

# Analisis Emosi Warganet pada Komentar Youtube Tentang Demo DPR 2025 Menggunakan Naive Bayes

*Emotion Analysis of Netizens on Youtube Comments Regarding the 2025 DPR Protests  
using Naive Bayes*

**M. Darwin<sup>1\*</sup>, Farid Wajidi<sup>2</sup>, A. Amirul Asnan Cirua<sup>3</sup>**

*Teknik Informatika, Universitas Sulawesi Barat*

*E-mail: <sup>1</sup>\*darwinkabut56@gmail.com, <sup>2</sup>faridwajidi@unsulbar.ac.id,*

*<sup>3</sup>amirulasnancirua@unsulbar.ac.id*

*\*Corresponding author*

Received 14 May 2026; Revised 18 June 2026; Accepted 1 July 2026

**Abstrak** - Demo DPR 2025 menimbulkan beragam reaksi di kalangan warganet yang terekspresikan melalui komentar di media sosial. Fenomena ini menghasilkan data komentar dalam jumlah besar dengan variasi ekspresi emosi yang beragam, sehingga menjadi sumber data yang relevan untuk menguji performa klasifikasi emosi pada data teks multikelas. Penelitian ini bertujuan untuk menganalisis emosi warganet terhadap demo tersebut menggunakan algoritma Naive Bayes dengan memanfaatkan komentar YouTube yang telah dibersihkan dan dilabeli ke dalam lima kategori emosi: Marah, Netral, Sedih, Senang, dan Takut. Hasil awal menunjukkan akurasi sebesar 85%, dengan performa tinggi pada kelas mayoritas (Marah) dan (sedih) namun rendah pada kelas senang, takut dan Netral. Permasalahan ini menunjukkan adanya ketidakseimbangan kelas yang menyebabkan bias prediksi terhadap emosi tertentu, yang masih jarang dibahas dalam penelitian serupa pada konteks sosial-politik Indonesia. Untuk mengatasi gap tersebut, penelitian ini menerapkan *Synthetic Minority Over-sampling Technique* (SMOTE) pada data training guna meningkatkan kemampuan model mengenali emosi minoritas. Setelah penerapan SMOTE, akurasi naik menjadi 89%. Hasil ini menunjukkan bahwa SMOTE mampu memperbaiki ketimpangan performa model tanpa bergantung pada akurasi keseluruhan. Kebaruan penelitian ini terletak pada penerapan SMOTE dalam analisis emosi warganet terhadap isu sosial-politik aktual di Indonesia, sehingga menghasilkan model yang lebih seimbang dan representatif dalam memahami persepsi publik di media sosial.

**Kata Kunci**- Naive Bayes, klasifikasi emosi, SMOTE, komentar YouTube, demo DPR 2025

**Abstract** - The 2025 DPR demonstration caused various reactions among netizens, which were expressed through comments on social media. This phenomenon generates large amounts of comment data with a wide variety of emotional expressions, making it a relevant data source to test the performance of emotion classification on multi-class text data. This study aims to analyze netizens' emotions towards the demo using the Naive Bayes algorithm by utilizing YouTube comments that have been cleaned and labeled into five categories of emotions: Angry, Neutral, Sad, Happy, and Afraid. Preliminary results showed an accuracy of 85%, with high performance in the majority (Angry) and (Sad) classes but low in the Happy, Afraid, and Neutral classes. This problem shows class imbalance that causes prediction bias against certain emotions, which is still rarely discussed in similar studies in the Indonesian socio-political context. To overcome this gap, this study applied the *Synthetic Minority Over-sampling Technique* (SMOTE) to the training data to improve the model's ability to recognize minority emotions. After the implementation of SMOTE, the accuracy rose to 89%. These results show that SMOTE is able to correct the model performance inequality without relying on overall accuracy. The novelty of this research lies in the application of SMOTE in the analysis of netizens' emotions to actual socio-political issues in Indonesia, resulting in a more balanced and representative model in understanding public perception on social media.

**Keywords** - Naive Bayes, emotion classification, SMOTE, YouTube comments, 2025 DPR demonstration

## **1. PENDAHULUAN**

Perkembangan internet telah mendorong media sosial menjadi sarana bagi masyarakat dalam menyampaikan opini terhadap berbagai isu sosial dan politik [1]. Fenomena Demo DPR 2025 memicu beragam respons warganet di platform YouTube melalui komentar yang mencerminkan opini, kritik, serta emosi publik terhadap kebijakan pemerintah. Analisis emosi terhadap sentimen warganet menjadi urgen karena platform digital kini berfungsi sebagai barometer opini publik yang dapat menjadi indikator dini terhadap potensi gejolak sosial [2]. Pemahaman pola emosi warganet dapat membantu stakeholder pemerintahan dalam merumuskan komunikasi publik yang lebih efektif dan responsif terhadap aspirasi masyarakat [3].

Analisis sentimen pada komentar YouTube menghadapi tantangan ketidakseimbangan data (imbalanced data), di mana distribusi kelas emosi seringkali tidak merata dengan dominasi kelas tertentu pada sebagian besar dataset [4]. Ketidakseimbangan ini berpotensi menghasilkan model klasifikasi yang bias dan gagal mengenali pola emosi pada kelas minoritas [5]. Selain itu, sifat komentar YouTube yang informal, mengandung singkatan, bahasa gaul, dan emoticon menambah kompleksitas preprocessing dan ekstraksi fitur [6].

Kebutuhan metode klasifikasi yang akurat sekaligus efisien secara komputasional menjadi prioritas dalam menghadapi volume data real-time yang masif [7]. Berbagai metode telah diterapkan dalam analisis sentimen media sosial dengan hasil yang beragam. Metode berbasis transfer learning mencapai akurasi tertinggi dibandingkan dengan metode leksikon maupun machine learning konvensional, namun disertai kompleksitas interpretasi yang lebih tinggi dan ketergantungan pada konteks aplikasi [8]. Support Vector Machine (SVM) menunjukkan performa baik pada data seimbang, namun mengalami degradasi signifikan pada data tidak seimbang [9]. Sebaliknya, Naive Bayes Classifier menawarkan keunggulan dengan waktu training yang cepat dan kebutuhan memori yang minimal, menjadikannya kandidat yang tepat untuk analisis teks berskala besar [10].


Penelitian terkait analisis sentimen pada isu-isu politik Indonesia telah banyak dilakukan melalui berbagai platform digital. Penelitian [11] menunjukkan bahwa model analisis sentimen lintas domain pada komentar YouTube berbahasa Indonesia dapat mencapai akurasi yang kompetitif, meskipun tantangan bahasa informal seperti singkatan dan campur kode tetap menjadi hambatan utama dalam proses preprocessing. Temuan ini relevan dengan konteks Demo DPR 2025 yang komentar-komentarnya didominasi oleh ekspresi emosional informal warganet. Sementara itu, penelitian [12] membuktikan bahwa algoritma Naive Bayes mampu mengklasifikasikan sentimen pada teks berbahasa Indonesia terkait kebijakan pemerintah dengan akurasi yang memadai, memperkuat kelayakan penggunaan metode ini pada penelitian yang melibatkan isu-isu politik domestik. Sejalan dengan itu, penelitian [13] juga mengonfirmasi efektivitas Naive Bayes pada komentar YouTube berbahasa Indonesia dalam topik ekonomi, semakin memperkuat kelayakan metode ini untuk diterapkan pada konteks serupa. Pada ranah analisis emosi, penelitian [14] berhasil mengklasifikasikan emosi pada live chat YouTube terkait konteks politik Indonesia menggunakan pendekatan leksikon EmoLex dan algoritma Multinomial Naive Bayes dengan akurasi mencapai 90,67%, yang secara langsung memperkuat urgensi pengembangan sistem analisis emosi berbasis teks untuk konteks politik Indonesia terkini. Adapun penelitian [15] mengeksplorasi analisis sentimen pemilu presiden Indonesia menggunakan klasifikasi multi-label berbasis deep learning pada ulasan online, semakin mengukuhkan pentingnya sistem klasifikasi emosi untuk konteks politik domestik sebagaimana yang menjadi fokus penelitian ini.

Meskipun berbagai penelitian telah mengeksplorasi analisis sentimen pada media sosial Indonesia, masih terdapat gap yang signifikan. Pertama, penelitian sebelumnya seperti [16] berfokus pada klasifikasi sentimen biner (positif-negatif) atau tiga kelas tanpa menangani ketidakseimbangan data secara eksplisit. Kedua, belum ada penelitian yang menerapkan kombinasi Naive Bayes dengan teknik oversampling SMOTE sebagai strategi penanganan imbalanced data untuk klasifikasi multi-kelas emosi (marah, sedih, senang, takut, netral) pada dataset komentar YouTube berbahasa Indonesia dalam konteks politik domestik terkini seperti

Demo DPR 2025. Penelitian ini hadir untuk mengisi gap tersebut, di mana SMOTE digunakan sebagai langkah preprocessing tambahan guna meningkatkan performa klasifikasi Naive Bayes, bukan sebagai metode utama.

Penelitian ini bertujuan untuk menganalisis emosi warganet pada komentar YouTube tentang Demo DPR 2025 menggunakan algoritma Naive Bayes yang dikombinasikan dengan SMOTE untuk mengatasi ketidakseimbangan data. Secara spesifik, penelitian ini bertujuan: (1) menganalisis karakteristik dan distribusi emosi warganet (marah, sedih, senang, takut, dan netral) pada komentar YouTube terkait Demo DPR 2025, (2) menerapkan SMOTE untuk menyeimbangkan distribusi data antarkelas emosi sebelum proses klasifikasi. Kontribusi penelitian ini meliputi: penerapan klasifikasi multi-class emotion (5 kelas) dalam konteks politik domestik terkini dan implementasi SMOTE untuk menangani ketidakseimbangan data pada dataset emosi berbahasa Indonesia.

## 2. METODE PENELITIAN



**Gambar 1.** Alur Penelitian

### 2.1 Pengumpulan Dataset

Tahap pengumpulan dataset diawali dengan studi literatur untuk memahami konsep analisis emosi warganet, serta penelitian terdahulu terkait klasifikasi emosi pada media sosial. Data penelitian diperoleh dari kolom komentar video YouTube kanal Liputan6 dan menghasilkan 2.134 komentar dari tanggal 29-08-2025 sampai tanggal 07-09-2025. Pengumpulan dilakukan secara otomatis menggunakan bahasa pemrograman Python dengan memanfaatkan YouTube Data API v3, sehingga peneliti dapat memperoleh komentar publik secara langsung, efisien, dan terstruktur.

### 2.2 Pelabelan Data

Tahap pelabelan data emosi dilakukan secara manual oleh Ibu Harlinda Sari, S.Pd., seorang guru Bahasa Indonesia di SMK Labuang, dan Ibu Nurlinda, S.Pd., seorang guru SD Negeri Puncak Landi Baru. Setiap komentar dianalisis secara cermat dengan memperhatikan makna leksikal dan konteks kalimat untuk menentukan kategori emosi yang paling tepat. Untuk mengukur konsistensi pelabelan antar-penilai, dilakukan pengujian *Inter-Rater Reliability* menggunakan Cohen's Kappa. Hasil pengujian menunjukkan nilai Cohen's Kappa sebesar 0,82

yang termasuk dalam kategori *Almost Perfect Agreement*, sehingga menunjukkan tingkat kesepakatan yang sangat tinggi antara kedua penilai. Nilai tersebut mengindikasikan bahwa proses pelabelan memiliki konsistensi yang baik dan dapat meminimalkan subjektivitas dalam pemberian label emosi. Oleh karena itu, hasil pelabelan digunakan sebagai data acuan (*ground truth*) dalam proses pelatihan dan evaluasi model klasifikasi Naive Bayes pada penelitian analisis emosi warganet.

Contoh data komentar hasil labeling ditampilkan pada Tabel 1 sebagai representasi dataset yang digunakan dalam penelitian ini.

**Tabel 1.** Sampel Komentar Warganet per Kelas Emosi

| No | Emosi  | Komentar                             |
|----|--------|--------------------------------------|
| 1  | Marah  | bakar kantor pajak                   |
| 2  | Takut  | rakyat kalau ngamuk ngeri            |
| 3  | Sedih  | korban jiwa sangat anarkis indonesia |
| 4  | Senang | mantap saudara                       |
| 5  | Netral | makassar memang                      |

### 2.3 Preprocessing Teks

Sebelum proses klasifikasi dilakukan, data komentar terlebih dahulu melewati tahap preprocessing. Tahap ini bertujuan untuk meningkatkan kualitas data dengan menghilangkan noise serta menyeragamkan bentuk teks, sehingga data menjadi lebih siap untuk dianalisis. Dalam penelitian ini preprocessing teks terdiri dari beberapa tahapan yaitu :

- case folding*  
mengubah seluruh karakter menjadi huruf kecil agar konsistensi penulisan terjaga.
- tokenisasi*  
memecah komentar menjadi kata-kata atau token.
- stopword* ,kata-kata umum dalam dataset yang dianggap tidak relevan, misalnya dan, yang, dari, atau
- Slang mapping* dilakukan untuk mengubah kata-kata gaul atau singkatan menjadi bentuk baku sehingga model dapat memahami maknanya dengan benar.
- repeated character handling*  
mengurangi huruf yang diulang berlebihan pada kata-kata emosional.
- stemming*  
mengubah kata-kata berimbuhan menjadi bentuk dasarnya

Sebelum dan sesudah Preprocessing bisa dilihat pada tabel 2 dibawah ini.

**Tabel 2.** Sebelum dan Sesudah Preprocessing Teks

| Tahapan      | Komentar asli                                                                | Hasil                                                                                                |
|--------------|------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------|
| Case Folding | Mantap makassar ewako bakarr semua gedung itu selanjutnya gedung dpr lainnya | mantap makassar ewako bakarr semua gedung itu selanjutnya gedung dpr lainnya                         |
| Tokenisasi   | mantap makassar ewako bakarr semua gedung itu selanjutnya gedung dpr lainnya | ['mantap','makassar','ewako','bakarr','semua','gedung','itu','selanjutnya','gedung','dpr','lainnya'] |

|                   |           |                                                                                                                |                                                                                                          |
|-------------------|-----------|----------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------|
| Stopword          |           | ['mantap', 'makassar', 'ewako', 'bakarr', 'semua', 'gedung', 'itu', 'selanjutnya', 'gedung', 'dpr', 'lainnya'] | ['mantap', 'makassar', 'ewako', 'bakarr', 'semua', 'gedung', 'selanjutnya', 'gedung', 'dpr', 'lainnya']  |
| Slang Mapping     |           | ['mantap', 'makassar', 'ewako', 'bakarr', 'semua', 'gedung', 'selanjutnya', 'gedung', 'dpr', 'lainnya']        | ['mantap', 'makassar', 'berani', 'bakarr', 'semua', 'gedung', 'selanjutnya', 'gedung', 'dpr', 'lainnya'] |
| Repeated handling | character | ['mantap', 'makassar', 'berani', 'bakarr', 'semua', 'gedung', 'selanjutnya', 'gedung', 'dpr', 'lainnya']       | ['mantap', 'makassar', 'berani', 'bakarr', 'semua', 'gedung', 'selanjutnya', 'gedung', 'dpr', 'lainnya'] |
| Stemming          |           | ['mantap', 'makassar', 'berani', 'bakarr', 'semua', 'gedung', 'selanjutnya', 'gedung', 'dpr', 'lainnya']       | mantap makassar berani bakar semua gedung lanjut gedung dpr lain                                         |

#### 2.4 Pembagian data

Setelah tahap preprocessing adalah melakukan pemisahan dataset menjadi data latih dan data uji. Penelitian ini menggunakan tiga skenario evaluasi model, yaitu pembagian data 80:20, 70:30, dan Stratified 5-Fold Cross Validation. Pendekatan ini bertujuan untuk mengukur stabilitas dan konsistensi performa algoritma dalam klasifikasi emosi berdasarkan variasi distribusi data latih dan data uji.

#### 2.5 Representasi Teks (TF-IDF)

Selanjutnya data teks yang telah dipisahkan direpresentasikan ke dalam bentuk numerik menggunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF). Metode ini digunakan untuk memberikan bobot pada setiap kata berdasarkan tingkat kepentingannya dalam keseluruhan dokumen, sehingga kata yang sering muncul pada suatu dokumen namun jarang ditemukan pada dokumen lain akan memiliki bobot yang lebih tinggi.

#### 2.6 SMOTE

Dataset komentar menunjukkan ketidakseimbangan kelas yang signifikan, di mana label “Marah” mendominasi jumlah data, sedangkan kelas minoritas memiliki sampel yang sedikit. Untuk mengatasinya, diterapkan teknik SMOTE (*Synthetic Minority Over-sampling Technique*) atau penyeimbangan data. Dengan demikian, distribusi label di data latih menjadi lebih seimbang, memungkinkan model untuk belajar pola dari semua kelas emosi secara merata.

#### 2.7 Naïve Bayes training

Tahap *Naive Bayes Training*, menggunakan multinomial Naive Bayes, merupakan proses pelatihan model klasifikasi menggunakan data latih yang telah dipersiapkan sebelumnya melalui tahap representasi fitur menggunakan TF-IDF serta penyeimbangan data dengan metode SMOTE. Pada tahap ini, algoritma Naive Bayes mempelajari pola hubungan antara fitur kata dan label emosi pada setiap komentar. Proses pelatihan dilakukan dengan menghitung probabilitas kemunculan kata pada masing-masing kelas serta probabilitas awal dari setiap kelas emosi berdasarkan data latih. Hasil dari tahap ini adalah terbentuknya model klasifikasi yang telah

memahami karakteristik setiap kategori emosi. Model yang telah dilatih kemudian digunakan pada tahap prediksi untuk mengklasifikasikan data uji yang belum pernah dipelajari sebelumnya.

## 2.8 Model

Pada tahap model, dilakukan penyimpanan hasil pelatihan yang telah diperoleh dari proses Naïve Bayes Training sebelum memasuki tahap evaluasi model. Model yang terbentuk menggunakan algoritma Naïve Bayes berisi parameter probabilitas setiap kelas emosi serta probabilitas kemunculan kata pada masing-masing kelas. Pada tahap ini, model telah selesai mempelajari pola dari data latih dan siap digunakan untuk melakukan proses klasifikasi pada data uji. Model tersebut kemudian menjadi dasar dalam tahap evaluasi untuk mengukur tingkat kinerja dan akurasi sistem.

## 2.9 Evaluasi model

Evaluasi dilakukan untuk mengukur performa model Naïve Bayes setelah proses pelatihan. Program menghitung nilai akurasi, serta menampilkan *classification report* yang berisi *precision*, *recall*, dan *F1-score* untuk masing-masing kelas emosi. Nilai akurasi diperoleh langsung dari fungsi *accuracy\_score* yang menghitung perbandingan antara jumlah prediksi benar dengan total data uji, sesuai rumus berikut:

$$Akurasi = \frac{\text{Prediksi benar}}{\text{Total tata uji}} \times 100\% \quad (1)$$

$$Precision = \frac{\text{Prediksi benar pada suatu kelas}}{\text{Total prediksi pada kelas tersebut}} \times 100\% \quad (2)$$

$$Recall = \frac{\text{Prediksi benar pada suatu kelas}}{\text{Total data aktual pada kelas tersebut}} \times 100\% \quad (3)$$

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Hasil *classification report* memberikan gambaran detail mengenai seberapa baik model mengenali setiap kategori emosi. Evaluasi juga dilakukan dengan mencoba beberapa komentar baru untuk melihat kemampuan model dalam menggeneralisasi data yang belum pernah dipelajari.

## 2.10 Parameter Pengujian

Penelitian ini menggunakan beberapa parameter utama pada setiap tahapan pengolahan data. Pada tahap pembagian data digunakan *test\_size=0,2*, *random\_state=42*, dan *stratify=y* untuk menjaga konsistensi pembagian serta distribusi kelas. Representasi fitur TF-IDF menggunakan *max\_features=5000* untuk membatasi jumlah fitur yang digunakan. Pada tahap penyeimbangan data, SMOTE menerapkan *k\_neighbors=5* untuk menghasilkan data sintetis berdasarkan lima tetangga terdekat. Selanjutnya, proses klasifikasi menggunakan Multinomial Naive Bayes dengan parameter *alpha=1,0* sebagai smoothing guna menjaga stabilitas probabilitas model.

## 2.11 Pengujian algoritma SVM

Pengujian SVM dilakukan sebagai metode pembandingan terhadap Naive Bayes untuk mengevaluasi performa klasifikasi pada dataset yang sama. Perbandingan dilakukan berdasarkan nilai akurasi guna mengetahui algoritma yang memiliki kinerja terbaik dalam mengklasifikasikan data secara lebih optimal dan konsisten.

### 3. HASIL DAN PEMBAHASAN

Hasil serta pembahasan dibagi menjadi 2 fase yaitu. Fase 1 klasifikasi naïve bayes, dan fase 2 penerapan SMOTE karena hasil dari klasifikasi naïve bayes tidak seimbang, tabel dibawah menggunakan rasio data 80:20

#### 3.1. Fase 1

Hasil pengujian menggunakan algoritma Naïve Bayes.


**Tabel 3.** Hasil Klasifikasi Naïve Bayes

| Emosi                | Precision | Recall | F1-Score | Support |
|----------------------|-----------|--------|----------|---------|
| Marah                | 0.73      | 0.78   | 0.82     | 87      |
| Netral               | 0.64      | 0.25   | 0.36     | 28      |
| Sedih                | 0.92      | 0.97   | 0.95     | 80      |
| Senang               | 0.93      | 0.74   | 0.82     | 38      |
| Takut                | 0.98      | 0.93   | 0.95     | 67      |
| Akurasi              |           |        | 0.85     | 300     |
| Rata-rata Makro      | 0.84      | 0.76   | 0.78     | 300     |
| Rata-rata Tertimbang | 0.85      | 0.85   | 0.84     | 300     |

Berdasarkan Tabel 3, proses klasifikasi emosi menggunakan algoritma Naïve Bayes menghasilkan tingkat akurasi sebesar 85%. Nilai ini menunjukkan bahwa model telah mampu mengklasifikasikan sebagian besar data uji dengan baik, hasil classification report, kelas marah menunjukkan performa yang cukup baik dengan nilai recall sebesar 93% dan F1-Score sebesar 82%, yang mengindikasikan bahwa sebagian besar data berlabel marah berhasil dikenali oleh model. Kelas sedih dan takut memiliki performa yang sangat baik dengan nilai precision dan recall yang tinggi, masing-masing sebesar 92% dan 97% untuk kelas sedih, serta 98% dan 93% untuk kelas takut.

Sementara itu, kelas senang juga menunjukkan kinerja yang baik dengan precision sebesar 93% dan recall sebesar 74%, sehingga sebagian besar data pada kelas ini dapat terklasifikasi dengan benar. Namun, kelas netral memiliki performa yang relatif lebih rendah dibandingkan kelas lainnya, dengan recall sebesar 25% dan F1-Score sebesar 36%. Berdasarkan hasil analisis, menunjukkan data netral yang belum dapat dikenali dengan baik oleh model karena faktor data yg sedikit dan data yg tidak seimbang. Secara keseluruhan, hasil ini menunjukkan bahwa model Naïve Bayes memiliki performa yang cukup baik dalam mengklasifikasikan emosi, meskipun masih terdapat kelemahan pada kelas tertentu, khususnya kelas netral, yang kemungkinan disebabkan oleh kemiripan fitur dengan kelas lain atau distribusi data yang belum sepenuhnya seimbang. Sedangkan hasil akurasi jika menggunakan algoritma SVM mencapai akurasi hingga 84%. Jika dibandingkan, algoritma Naïve Bayes sedikit lebih baik.

Parameter yang digunakan meliputi pembagian data menggunakan test\_size 0,2 dengan random\_state 42 dan stratified split. Ekstraksi fitur dilakukan menggunakan TF-IDF dengan max\_features sebesar 5000. Penyeimbangan data dilakukan menggunakan SMOTE dengan random\_state 42 dan k\_neighbors 5. Model klasifikasi menggunakan Multinomial Naive Bayes dengan parameter alpha sebesar 1,0.



**Gambar 2.** Confusion Matrix Hasil Klasifikasi Naïve Bayes

Berdasarkan confusion matrix pada gambar 2 hasil klasifikasi Naïve Bayes, model menunjukkan kinerja yang cukup baik pada beberapa kelas emosi, khususnya kelas marah, sedih, dan takut. Pada kelas marah, sebanyak 81 data berhasil diklasifikasikan dengan benar, sementara sebagian kecil data lainnya salah diprediksi ke kelas netral, sedih, dan takut.

Pada kelas netral, performa model masih tergolong rendah, di mana hanya 7 data yang berhasil dikenali dengan benar, sedangkan sebagian besar data lainnya salah diklasifikasikan sebagai marah, serta beberapa sebagai sedih dan senang. Pola ini menunjukkan bahwa model masih mengalami kesulitan dalam membedakan emosi netral dengan emosi lainnya, khususnya marah, yang kemungkinan disebabkan oleh kemiripan karakteristik fitur atau penggunaan kata dalam teks.

Sementara itu, kelas sedih menunjukkan performa yang sangat baik dengan 78 data berhasil diprediksi dengan benar dan hanya sedikit kesalahan klasifikasi. Kelas senang juga memiliki kinerja yang cukup baik dengan 28 data yang diklasifikasikan dengan benar, meskipun masih terdapat sejumlah data yang salah diprediksi sebagai marah.

Pada kelas takut, model mampu mengklasifikasikan 62 data dengan benar, dengan hanya sedikit kesalahan ke kelas lain. Secara keseluruhan, hasil ini menunjukkan bahwa model memiliki kemampuan yang baik dalam mengenali emosi dengan ciri yang kuat seperti sedih dan takut, namun masih memiliki kelemahan dalam membedakan kelas netral akibat kemiripan fitur dengan kelas lainnya.

### 3.2. Fase 2

Hasil setelah penerapan SMOTE.

**Tabel 4.** Hasil Klasifikasi Naïve Bayes Setelah SMOTE

| Emosi                | Precision | Recall | F1-Score | Support |
|----------------------|-----------|--------|----------|---------|
| Marah                | 0.85      | 0.85   | 0.85     | 87      |
| Netral               | 0.58      | 0.54   | 0.56     | 28      |
| Sedih                | 0.98      | 1.00   | 0.99     | 80      |
| Senang               | 0.88      | 0.92   | 0.90     | 38      |
| Takut                | 0.95      | 0.93   | 0.94     | 67      |
| Akurasi              |           |        | 0.89     | 300     |
| Rata-rata Makro      | 0.85      | 0.85   | 0.85     | 300     |
| Rata-rata Tertimbang | 0.88      | 0.89   | 0.89     | 300     |




Berdasarkan tabel 4 menunjukkan hasil kinerja model Naïve Bayes setelah penerapan teknik SMOTE pada dataset. Secara umum, performa model mengalami perbaikan pada kelas minoritas. Kelas Sedih memiliki nilai *recall* tertinggi sebesar 100% menunjukkan bahwa data dengan label sedih berhasil terklasifikasi dengan benar. Kelas Netral yang sebelumnya sulit dikenali kini berhasil terdeteksi oleh model.

Secara keseluruhan, akurasi model sebesar 89% menunjukkan bahwa SMOTE membantu meningkatkan kemampuan model dalam mengenali variasi emosi, terutama pada kelas dengan jumlah data kecil, sehingga menghasilkan distribusi prediksi yang lebih seimbang dibandingkan sebelum SMOTE diterapkan.

Setelah penerapan SMOTE, model Naïve Bayes menunjukkan peningkatan performa yang cukup signifikan dengan akurasi mencapai 89%. Hasil ini menunjukkan bahwa sebagian besar data uji berhasil diklasifikasikan dengan baik oleh model. Berdasarkan classification report, kelas sedih memperoleh performa terbaik dengan nilai precision sebesar 98%, recall 100%, dan F1-Score 99%, yang menandakan bahwa model mampu mengenali seluruh data pada kelas ini secara sangat akurat. Kelas takut dan senang juga mengalami peningkatan performa yang signifikan dengan F1-Score masing-masing sebesar 94% dan 90%.


Sementara itu, kelas marah menunjukkan performa yang stabil dengan nilai precision, recall, dan F1-Score sebesar 85%. Namun, kelas netral masih memiliki performa yang relatif lebih rendah dengan F1-Score sebesar 56%, yang menunjukkan bahwa masih terdapat kesulitan dalam mengklasifikasikan kelas tersebut. Dari hasil analisis menunjukkan performa klasifikasi pada emosi netral masih relatif rendah karena karakteristik fitur pada kelas tersebut cenderung kurang spesifik serta memiliki kemiripan dengan kelas emosi lain. Hasil akurasi jika menggunakan algoritma SVM+SMOTE mencapai akurasi hingga 87%, Secara keseluruhan penerapan SMOTE pada algoritma Naïve Bayes lebih unggul dari hasil akurasi.



**Gambar 3.** Confusion Matrix Hasil Naïve Bayes Setelah SMOTE

Berdasarkan confusion matrix pada gambar 3 menunjukkan performa yang sangat baik pada beberapa kelas emosi. Kelas sedih memiliki jumlah prediksi benar tertinggi dengan 80 data, diikuti oleh kelas marah sebanyak 74 data dan kelas takut sebanyak 62 data yang berhasil diklasifikasikan dengan benar.

Kelas senang juga menunjukkan kinerja yang cukup baik dengan 35 data yang terklasifikasi dengan benar, meskipun masih terdapat kesalahan prediksi ke kelas marah. Namun, kelas netral memiliki performa yang paling rendah dengan hanya 15 data yang berhasil dikenali dengan benar, sementara sebagian lainnya salah diklasifikasikan ke kelas marah.



**Gambar 4.** Diagram emosi

Diagram di atas menunjukkan distribusi emosi, dataset didominasi oleh emosi marah sebanyak 432 data (28,8%), diikuti sedih sebanyak 399 data (26,6%), takut sebanyak 336 data (22,4%), senang sebanyak 191 data (12,7%), dan netral sebanyak 141 data (9,4%). Distribusi ini menunjukkan bahwa mayoritas komentar warganet cenderung mengandung emosi negatif, khususnya marah, sedih, dan takut, sedangkan emosi netral dan senang memiliki proporsi yang lebih rendah. Total semua data sebanyak 1499 Komentar yang digunakan untuk klasifikasi Naïve Bayes.

### 3. 3 Hasil Analisis Kesalahan Klasifikasi Netral

Analisis kualitatif dilakukan untuk mengidentifikasi faktor-faktor yang menyebabkan model Naive Bayes menghasilkan prediksi yang berbeda dari label aktual. Beberapa komentar berlabel Netral ditemukan salah diklasifikasikan menjadi emosi Marah maupun Senang. Tabel 5 menyajikan beberapa contoh komentar berlabel Netral yang mengalami kesalahan klasifikasi.

**Tabel 5.** Kesalahan Klasifikasi Netral

| Komentar                             | Label Aktual | Prediksi Model |
|--------------------------------------|--------------|----------------|
| kapan gedung dpr di jakarta di bakar | Netral       | Marah          |
| ini baru demo mantap makassar        | Netral       | Senang         |
| presiden buat gaduh indonesia        | Netral       | Marah          |

Berdasarkan tabel 5 menunjukkan bahwa model Naive Bayes masih mengalami kesulitan dalam membedakan komentar netral yang mengandung kata-kata berkonotasi emosional. Pada komentar "kapan gedung dpr di jakarta di bakar", model mengklasifikasikan komentar sebagai emosi marah karena adanya kata "bakar" yang sering muncul pada komentar bernada kemarahan dalam data pelatihan. Pada komentar "ini baru demo mantap makassar", model memprediksi emosi senang akibat keberadaan kata "mantap" yang memiliki asosiasi kuat dengan ekspresi positif. Sementara itu, komentar "presiden buat gaduh indonesia" diprediksi sebagai marah karena kata "gaduh" memiliki kecenderungan muncul pada komentar yang berisi kritik atau ketidakpuasan.

### 3.4 Hasil Pembagian data

Hasil proses pengujian tiga skenario evaluasi, yaitu pembagian data 80:20, pembagian data 70:30, dan 5-Fold Cross Validation untuk mengukur performa model secara menyeluruh pada berbagai pembagian data latih dan data uji.

**Tabel 6.** Hasil akurasi

| Metode Evaluasi         | Hasil Akurasi |
|-------------------------|---------------|
| Split Data 80:20        | 85%           |
| Split Data 70:30        | 84%           |
| 5-Fold Cross Validation | 83%           |

Berdasarkan tabel 6 menunjukkan model memperoleh akurasi tertinggi pada split data 80:20 sebesar 85.%, sedangkan pada split data 70:30 diperoleh akurasi 84.%. Sementara itu, rata-rata akurasi pada 5-Fold Cross Validation sebesar 83.%. Perbedaan hasil yang relatif kecil menunjukkan bahwa model memiliki performa yang cukup stabil pada berbagai metode evaluasi.



Gambar 5. Wordcloud komentar Warganet

Berdasarkan wordcloud pada gambar 5 memperlihatkan wordcloud keseluruhan komentar warganet yang mencerminkan lima kategori emosi, yaitu marah, senang, sedih, takut, dan netral. Kata “rakyat” menjadi yang paling dominan, diikuti “negara”, “senang”, “makassar”, “indonesia”, “keadaan”, dan “demo”. Dominasi tersebut menunjukkan fokus utama komentar pada masyarakat, kondisi negara, dan situasi demonstrasi. Kata “senang” merepresentasikan emosi positif, sedangkan kata seperti “takut”, “korban”, dan “hancur” mencerminkan emosi negatif seperti marah, sedih, dan takut. Sementara itu, kata informatif seperti “negara” dan “keadaan” menggambarkan emosi netral. Secara keseluruhan, wordcloud menunjukkan beragam respons emosional publik terhadap dinamika sosial-politik.

#### 4. KESIMPULAN DAN SARAN

Kesimpulan atas Penelitian ini algoritma Naive Bayes terbukti cukup baik dalam menganalisis komentar warganet terkait demonstrasi DPR 2025 berdasarkan komentar YouTube. Hasil awal tanpa penerapan SMOTE (Fase 1) mencapai akurasi sebesar 85%, dengan kinerja yang baik pada kelas *sedih* (recall 93%, F1-Score 82%) serta *marah* dan *takut* yang juga menunjukkan performa tinggi. Namun, kelas *netral* masih memiliki performa yang relatif rendah dengan recall sebesar 25% dan F1-Score 36%, dari hasil analisis yang menunjukkan adanya kesulitan model dalam mengenali kelas tersebut secara optimal.

Untuk mengatasi ketidakseimbangan data, teknik SMOTE diterapkan pada data latih (Fase 2). Setelah penerapan SMOTE, akurasi model meningkat menjadi 89%. Selain itu, terjadi peningkatan kemampuan model dalam mengenali beberapa kelas, seperti *sedih* (recall 100%), *senang* (92%), dan *takut* (93%), serta performa *marah* yang tetap stabil pada 85%. Kelas *netral* juga mengalami peningkatan menjadi 54%, meskipun masih menjadi kelas dengan performa terendah.

Kombinasi Naïve Bayes dengan SMOTE mampu meningkatkan kemampuan generalisasi model dan menghasilkan distribusi prediksi yang lebih seimbang. Hal ini menunjukkan bahwa teknik penyeimbangan data memiliki peran penting dalam meningkatkan performa klasifikasi, khususnya pada dataset dengan distribusi kelas yang tidak merata.

Saran untuk penelitian selanjutnya adalah menambahkan kategori emosi yang lebih beragam agar analisis respons warganet menjadi lebih mendalam dan representatif. Penambahan variasi emosi dapat memberikan pemahaman yang lebih komprehensif terhadap dinamika opini publik serta meningkatkan kemampuan model dalam mengidentifikasi ekspresi emosional secara lebih spesifik. Penelitian selanjutnya juga disarankan untuk meningkatkan kemampuan model dalam mengidentifikasi komentar berlabel Netral yang masih berpotensi mengalami kesalahan prediksi akibat keterbatasan metode berbasis pembobotan kata TF-IDF. Penggunaan pendekatan deep learning, seperti LSTM, Bi-LSTM, atau IndoBERT, serta ekstraksi fitur yang mempertimbangkan konteks kalimat secara utuh dapat menjadi alternatif untuk meningkatkan akurasi klasifikasi emosi dan mengurangi kesalahan prediksi pada komentar yang mengandung kata-kata ambigu atau memiliki makna yang bergantung pada konteks kalimat.

## REFERENSI

- [1] T. Krisdiyanto, "Analisis Sentimen Opini Masyarakat Indonesia Terhadap Kebijakan PPKM pada Media Sosial Twitter Menggunakan Naïve Bayes Clasifiers," *J. CoreIT J. Has. Penelit. Ilmu Komput. dan Teknol. Inf.*, vol. 7, no. 1, p. 32, 2021, doi: 10.24014/coreit.v7i1.12945.
- [2] F. A. Acheampong, C. Wenyu, and H. Nunoo-Mensah, "Text-based emotion detection: Advances, challenges, and opportunities," *Eng. Reports*, vol. 2, no. 7, pp. 1–24, 2020, doi: 10.1002/eng2.12189.
- [3] J. Samuel, G. G. M. N. Ali, M. M. Rahman, E. Esawi, and Y. Samuel, "COVID-19 public sentiment insights and machine learning for tweets classification," *Inf.*, vol. 11, no. 6, pp. 1–22, 2020, doi: 10.3390/info11060314.
- [4] P. Nandwani and R. Verma, "A review on sentiment analysis and emotion detection from text," *Soc. Netw. Anal. Min.*, vol. 11, no. 1, p. 81, 2021, doi: 10.1007/s13278-021-00776-6.
- [5] R. Mohammed, J. Rawashdeh, and M. Abdullah, "Machine learning with oversampling and undersampling techniques: Overview study and experimental results," in *Proceedings of the 11th International Conference on Information and Communication Systems (ICICS)*, 2020, pp. 243–248. doi: 10.1109/ICICS49469.2020.239556.
- [6] M. Wankhade, A. Chandra, S. Rao, and C. Kulkarni, "A survey on sentiment analysis methods, applications, and challenges," *Artif. Intell. Rev.*, vol. 55, no. 7, pp. 5731–5780, doi: 10.1007/s10462-022-10144-1.
- [7] M. Birjali, M. Kasri, and A. Beni-Hssane, "A comprehensive survey on sentiment analysis: Approaches, challenges and trends," *Knowledge-Based Syst.*, vol. 226, p. 107134, 2021, doi: 10.1016/j.knosys.2021.107134.
- [8] J. Hartmann, M. Heitmann, C. Siebert, and C. Schamp, "More than a feeling: Accuracy and application of sentiment analysis," *Int. J. Res. Mark.*, vol. 40, no. 1, pp. 75–87, 2023, doi: 10.1016/j.ijresmar.2022.05.005.
- [9] M. Naushin, A. Das, and A. K. Das, "Handling Class Imbalance Problem Using Support Vector Machine," in *Computational Intelligence in Pattern Recognition*, Singapore: Springer, 2023, pp. 133–144, doi: 10.1007/978-981-99-3734-9\_12.
- [10] C. Villavicencio, J. J. Macrohon, X. A. Inbaraj, J. H. Jeng, and J. G. Hsieh, "Twitter sentiment analysis towards covid-19 vaccines in the Philippines using naïve bayes," *Inf.*, vol. 12, no. 5, 2021, doi: 10.3390/info12050204.
- [11] A. S. Aribowo, H. Basiron, N. F. A. Yusof, and S. Khomsah, "Cross-domain sentiment analysis model on indonesian youtube comment," *Int. J. Adv. Intell. Informatics*, vol. 7,

- no. 1, pp. 12–25, 2021, doi: 10.26555/ijain.v7i1.554.
- [12] A. R. Isnain, N. S. Marga, and D. Alita, “Sentiment Analysis Of Government Policy On Corona Case Using Naive Bayes Algorithm,” *IJCCS (Indonesian J. Comput. Cybern. Syst.*, vol. 15, no. 1, p. 55, 2021, doi: 10.22146/ijccs.60718.
- [13] A. A. Ningtyas, A. Solichin, and R. Pradana, "Analisis Sentimen Komentar Youtube Tentang Prediksi Resesi Ekonomi Tahun 2023 Menggunakan Algoritme Naïve Bayes," *Bit (Fak. Teknol. Inf. Univ. Budi Luhur)*, vol. 20, no. 1, pp. 9–16, 2023, doi: 10.36080/bit.v20i1.2317.
- [14] F. Amrullah and A. Solichin, "Analisis Emosi Pada Live Chat Youtube 'Mata Najwa: 3 Bacapres Bicara Gagasan' Menggunakan Pendekatan Lexicon dan Algoritma Naive Bayes," *J. Ticom Technol. Inf. Commun.*, vol. 12, no. 3, pp. 121–128, 2024, doi: 10.70309/ticom.v12i3.132.
- [15] A. N. Ma’aly, D. Pramesti, A. D. Fathurahman, and H. Fakhurroja, “Exploring Sentiment Analysis for the Indonesian Presidential Election Through Online Reviews Using Multi-Label Classification with a Deep Learning Algorithm,” *Inf.*, vol. 15, no. 11, pp. 1–33, 2024, doi: 10.3390/info15110705.
- [16] D. A. Kristiyanti, S. A. Sanjaya, V. C. Tjokro, and J. Suhali, “Dealing imbalance dataset problem in sentiment analysis of recession in Indonesia,” *IAES Int. J. Artif. Intell.*, vol. 13, no. 2, pp. 2058–2070, 2024, doi: 10.11591/ijai.v13.i2.pp2060-2072.