres Bicara Gagasan" pada 19 September 2023. Data diunduh menggunakan pustaka *chat-downloader* yang tersedia di GitHub. Pengumpulan data dilakukan saat tiga Bacapres, yaitu Anies Baswedan, Ganjar Pranowo, dan Prabowo Subianto, tampil pada acara tersebut. Rentang waktu untuk setiap Bacapres telah ditentukan. Total *dataset* adalah 77.397. *Dataset* disimpan dalam format CSV dengan kolom 'Nama', 'Pesan', dan 'Waktu'. Sampel dari *dataset* yang telah dikumpulkan dapat ditemukan dalam Tabel 1.

TABEL 1.  
SAMPSEL DATA LIVE CHAT

Nama	Pesan	Waktu
Muhammad Iqbal	Bagaimana Indonesia bisa menjadi negara SUPER POWER didunia?	00:27
Noval Praditya	anies for next presiden indonesia bismillah. amin :hand-pink-waving:	00:27
Trio AR	Apa yg akan beda dari pemerintahan Pak Jokowi bila jadi Presiden?	03:00

**B. Tahapan Preprocessing**


Setelah mendapatkan *dataset*, langkah berikutnya adalah *preprocessing*. Ini terdiri dari beberapa tahap, termasuk *Tokenization*, *Case folding*, *Cleansing*, konversi *Slang Word*, dan penghapusan *Stop Word*.

1) *Tokenization*: Peneliti melakukan *Tokenization* kata pada data *live chat* untuk memudahkan pemrosesan kata secara terperinci, dan hasilnya disimpan dalam bentuk *list string* ditunjukkan pada Gambar 2.



Gambar 2. Proses *Tokenization*

2) *Case Folding*: Proses ini melibatkan penyetaraan teks menjadi huruf kecil secara menyeluruh ditunjukkan pada Gambar 3.



Gambar 3. Proses *Case Folding*

3) *Cleansing*: Pada tahap ini, dilakukan pembersihan atau penyaringan teks dengan menghapus tanda baca, spasi berlebih, dan karakter selain huruf ditunjukkan pada Gambar 4.



Gambar 4. Proses *Cleansing*

4) *Convert Slang Word*: Dalam tahap ini, dilakukan penggantian kata-kata *Slang Word* dalam data menjadi bentuk formal dengan menggunakan daftar *Slang Word* dari laman GitHub secara terbuka. Peneliti terus memperbarui daftar *Slang Word* dengan menambahkan kata-kata baru seiring berjalannya penelitian. Misalnya, 'made' diubah menjadi 'buatan', 'kongkrit' menjadi 'nyata', dan 'dp' menjadi 'uang muka' ditunjukkan pada Gambar 5.



Gambar 5. Proses *Convert Slang Word*

5) *Stop Word Removal*: Pada tahap ini, kata-kata yang terdaftar dalam daftar *Stop Word* akan dihapus dari teks. Proses penghapusan mengacu pada daftar *Stop Word* yang didapatkan dari laman GitHub secara publik. Sebagaimana proses *Slang Word*, peneliti juga terus memperbarui daftar *Stop Word* dengan menambahkan kata-kata baru, seperti 'maka', 'anda', dan 'bagaimana' ditunjukkan pada Gambar 6.



Gambar 6. Proses *Stop Word Removal*

**C. Tahapan Labeling**

Setelah tahap *preprocessing*, langkah berikutnya adalah memberi label secara otomatis pada data *live chat* dengan mencocokkan kata-kata dalam kamus EmoLex. Proses ini melibatkan pencarian kata-kata dalam *dataset* yang sesuai dengan entri-entri dalam kamus EmoLex untuk menetapkan label emosi. Kamus EmoLex, asalnya dalam bahasa Inggris, diterjemahkan ke bahasa Indonesia sebelum digunakan dalam penelitian ini. Selama pencocokan, beberapa kata ditemukan memiliki lebih dari satu kelas emosi, yang terdokumentasi dalam Tabel 2.

TABEL 2.  
SAMPSEL DATA EMOLEX

Kata Inggris	Label EmoLex	Kata Indonesia
<i>honest</i>	marah	jujur
<i>candid</i>	antisipasi	jujur
<i>honest</i>	jiik	jujur
<i>honest</i>	takut	jujur
<i>candid</i>	gembira	jujur
<i>honest</i>	sedih	jujur
<i>candid</i>	kejutan	jujur
<i>honest</i>	percaya	jujur

Dalam Tabel 2, kata 'jujur' memiliki banyak nilai emosi dalam bahasa Indonesia dan juga memiliki beberapa padanan dalam bahasa Inggris. Keberagaman makna ini menjadi penting

dalam menetapkan label emosi. Peneliti menggunakan Google Translate dan DeepL Translator untuk mencari padanan yang tepat dalam bahasa Inggris, dan dengan bantuan Chat GPT, menentukan kelas emosi yang paling sesuai. Setelah normalisasi kamus kata EmoLex, hanya sebagian kecil *dataset* yang terlabel, dengan lebih dari separuh *dataset* tidak dikenali oleh EmoLex. Peneliti memilih untuk fokus pada data dengan satu kelas emosi untuk mendapatkan *dataset* yang lebih terfokus dan relevan dalam analisis emosi.

#### D. Tahapan Ekstraksi Fitur TF-IDF

Langkah berikutnya adalah dalam tahapan pemodelan. Data latih diekstraksi fiturnya menggunakan metode TF-IDF. Tujuannya adalah memastikan data latih dapat diidentifikasi dan diproses secara efektif saat menerapkan klasifikasi dengan algoritma Naive Bayes. Tabel 3 menampilkan *term frequency* dari setiap dokumen, *inverse document frequency* dari setiap term, dan hasil TF-IDF dari setiap dokumen di sebelah kanan.

TABEL 3.  
SAMPEL HASIL EKSTRAKSI FITUR TF-IDF

Term	D-1	D-2	D-3	D-4	IDF	TF-IDF D-1	TF-IDF D-2	TF-IDF D-3	TF-IDF D-4
amin	0	1/7	0	0	0.699	0	0.01	0	0
anies	0	1/7	0	0	0.699	0	0.01	0	0
baswedan	0	1/7	0	0	0.699	0	0.01	0	0
butuh	0	0	0	2/6	0.699	0	0	0	0.233
gagasan	0	0	0	1/6	0.699	0	0	0	0.117
ganjar	0	0	1/5	0	0.699	0	0	0.14	0
indonesia	1/4	1/7	1/5	0	0.222	0.056	0.032	0.044	0
janji	0	0	0	2/6	0.699	0	0	0	0.233
nyata	0	0	0	1/6	0.699	0	0	0	0.117
presiden	1/4	1/7	1/5	0	0.222	0.056	0.032	0.044	0
republik	1/4	1/7	1/5	0	0.222	0.056	0.032	0.044	0

#### E. Klasifikasi Multinomial Naive Bayes

Langkah berikutnya adalah tahap klasifikasi menggunakan Multinomial Naive Bayes. Fokus utamanya adalah pada perhitungan nilai probabilitas, Algoritma ini memperkirakan label data uji dengan membandingkannya dengan data latih, menggunakan probabilitas untuk menentukan kelas yang paling mungkin. Ini adalah metode klasifikasi yang efektif dan kuat dalam analisis data. Pengumpulan sampel data latih dan data uji dapat dilihat pada Tabel 4 dan 5.

TABEL 4.  
SAMPEL DATA LATIH

No	Data Live Chat	Label
1	teori, doang, praktek	antisipasi
2	anies, harapan, indonesia	gembira
3	anies, berbicara, kebohongan	jijik
4	kadang, heran, milih, dukung	kejutan
5	tukang, kebanyakan, berbohong	marah
6	butuh, gagasan, janji, butuh, janji, nyata	percaya
7	hostnya, hilang, senyumnya	sedih
8	raut, wajah, panik	takut

TABEL 5.  
SAMPEL DATA UJI

No	Data Live Chat	Label
1	ingat, janji, anies	percaya

Langkah selanjutnya adalah menghitung frekuensi kemunculan kata dalam data latih untuk setiap kategori emosi, termasuk antisipasi, gembira, jijik, kejutan, marah, percaya, sedih, dan takut. Hasil perhitungan ini terperinci dalam Tabel 6.

TABEL 6.  
FREKUENSI KATA PADA SETIAP KELAS

Kelas	Kata	Frekuensi	Jumlah
Antisipasi	teori	1	3
	doang	1	
	praktek	1	
Gembira	anies	1	3
	harapan	1	
	indonesia	1	
Jijik	anies	1	3
	berbicara	1	
	kebohongan	1	
Kejutan	kadang	1	4
	heran	1	
	milih	1	
	dukung	1	
Marah	tukang	1	3
	kebanyakan	1	
	berbohong	1	
Percaya	butuh	2	6
	janji	2	
	gagasan	1	
	nyata	1	
Sedih	hostnya	1	3
	hilang	1	
	senyumnya	1	
Takut	raut	1	3
	wajah	1	
	panik	1	

Setelah menyusun tabel frekuensi kata untuk setiap kelas, langkah berikutnya adalah menggabungkan semua kata tersebut untuk membentuk kamus kata dari data latih. Kamus kata dari seluruh data latih dapat dilihat dalam Tabel 7.

TABEL 7.  
KAMUS KATA KESELURUHAN DATA LATIH

No	Kamus Kata	Jumlah
1	teori, doang, praktek, anies, harapan, indonesia, berbicara, kebohongan, kadang, heran, milih, dukung, tukang, kebanyakan, berbohong, butuh gagasan, janji, nyata, hostnya, hilang, senyumnya, raut, wajah, panik	25

Setelah mendapatkan frekuensi kata untuk setiap kelas dan kamus kata dari seluruh data latih, langkah selanjutnya adalah menghitung peluang kelas. Karena setiap kelas berbeda dengan yang lain, peluang untuk setiap kelas adalah sama, yaitu 1/8. Selanjutnya, Langkah berikutnya melibatkan perhitungan probabilitas kata-kata yang berasal dari data uji Tabel 8.

TABEL 8.  
PROBABILITAS DATA UJI TERHADAP SETIAP KELAS

Kata	Antisipasi	Gembira	Jijik	Kejutan	Marah	Percaya	Sedih	Takut
ingat	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{4+25} = \frac{1}{30}$	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{6+25} = \frac{1}{31}$	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{3+25} = \frac{1}{28}$
janji	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{4+25} = \frac{1}{30}$	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{2+1}{6+25} = \frac{3}{31}$	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{3+25} = \frac{1}{28}$
anies	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{1+1}{3+25} = \frac{2}{28}$	$\frac{1+1}{3+25} = \frac{2}{28}$	$\frac{0+1}{4+25} = \frac{1}{30}$	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{6+25} = \frac{1}{31}$	$\frac{0+1}{3+25} = \frac{1}{28}$	$\frac{0+1}{3+25} = \frac{1}{28}$

Setelah diperoleh perhitungan probabilitas kata-kata terhadap kelas pada data uji, langkah selanjutnya adalah menghitung probabilitas keseluruhan data uji. Tahap awal melibatkan perolehan frekuensi kata pada data uji, yang terperinci pada Tabel 9.

TABEL 9.  
FREKUENSI KATA PADA DATA UJI

No	Kata	Frekuensi
1	raut	1
2	wajah	1
3	panik	1

Setelah berhasil mendapatkan frekuensi kata pada data uji, langkah berikutnya adalah menghitung probabilitas data uji terhadap setiap kelas emosi.

$$P(\text{antisipasi}, d1) = \frac{1}{8} \times \left(\frac{1}{28}\right)^3 = 0.00000569$$

$$P(\text{gembira}, d1) = \frac{1}{8} \times \left(\frac{1}{28}\right)^2 \times \left(\frac{2}{28}\right) = 0.000001138$$

$$P(\text{jijik}, d1) = \frac{1}{8} \times \left(\frac{1}{28}\right)^2 \times \left(\frac{2}{28}\right) = 0.000001138$$

$$P(\text{kejutan}, d1) = \frac{1}{8} \times \left(\frac{1}{30}\right)^3 = 0.00000569$$

$$P(\text{marah}, d1) = \frac{1}{8} \times \left(\frac{1}{28}\right)^3 = 0.00000569$$

$$P(\text{percaya}, d1) = \frac{1}{8} \times \left(\frac{1}{31}\right)^2 \times \left(\frac{3}{31}\right) = 0.000001258$$

$$P(\text{sedih}, d1) = \frac{1}{8} \times \left(\frac{1}{28}\right)^3 = 0.00000569$$

$$P(\text{takut}, d1) = \frac{1}{8} \times \left(\frac{1}{28}\right)^3 = 0.00000569$$

Dari perhitungan probabilitas dokumen terhadap kelas emosi, disimpulkan bahwa probabilitas untuk kelas "percaya" lebih tinggi, yaitu 0.000001258. Ini menunjukkan kecenderungan sampel data uji untuk diklasifikasikan sebagai kelas "percaya".

#### F. Pengujian

Pengujian penting dalam pengembangan sistem bertujuan untuk mengevaluasi akurasi dan kesesuaian hasil sistem. Penelitian ini melibatkan serangkaian pengujian yang mengevaluasi akurasi, presisi, recall dan f1-score algoritma Multinomial Naive Bayes dalam memprediksi label data uji. Hasil pengujian kritis untuk menilai kinerja algoritma dalam memprediksi kategori pada data uji yang beragam tersedia dalam Tabel 10.

TABEL 10.  
SAMPEL TABEL HASIL PREDIKSI

No	Pesan	Label Aktual	Label Prediksi
1	indonesia butuh etika tulus rakyat	percaya	percaya

2	ganjar maju indonesia sejahtera	antisipasi	antisipasi
3	merendahkan mc lawan bicara	marah	Marah
....	.....	.....	.....
2112	fanatisme dikesampingkan maka jwban realistis	takut	takut

Tabel 10 menampilkan sampel data prediksi, dengan kolom Label Aktual dan Label Prediksi. Label Aktual adalah hasil labeling, sedangkan Label Prediksi adalah hasil dari klasifikasi menggunakan algoritma Multinomial Naive Bayes. Ada total 2.112 prediksi data uji yang direpresentasikan dalam multi-class confusion matrix di Tabel 11.

TABEL 11.  
MULTI-CLASS CONFUSION MATRIX PENGUJIAN MODEL

Nilai Aktual	Nilai Prediksi							
	Antisip asi	Gembi ra	Jiji k	Kejut an	Mara h	Perca ya	Sedi h	Tak ut
Antisip asi	86	5	0	0	0	28	0	0
Gembir a	0	454	1	0	0	17	0	0
Jijik	0	3	101	0	1	20	0	0
Kejutan	0	1	0	2	0	15	0	0
Marah	0	0	1	0	63	30	0	0
Percaya	0	3	0	0	0	1017	0	0
Sedih	0	6	0	0	0	33	73	0
Takut	0	1	0	0	0	32	0	119

Untuk menghitung akurasi keseluruhan dari tabel 11 adalah dengan membagi total prediksi benar dengan total seluruh prediksi:

$$\text{Akurasi} = \frac{86 + 454 + 101 + 2 + 1017 + 73 + 119}{2112} = 90.67\%$$

Dari Tabel 11, hasil perbandingan antara label aktual dan label prediksi untuk setiap kelas digunakan untuk menghitung akurasi, presisi, recall, dan f1-score. Hasilnya dapat dilihat pada Tabel 12.

TABEL 12.  
PERHITUNGAN NILAI AKURASI, PRESISI, RECALL, DAN F1-SCORE

	Penguujian			
	Akurasi	Presisi	Recall	F1-Score
Antisipasi	$\frac{(86+1993)}{(86+1993+0+33)} = 98.44\%$	$\frac{(86)}{(86+0)} = 100\%$	$\frac{(86)}{(86+33)} = 72.27\%$	$2 \times \frac{1 \times 0.72}{1+0.72} = 83.90\%$
Gembira	$\frac{(454+1621)}{(454+1621+19+18)} = 98.25\%$	$\frac{(454)}{(454+19)} = 95.98\%$	$\frac{(454)}{(454+18)} = 96.19\%$	$2 \times \frac{0.96 \times 0.96}{0.96+0.96} = 96.08\%$
Jijik	$\frac{(101+1985)}{(101+1985+2+24)} = 98.77\%$	$\frac{(101)}{(101+2)} = 98.06\%$	$\frac{(101)}{(101+24)} = 80.80\%$	$2 \times \frac{0.98 \times 0.81}{0.98+0.81} = 88.60\%$
Kejutan	$\frac{(2+2094)}{(2+2094+0+16)} = 99.24\%$	$\frac{(2)}{(2+0)} = 100\%$	$\frac{(2)}{(2+16)} = 11.11\%$	$2 \times \frac{1 \times 0.11}{1+0.11} = 20.00\%$
Marah	$\frac{(63+2017)}{(63+2017+1+31)} = 98.48\%$	$\frac{(63)}{(63+1)} = 98.44\%$	$\frac{(63)}{(63+31)} = 67.02\%$	$2 \times \frac{0.98 \times 0.67}{0.98+0.67} = 79.75\%$
Percaya	$\frac{(1017+917)}{(1017+917+175+3)} = 91.57\%$	$\frac{(1017)}{(1017+175)} = 85.32\%$	$\frac{(1017)}{(1017+3)} = 99.71\%$	$2 \times \frac{0.85 \times 0.99}{0.85+0.99} = 91.95\%$
Sedih	$\frac{(73+2000)}{(73+2000+0+39)} = 98.15\%$	$\frac{(73)}{(73+0)} = 100\%$	$\frac{(73)}{(73+39)} = 65.18\%$	$2 \times \frac{1 \times 0.65}{1+0.65} = 78.92\%$
Takut	$\frac{(119+1960)}{(119+1960+0+33)} = 98.44\%$	$\frac{(119)}{(119+0)} = 100\%$	$\frac{(119)}{(119+33)} = 78.29\%$	$2 \times \frac{1 \times 0.78}{1+0.78} = 87.82\%$

Dari data yang tertera dalam Tabel 12, dapat diamati bahwa setiap kelas emosi memiliki nilai akurasi, presisi, *recall*, dan *f1-score* yang berbeda-beda. Kelas 'Kejutan' mengungguli dengan akurasi tertinggi sebesar 99.24% dan presisi mencapai 100%, menandakan kemampuan model untuk mengklasifikasikan kasus 'Kejutan' dengan tingkat ketepatan yang tinggi. Namun demikian, meskipun memiliki akurasi dan presisi yang tinggi, kelas 'Kejutan' menunjukkan nilai *recall* dan *f1-score* yang rendah, masing-masing hanya 11.11% dan 20.00%. Hal ini mengindikasikan adanya kesulitan dalam mengidentifikasi kasus positif untuk kelas ini. Sebaliknya, kelas 'Gembira' menunjukkan konsistensi dengan nilai akurasi, presisi, *recall*, dan *f1-score* yang baik, berturut-turut sebesar 98.25%, 95.98%, 96.19%, dan 96.08%. Evaluasi dari hasil analisis menyoroti perlunya peningkatan kinerja model dalam mengenali kasus 'Kejutan', sementara kelas 'Gembira' telah memperoleh penilaian yang memuaskan dan konsisten.

#### IV. KESIMPULAN

Berdasarkan hasil pengujian dan evaluasi dari aplikasi yang dikembangkan menggunakan dataset dan algoritma yang diusulkan, dapat disimpulkan bahwa tahap utama penelitian ini meliputi *Scraping*, *Preprocessing*, *Labeling*, *Modeling*, dan Klasifikasi Multinomial Naive Bayes. Dengan menerapkan ekstraksi fitur TF-IDF dan Algoritma Multinomial Naive Bayes dalam analisis emosi multi kelas, penelitian ini berhasil mencapai kinerja yang sangat baik, dengan tingkat akurasi mencapai 90.67%.

Selama proses labelisasi menggunakan kamus EmoLex, ditemukan distribusi emosi yang signifikan pada data, meskipun hasil pengujian tidak sepenuhnya mencerminkan respons emosional masyarakat karena adanya sesi tertentu dengan bakal calon presiden di mana masyarakat tidak secara spontan memberikan komentar tentang gagasan yang dibahas dalam sesi tersebut.

#### REFERENSI

- [1] M. Istianda and A. Zastrawati, "Evaluasi Penyelenggaraan Pemilu Serentak 2019 Kota Makassar," *Sebatik*, vol. 25, no. 1, pp. 92-101, 2021.
- [2] F. V. Sari and A. Wibowo, "Analisis Sentimen Pelanggan Toko Online Jd.Id Menggunakan Metode Naive Bayes Classifier Berbasis Konversi Ikon Emosi," *Jurnal SIMETRIS*, vol. 10, no. 2, pp. 681-686 2019.
- [3] D. Ariyanti and K. Iswardani, "Teks Mining untuk Klasifikasi Keluhan Masyarakat Menggunakan Algoritma Naive Bayes," *Jurnal IKRA-ITH Informatika*, vol. 4, no. 3, pp. 125-132, 2020.
- [4] K. A. Nugraha, "Analisis Sentimen Berbasis Emoticon pada Komentar Instagram Bahasa Indonesia Menggunakan Naive Bayes," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 7, no. 3, pp. 715-721 2021.
- [5] A. Mathur, P. Kubde, S. Vaidya, "Emotional Analysis using Twitter Data during Pandemic Situation: COVID-19," *Proceedings of the Fifth International Conference on Communication and Electronics Systems (ICCES 2020)*, 2020.
- [6] B. M. Akbar, A. T. Akbar, and R. Husaini, "Analisis Sentimen dan Emosi Vaksin Sinovac pada Twitter menggunakan Naive Bayes dan Valence Shifter," *Jurnal Teknologi Terpadu*, vol. 7, no. 2, pp. 83-92 2021.
- [7] A. A. Ningtyas, A. Solichin, and R. Pradana, "Analisis Sentimen Komentar Youtube Tentang Prediksi Resesi Ekonomi Tahun 2023 Menggunakan Algoritma Naive Bayes," *Bit Fakultas Teknologi Informasi*, vol. 20, no. 1, pp. 9-16, 2023.
- [8] A. Deolika, K. Kusriani, and E. T. Luthfi, "Analisis Pembobotan Kata pada Klasifikasi Text Mining," *Jurnal Teknologi Informasi*, vol. 3, no. 2, pp. 179-184, 2019.
- [9] G. Czarnek and D. Stillwell, "Two is better than one: Using a single emotion lexicon can lead to unreliable conclusions," *PLoS One*, vol. 17, no. 10, pp.1-22, 2022.
- [10] R. Asmara, M. F. Ardiansyah, and M. Anshori, "Analisa Sentiment Masyarakat terhadap Pemilu 2019 berdasarkan Opini di Twitter menggunakan Metode Naive Bayes Classifier," *Jurnal INOVTEK Polbeng - Seri Informatika*, vol. 5, no. 2, pp. 193-204, 2020.
- [11] D. D. Putri, G. F. Nama, and W. E. Sulistiono, "Analisis Sentimen Kinerja Dewan Perwakilan Rakyat (DPR) Pada Twitter Menggunakan Metode Naive Bayes Classifier," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 10, no. 1, pp. 34-40, 2022.
- [12] A. Wibowo and R. Wajhillah, "Information Retrieval Pemetaan Peta Jalan Penelitian Perguruan Tinggi Berbasis Dokumen Publikasi Ilmiah Dosen," *Jurnal Larik: Ladang Artikel Ilmu Komputer*, vol. 2, no. 2, pp. 49-56 2022.
- [13] M. U. Albab, Y. Karuniawati P, and M. N. Fawaiq, "Optimization of the Stemming Technique on Text preprocessing President 3 Periods Topic," *Jurnal Transformatika*, vol. 20, no. 2, pp. 1-10, 2023.
- [14] D. Arisandi, T. Sutrisno, and I. Kurniawan, "Klasifikasi Opini Masyarakat Di Twitter Tentang Kebocoran Data Yang Terjadi Di

- Indonesia Menggunakan Algoritma SVM,” *Jurnal Informatika Kaputama (JIK)*, vol. 7, no. 1, pp. 84-90, 2023.
- [15] F. A. J. Ayomi, and K. E. Dewi, “Analisis Emosi Pada Media Sosial Twitter Menggunakan Metode Multinomial Naive Bayes Dan Synthetic Minority Oversampling Technique,” *KOMPUTA: Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 2, pp. 9-19, 2023.
- [16] D. Septiani and I. Isabela, “Analisis Term Frequency Inverse Document Frequency (Tf-Idf) Dalam Temu Kembali Informasi Pada Dokumen Teks,” *SINTESIA*, vol. 1, no. 2, pp. 81-88, 2022.
- [17] N. Umar and M. A. Nur, “Application of Naive Bayes Algorithm Variations On Indonesian General Analysis Dataset for Sentiment Analysis,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 4, pp. 585-590, 2022.
- [18] A. Sabrani, I. W. G. P. W. Wedashwara, and F. Bimantoro, “Metode Multinomial Naive Bayes Untuk Klasifikasi Artikel Online Tentang Gempa di Indonesia (Multinomial Naive Bayes Method for Classification of Online Article About Earthquake in Indonesia),” *JTIKA*, vol. 2, no. 1, pp. 89-100, 2020.