

# Analisis Sentimen Terhadap RUU TNI Di Platform X (Twitter) Menggunakan Metode Ensemble Berbasis Naïve Bayes Dan Support Vector Machine

Nur Cholis Majid<sup>1</sup>, Aries Dwi Indriyanti<sup>2</sup>

<sup>1,2</sup> Sistem Informasi, Universitas Negeri Surabaya

<sup>1</sup>[nur.21062@mhs.unesa.ac.id](mailto:nur.21062@mhs.unesa.ac.id)

<sup>2</sup>[ariesdwi@unesa.ac.id](mailto:ariesdwi@unesa.ac.id)

**Abstrak**— Revisi Rancangan Undang-Undang Tentara Nasional Indonesia (RUU TNI) menjadi isu strategis yang memicu dinamika opini publik di media sosial. Penelitian ini bertujuan untuk menganalisis sentimen masyarakat terhadap Revisi RUU TNI di platform X (*Twitter*). Sebanyak 15.090 *tweet* dikumpulkan dan dianalisis menggunakan pendekatan *machine learning* untuk mengidentifikasi kecenderungan opini publik terhadap kebijakan tersebut. Data melalui beberapa tahap pengolahan, meliputi *data cleaning*, *case folding*, *tokenization*, *stopword removal*, dan *TF-IDF vectorization* sebelum dilakukan pelabelan dan pemodelan sentimen. Proses klasifikasi menggunakan tiga algoritma utama, yaitu *Naïve Bayes*, *Support Vector Machine (SVM)*, serta metode *Ensemble Weighted Soft Voting (Naïve Bayes–SVM)* untuk memperoleh hasil yang lebih akurat dan stabil. Hasil penelitian menunjukkan bahwa sentimen publik di ruang digital terhadap Revisi RUU TNI cenderung negatif dan menunjukkan kekhawatiran terhadap meningkatnya peran militer dalam ranah sipil, sekaligus menggarisbawahi pentingnya komunikasi publik yang transparan dan partisipasi masyarakat dalam proses legislasi. Hasil klasifikasi menunjukkan bahwa opini publik didominasi oleh sentimen negatif sebesar 47,87%, diikuti sentimen netral sebesar 33,87%, dan positif sebesar 18,26%. Model *SVM* menghasilkan akurasi tertinggi sebesar 95,34%, diikuti *Naïve Bayes* dengan 93,67%, sementara *ensemble Weighted Soft Voting* mencapai 96,00%, meskipun peningkatan tersebut tidak signifikan secara statistik.


**Kata Kunci**— Analisis Sentimen, RUU TNI, Twitter, Naïve Bayes, Support Vector Machine, Ensemble, Framing Media.

## I. PENDAHULUAN

Revisi Undang-Undang Tentara Nasional Indonesia (RUU TNI) menjadi topik perdebatan publik yang cukup hangat di Indonesia. Pemerintah dan DPR tengah membahas perubahan terhadap Undang-Undang Nomor 34 Tahun 2004 tentang TNI, yang memunculkan kekhawatiran akan kembalinya *dwifungsi militer* serta potensi penempatan personel aktif di lembaga sipil [1]. Beberapa poin revisi mencakup penyesuaian batas usia pensiun prajurit, perluasan tugas TNI di bidang non-perang, serta peningkatan peran personel aktif di berbagai lembaga negara. Kondisi ini memicu reaksi publik, termasuk aksi unjuk rasa mahasiswa yang menolak perubahan tersebut.

Media sosial telah menjadi ruang utama bagi masyarakat untuk mengekspresikan pandangan dan opini secara terbuka. Platform X (sebelumnya *Twitter*) menyediakan wadah komunikasi *real-time* yang memungkinkan publik merespons isu kebijakan secara cepat dan interaktif [2]. Data dari

platform ini memberikan gambaran berharga mengenai persepsi masyarakat terhadap isu sosial dan politik. Berdasarkan laporan *We Are Social* tahun 2020, sekitar 59% pengguna internet di Indonesia aktif menggunakan media sosial setiap bulan, dan *Twitter* termasuk dalam lima besar platform yang paling sering digunakan [3]. Hal ini menunjukkan relevansi media sosial dalam analisis opini publik.



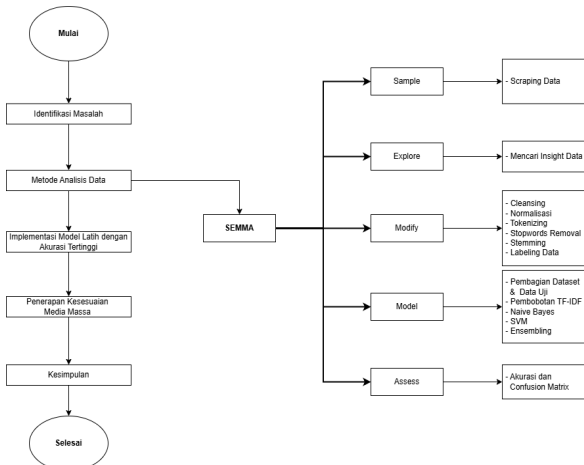
Gambar 1 Data Pengguna Media Sosial

Analisis sentimen menjadi pendekatan penting untuk memahami reaksi emosional masyarakat terhadap isu tertentu. Teknik ini mengklasifikasikan opini menjadi kategori positif, negatif, atau netral sehingga membantu peneliti mengekstraksi pola sikap publik secara sistematis [4]. Hasil analisis sentimen dapat digunakan untuk menilai respons publik terhadap kebijakan, mengidentifikasi tren opini, serta mendukung pengambilan keputusan yang berbasis data. Dengan demikian, metode ini memberikan kontribusi signifikan terhadap studi komunikasi publik dan kebijakan.

Dalam konteks analisis teks di media sosial, algoritma *Naïve Bayes (NB)* dan *Support Vector Machine (SVM)* merupakan dua metode yang paling banyak digunakan. *NB* memiliki keunggulan pada efisiensi komputasi dan kecepatan pemrosesan data berukuran besar [5], sedangkan *SVM* unggul dalam menangani data berdimensi tinggi dan menghasilkan pemisahan kelas yang optimal [6]. Beberapa penelitian menunjukkan bahwa *SVM* mampu memberikan akurasi tinggi dalam klasifikasi opini publik di media sosial [7]. Kombinasi kedua algoritma ini melalui pendekatan *Ensemble Soft Voting* memungkinkan penggabungan keunggulan masing-masing metode untuk meningkatkan stabilitas dan akurasi hasil klasifikasi [8].

Data penelitian ini dikumpulkan menggunakan teknik *web scraping* dengan bantuan *web driver Selenium* terhadap *tweet* terkait RUU TNI di platform *X*. Pendekatan ini efektif digunakan ketika akses *API* terbatas dan mampu menghasilkan data *real-time* yang relevan untuk analisis sentimen [9]. Melalui metode ini, diperoleh kumpulan data autentik yang merepresentasikan opini publik secara langsung, sehingga memungkinkan analisis yang lebih komprehensif terhadap persepsi masyarakat di ruang digital.

## II. METODE PENELITIAN



Gambar 2 Metode Penelitian

Penelitian ini menggunakan kerangka kerja *SEMMA* (*Sample, Explore, Modify, Model, Assess*) sebagai pedoman utama dalam proses analisis data. *Framework* ini menggambarkan tahapan sistematis yang dimulai dari pengambilan sampel data hingga evaluasi model untuk menghasilkan *analisis sentimen* yang akurat dan representatif.

### A. Sample

Pada tahap ini, data dikumpulkan menggunakan teknik *web scraping* dengan bantuan *web driver Selenium* terhadap *tweet* yang mengandung kata kunci terkait RUU TNI di platform *X* (*Twitter*). Pendekatan ini digunakan karena mampu memperoleh data secara *real-time* dan relevan ketika akses *API* resmi terbatas.

*Scraping* tanpa *API* merupakan alternatif yang efektif dalam memperoleh data mentah untuk *analisis sentimen*, terutama dalam konteks keterbatasan teknis atau administratif [9].

### B. Explore

Proses ini mencakup analisis distribusi konten yang berkaitan dengan topik RUU TNI. Selain itu, meninjau waktu unggahan dan pola pengguna dalam membuat *tweet*. Analisis ini didukung oleh visualisasi data menggunakan *library Python* seperti *seaborn* dan *matplotlib*, yang menghasilkan grafik distribusi. Tahapan eksplorasi ini sangat esensial dalam proses analisis data, karena dapat mengungkap pola

tersembunyi dan mendukung arah analisis yang lebih terarah [10].

### C. Modify

Tahap *Modify* merupakan bagian penting dalam metodologi *SEMMA*, yang berfokus pada proses transformasi dan penyiapan data agar siap digunakan dalam pemodelan. Langkah ini bertujuan untuk meningkatkan kualitas data, menghilangkan *noise*, serta memastikan struktur data sesuai kebutuhan analisis. Dengan demikian, data yang dihasilkan lebih bersih, konsisten, dan representatif terhadap konteks penelitian.

#### 1. Cleaning

Proses *cleaning* dilakukan untuk menghapus elemen-elemen yang tidak relevan atau mengganggu dalam data teks, seperti *URL*, tanda baca, angka, dan karakter khusus. Tujuan utamanya adalah menjaga agar data yang digunakan hanya berisi informasi bermakna yang dapat meningkatkan akurasi model analisis sentimen [11].

#### 2. Normalization

*Normalization* merupakan proses penyamaan bentuk teks agar lebih seragam. Tahap ini meliputi pengubahan seluruh huruf menjadi huruf kecil (*case folding*), penghapusan spasi berlebih, serta konversi kata tidak baku menjadi bentuk baku. Proses ini membantu menghindari duplikasi makna akibat variasi penulisan kata [12].

#### 3. Tokenizing

Tahap *tokenizing* dilakukan untuk memecah teks menjadi unit-unit kata yang disebut *token*. *Tokenization* membantu model memahami struktur teks dengan lebih baik dan menjadi dasar dalam tahap analisis lanjutan seperti penghitungan frekuensi kata atau pembentukan vektor fitur [13].

#### 4. Stopwords Removal

*Stopwords removal* bertujuan untuk menghapus kata-kata umum yang tidak memberikan kontribusi signifikan terhadap konteks sentimen, seperti “yang”, “dan”, atau “pada”. Langkah ini mengurangi dimensi data dan meningkatkan efisiensi model dengan mempertahankan hanya kata yang memiliki makna penting.

#### 5. Stemming

*Stemming* adalah proses mengembalikan kata ke bentuk dasarnya, misalnya “menolak”, “penolakan”, dan “ditolak” menjadi “tolak”. Tahap ini penting untuk menyamakan makna kata yang memiliki akar sama, sehingga membantu sistem dalam memahami konteks semantik secara lebih konsisten [14].

#### 6. Labeling Data

Tahap *labeling* dilakukan untuk memberikan kategori sentimen pada data teks berdasarkan konteks kalimat, seperti positif, netral, atau negatif. Label dapat ditentukan melalui dua pendekatan, yaitu pelabelan manual dan berbasis *lexicon*. Hasil pelabelan berperan penting sebagai dasar pembelajaran model klasifikasi sentimen [15].

#### D. Model

Tahap *Model* merupakan proses membangun dan melatih algoritma *pembelajaran mesin* berdasarkan data yang telah melalui tahap *Modify*. Tujuannya adalah menghasilkan *model prediktif* yang mampu mengklasifikasikan sentimen dengan tingkat akurasi yang optimal [16]. Dalam penelitian ini digunakan beberapa metode, yaitu pembagian *dataset*, pembobotan *TF-IDF*, *Naïve Bayes*, *Support Vector Machine (SVM)*, serta teknik *Ensembling Soft Voting*.

##### 1. Pembagian Dataset

Pembagian *dataset* dilakukan untuk memisahkan data menjadi dua bagian utama, yaitu data latih (*training set*) dan data uji (*testing set*). Data latih digunakan untuk membangun model, sementara data uji digunakan untuk mengevaluasi performa model terhadap data baru. Proporsi umum yang digunakan adalah 80% data latih dan 20% data uji agar model dapat belajar secara optimal tanpa mengalami *overfitting* [17].

##### 2. Pembobotan TF-IDF

*Term Frequency-Inverse Document Frequency (TF-IDF)* adalah teknik pembobotan kata yang bertujuan untuk mengukur seberapa penting suatu kata dalam sebuah dokumen relatif terhadap kumpulan dokumen lainnya. *TF-IDF* memperkuat bobot kata yang unik dan menurunkan bobot kata yang sering muncul di banyak dokumen, sehingga membantu model mengenali kata yang paling relevan dalam menentukan sentimen [18].

Pada proses *TF-IDF* ini dilakukan pembobotan pada kata atau pengubahan data teks menjadi representasi numerik..

$$w_{td} = tf_{td} \times \left( \log \left( \frac{N}{df_t} \right) + 1 \right)$$

Keterangan :

d : dokumen ke-d

t : kata ke-t dari kata kunci

w : bobot d sampai d terhadap kata t

tf : jumlah kata yang dicari pada sebuah dokumen

IDF : *Inverse Document Frequency*

N : jumlah total dokumen

df : jumlah dokumen yang berisi token

##### 3. Naïve Bayes

*Naïve Bayes* merupakan algoritma klasifikasi berbasis teori probabilitas *Bayes* yang mengasumsikan independensi antar fitur. Dalam analisis sentimen, algoritma ini banyak digunakan karena efisien dalam memproses data teks berukuran besar dan mampu memberikan hasil akurat meskipun dengan jumlah data pelatihan yang terbatas [19].

##### 4. Support Vector Machine (SVM)

*SVM* adalah algoritma pembelajaran mesin yang bekerja dengan mencari garis pemisah terbaik

(*hyperplane*) untuk memisahkan kelas data. *SVM* unggul dalam menangani data berdimensi tinggi dan efektif dalam masalah klasifikasi teks seperti analisis sentimen karena kemampuannya menemukan *margin* maksimum antara kelas positif dan negatif [20].

##### 5. Ensembling Soft Voting

*Soft Voting* merupakan metode *ensemble learning* yang menggabungkan hasil probabilitas dari beberapa model klasifikasi (seperti *Naïve Bayes* dan *SVM*) untuk menghasilkan prediksi akhir. Dengan menggabungkan kekuatan berbagai algoritma, metode ini mampu meningkatkan stabilitas dan akurasi model prediksi dibandingkan jika hanya menggunakan satu model tunggal [21].

#### E. Assess

Tahap *Assess* bertujuan untuk mengevaluasi performa model klasifikasi dengan menggunakan metrik tertentu, seperti akurasi dan *confusion matrix*. Evaluasi ini penting untuk mengetahui sejauh mana model mampu melakukan prediksi secara tepat terhadap data uji [22]. Evaluasi dalam penelitian ini dilakukan dengan menggunakan *confusion matrix* untuk mengukur kinerja model berdasarkan metrik *recall*, *precision*, *accuracy*, dan *F1-score*.

1. *Recall (Sensitivity)*, yaitu perbandingan jumlah data yang mungkin dikenali dengan jumlah seluruh data yang dikenali [16]. Berikut rumus perhitungan *recall*:

$$\frac{TP}{TP + FN} \times 100\%$$

2. *Precision*, yaitu perbandingan jumlah data yang mungkin dikenali dengan jumlah data yang dikenali. Berikut rumus perhitungan *Precision*:

$$\frac{TP}{TP + FP} \times 100\%$$

3. *Accuracy*, yaitu nilai yang menunjukkan tingkat akurasi system dalam mengklasifikasikan secara benar. Berikut rumus perhitungan *Accuracy*:

$$\frac{TN + TP}{TN + TP + FN + FP} \times 100\%$$

4. *F1-Score*, yaitu rata-rata *harmonic* dari nilai *Precision* dan *Recall*. Berikut rumus *F1-score*:

$$2 \times \frac{Precision \times Recall}{Precision + Recall} \times 100\%$$

### III. HASIL DAN PEMBAHASAN

#### A. Sample

Proses pengambilan data dalam penelitian ini dilakukan secara otomatis melalui teknik *web scraping* menggunakan *Selenium WebDriver* yang berfungsi sebagai peramban virtual untuk meniru aktivitas pengguna di platform *X (Twitter)*. Sistem melakukan *login* otomatis dengan kredensial yang telah disiapkan, kemudian menelusuri konten berdasarkan tiga kata kunci utama, yaitu *RUU TNI*, *militerasi*, dan *ancaman demokrasi*.

Rentang waktu pengambilan data ditetapkan antara 1 Maret hingga 31 Maret 2025. Untuk menghindari deteksi sebagai aktivitas *bot*, sistem disusun agar menyisipkan jeda acak 1–5 detik serta mengatur kecepatan *scrolling* secara bervariasi. Implementasi *scraping* dilakukan menggunakan bahasa *Python* yang terintegrasi dengan *Selenium* dan *browser Chrome*, memungkinkan pengambilan elemen-elemen *tweet* secara langsung dari halaman situs.


Proses *scraping* ini diimplementasikan menggunakan bahasa pemrograman *Python* yang terintegrasi dengan *Selenium* dan *browser Chrome*, sehingga memungkinkan sistem untuk melakukan pencarian, navigasi halaman, serta pengambilan elemen-elemen *tweet* secara langsung dari situs web.

Hasil proses pengumpulan menunjukkan terdapat 18.909 *tweet* untuk kata kunci *RUU TNI*, 318 *tweet* untuk *militerisasi*, dan 48 *tweet* untuk *ancaman demokrasi*, sehingga total data mentah yang diperoleh mencapai 19.275 *tweet*.

B. Explore

Pada tahap *explore*, analisis difokuskan pada pola perkembangan diskusi publik di platform *X (Twitter)* selama periode pengamatan. Tujuannya adalah untuk mengidentifikasi dinamika percakapan masyarakat terhadap isu revisi *RUU TNI*, termasuk momen-momen yang memicu peningkatan aktivitas daring.

Hasil analisis menunjukkan bahwa puncak diskusi terjadi pada 21 Maret 2025, dengan total 3.693 *tweet* dalam satu hari—sekitar 25% dari keseluruhan percakapan selama masa observasi. Lonjakan tersebut bertepatan dengan sidang paripurna DPR yang membahas revisi *RUU TNI*, menandakan bahwa intensitas diskusi publik meningkat secara signifikan ketika peristiwa politik penting berlangsung.



Gambar 3 Grafik Twet Harian

C. Modify

Tahap transformasi data (*modify*) dalam penelitian ini bertujuan memastikan kualitas input bagi model klasifikasi sentimen. Proses ini secara sistematis mempersiapkan data teks mentah menjadi struktur terstandarisasi yang siap diekstraksi fiturnya untuk model [23].

1. Cleaning

Proses *data cleaning* bertujuan menghapus elemen tidak relevan seperti tanda baca, angka, emotikon, simbol,

dan elemen *HTML* menggunakan *Regular Expression (re)* agar teks menjadi bersih dan konsisten. Proses ini juga melibatkan penghapusan data kosong, duplikat, dan *tweet* tidak utuh yang mengandung frasa “*Show more*”. Selain itu, *tweet* yang mengandung frasa *buzzer* dihapus agar analisis tetap objektif.

Langkah ini penting karena data mentah dari media sosial sering kali mengandung banyak *noise* yang dapat menurunkan kualitas analisis. Dengan melakukan pembersihan data secara menyeluruh, teks yang diolah menjadi lebih representatif terhadap opini publik sebenarnya.

Tabel 1 Hasil Proses Cleaning

Sebelum	Sesudah
” nel nel @stroberimylk · @glit terswan Apa katanya TNI masuk masih sesuai demokrasi , ini yg lu sebut demokrasi ? Ini mah ancaman kocaaak #CabutUUTNI #TolakRUUPolri 27 27 27 ”	”apa katanya tni masuk masih sesuai demokrasi ini yg lu sebut demokrasi ini mah ancaman kocaaak cabutuutni tolakruupolri”

2. Normalization

Pada tahap *Normalization* dilakukan untuk menyeragamkan teks dari berbagai bentuk penulisan kata yang tidak baku, seperti slang, singkatan, atau ejaan tidak konsisten. Proses ini dimulai dengan mengubah seluruh karakter dalam teks menjadi huruf kecil serta menghapus karakter selain huruf dan spasi. Setelah itu, teks yang sudah dibersihkan dipisahkan menjadi token atau potongan kata menggunakan fungsi

Tabel 2 Hasil Proses Normalization

Sebelum	Sesudah
”apa katanya tni masuk masih sesuai demokrasi ini yg lu sebut demokrasi ini mah ancaman kocaaak cabutuutni tolakruupolri”	” apa katanya tni masuk masih sesuai demokrasi ini yang kamu sebut demokrasi ini ancaman kocak cabutuutni tolakruupolri”

3. Tokenizing

Tahap *tokenizing* dilakukan setelah proses normalisasi, yaitu setelah data teks dibersihkan dan diseragamkan bentuk katanya. *Tokenizing* merupakan proses pemecahan kalimat atau teks menjadi satuan-satuan kata yang disebut *token*.

Tabel 3 Hasil Proses Tokenizing

Sebelum	Sesudah
" apa katanya tni masuk masih sesuai demokrasi ini yang kamu sebut demokrasi ini ancaman kocak cabutuutni tolakruupolri"	['apa', 'katanya', 'tni', 'masuk', 'masih', 'sesuai', 'demokrasi', 'ini', 'yang', 'kamu', 'sebut', 'demokrasi', 'ini', 'ancaman', 'kocak', 'cabutuutni', 'tolakruupolri'],

#### 4. Stopwords Removal

Proses penghapusan *stopwords* bertujuan untuk mengeliminasi kata-kata yang tidak memiliki kontribusi signifikan terhadap makna analisis. *Stopwords* yang digunakan merupakan gabungan dari *stopwords* bawaan Sastrawi (*default\_stopwords*) dan *stopwords* tambahan hasil penyesuaian konteks media sosial dalam penelitian ini (*formal\_stopwords*).

Tabel 4 Hasil Proses Stopwords Removal

Sebelum	Sesudah
['apa', 'katanya', 'tni', 'masuk', 'masih', 'sesuai', 'demokrasi', 'ini', 'yang', 'kamu', 'sebut', 'demokrasi', 'ini', 'ancaman', 'kocak', 'cabutuutni', 'tolakruupolri'],	"katanya tni masuk sesuai demokrasi sebut demokrasi ancaman kocak cabutuutni tolakruupolri"

#### 5. Stemming

*Stemming* merupakan proses penting dalam tahapan pra-pemrosesan teks yang bertujuan untuk mengurangi variasi kata dengan mengubah setiap kata ke bentuk dasarnya. Pada teks yang diambil dari media sosial, seringkali ditemukan banyak kata yang memiliki bentuk turunan berbeda namun memiliki akar makna yang sama, seperti "menjadi, terjadi, menjadikan, dijadikan". Dengan menerapkan *stemming*, seluruh variasi kata tersebut akan dikonversi ke bentuk akar yang sama, yaitu "jadi".

Tabel 5 Hasil Proses Stemming

Sebelum	Sesudah
"katanya tni masuk sesuai demokrasi sebut demokrasi ancaman kocak cabutuutni tolakruupolri"	"kata tni masuk sesuai demokrasi sebut demokrasi ancam kocak cabutuutni tolakruupolri"

#### 6. Labeling Data

Dalam penelitian ini, dilakukan proses pelabelan manual terhadap 1.500 *tweet* dari total 16.590 data yang telah dikumpulkan. Pelabelan dilakukan dengan membaca dan menganalisis setiap *tweet* satu per satu untuk menentukan sentimen yang terkandung di dalamnya. Sisa data sebanyak 15.090 *tweet* tidak diberi label secara manual dan digunakan untuk implementasi teknik *semi-supervised learning*. Distribusi label dari 1.500 data manual ini dijadikan dasar untuk pelatihan awal model analisis sentimen.

Hasil pelabelan menunjukkan distribusi sebagai berikut:

- 500 *tweet* diberi label positif.
- 500 *tweet* diberi label negatif.
- 500 *tweet* diberi label netral.

#### D. Model

Tahap *Model* merupakan bagian penting dalam proses klasifikasi sentimen yang bertujuan untuk melatih algoritma *machine learning* agar mampu mengenali pola sentimen dari data yang telah diproses sebelumnya.

##### 1. Pembagian Dataset

Pada tahap awal pemodelan, data dibagi menjadi dua bagian utama, yaitu data latih (*training set*) dan data uji (*testing set*). Pembagian ini dilakukan menggunakan fungsi *train test split* dari pustaka *scikit-learn*, dengan proporsi 80% data digunakan untuk pelatihan model dan 20% untuk pengujian. Kolom *stemmed* digunakan sebagai fitur teks (*X*) dan kolom *label* sebagai target klasifikasi (*y*). Pembagian data juga menggunakan parameter *stratify=y* untuk memastikan distribusi label tetap seimbang antara data latih dan uji.

##### 2. Pembobotan TF-IDF

Proses ini dilakukan menggunakan teknik *Term Frequency-Inverse Document Frequency (TF-IDF)* dengan memanfaatkan *TfidfVectorizer* dari pustaka *scikit-learn*. Pada proses ini, *max\_features* ditetapkan sebanyak 5.000 kata fitur yang paling sering muncul dalam data latih. Selanjutnya, data latih (*X\_train*) diubah menjadi representasi vektor menggunakan *fit\_transform*, sedangkan data uji (*X\_test*) ditransformasikan menggunakan *transform* dengan *vectorizer* yang telah dilatih sebelumnya..



Tabel 6 Hasil Pembobotan TF-IDF

No	Kata	TF-IDF
1	Tni	0.080504
2	RUU	0.066988
3	Sipil	0.062732
4	Militer	0.042681
5	Supremasi	0.037621
6	Dwifungsi	0.036427
7	Tolak	0.031948
8	UU	0.027822
9	Dukung	0.027577
10	Reformasi	0.025268

### 3. Naïve Bayes

Model *Multinomial Naïve Bayes* digunakan sebagai salah satu algoritma utama dalam klasifikasi sentimen terhadap RUU TNI. Sebelum pelatihan dilakukan, *dataset* dibagi menjadi dua bagian, yaitu 80% data latih (*training set*) dan 20% data uji (*testing set*) menggunakan fungsi *train\_test\_split* dari pustaka *scikit-learn*. Selanjutnya, model dilatih (*fit*) pada vektor *TF-IDF* hasil transformasi dari data latih ( $X_{train\_vec}$ ) dengan label yang telah di-encode ( $y_{train\_enc}$ ). Setelah proses pelatihan, model diuji menggunakan data uji ( $X_{test\_vec}$ ) untuk menghasilkan prediksi ( $y_{pred\_nb}$ ). Hasil prediksi tersebut kemudian dievaluasi dengan membandingkannya terhadap label sebenarnya ( $y_{test\_enc}$ ) menggunakan metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score*, guna mengukur sejauh mana model mampu mengklasifikasikan sentimen dengan tepat.

### 4. Support Vector Machine (SVM)

Model *Support Vector Machine (SVM)* dengan *kernel linear* diterapkan untuk memperoleh klasifikasi sentimen yang lebih optimal. Sama seperti pada *Naïve Bayes*, *dataset* dibagi secara proporsional menjadi 80% data latih dan 20% data uji menggunakan fungsi *train\_test\_split*, sehingga dari total 1.500 data berlabel, sebanyak 1.200 digunakan untuk pelatihan dan 300 untuk pengujian. Model kemudian dilatih pada representasi *TF-IDF* ( $X_{train\_vec}$ ) serta label yang telah di-encode ( $y_{train\_enc}$ ). Setelah pelatihan selesai, model melakukan prediksi terhadap data uji ( $X_{test\_vec}$ ), menghasilkan *output* sentimen yang dibandingkan dengan label sebenarnya ( $y_{test\_enc}$ ). Evaluasi performa dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk menilai kemampuan model dalam mengidentifikasi masing-masing kelas sentimen.

### 5. Ensembling Soft Voting

Dua model dasar yang digunakan adalah *Support Vector Machine (SVM)* dengan *kernel linear* dan *Multinomial Naïve Bayes (NB)*. Keduanya dikombinasikan menggunakan pendekatan *Soft Voting*, di


mana setiap model diberi bobot berbeda untuk menentukan kontribusi terhadap hasil akhir. Proses pencarian dilakukan dengan menguji berbagai kombinasi bobot dari 0.1 hingga 0.9, dengan total bobot tetap 1.0. Pada setiap kombinasi, model *ensemble* dilatih menggunakan data latih ( $X_{train\_vec}$  dan  $y_{train\_enc}$ ) dan dievaluasi berdasarkan *accuracy* terhadap data uji.

### E. Assess

*Assessment* model dilakukan dengan menghitung *accuracy*, *F1-score*, dan *confusion matrix* untuk mengevaluasi performa klasifikasi. *Accuracy* mengukur persentase prediksi benar secara keseluruhan, sementara *F1-score* (rata-rata harmonik antara *precision* dan *recall*) menilai keseimbangan model dalam mengklasifikasikan setiap kelas sentimen (positif, netral, negatif).

#### 1. Model Naïve Bayes

Model *Multinomial Naïve Bayes* menunjukkan kinerja yang baik dalam mengklasifikasikan sentimen terhadap RUU TNI dengan *accuracy* sebesar 93,6%. Kelas positif memiliki performa tertinggi dengan *precision* 0.93, *recall* 0.97, dan *F1-score* 0.95, diikuti kelas netral dengan *precision* 0.92, *recall* 0.94, dan *F1-score* 0.93, yang menunjukkan keseimbangan antara ketepatan dan kemampuan deteksi. Sementara itu, kelas negatif memperoleh *precision* 0.96, *recall* 0.90, dan *F1-score* 0.93, menandakan bahwa model cukup akurat dalam mengenali sentimen negatif meskipun masih terdapat sedikit kesalahan klasifikasi.



Gambar 4 Confusion Matrix Naïve Bayes

Berikut adalah hasil tabel *Confusion Matrix* dari Algoritma *Naïve Bayes*.

Tabel 7 Confusion Matrix Naïve Bayes

Actual \ Predicted	Negatif	Netral	Positif
Negatif	90	7	3
Netral	2	94	4
Positif	2	1	97

Jika dijumlahkan, total keseluruhan data yang digunakan untuk pengujian adalah 300 *tweet*, yang terdiri dari 100 data negatif, 100 netral, dan 100 positif. Berdasarkan hasil prediksi model, distribusi prediksi menunjukkan bahwa terdapat 94 *tweet* yang diprediksi sebagai negatif, 102 *tweet* sebagai netral, dan 104 *tweet* sebagai positif. Informasi ini menjadi dasar dalam menghitung metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score* untuk menilai kinerja model secara lebih mendalam.


Berikut adalah Perhitungan Persamaan dari Akurasi Model *Naive Bayes*.

$$\text{Akurasi} = \frac{\text{Total prediksi benar}}{\text{Total data}} = \frac{90 + 94 + 97}{300} = \frac{281}{300} = 93,67\%$$

Secara keseluruhan, model *Multinomial Naïve Bayes* menunjukkan akurasi tinggi sebesar 93,67% dengan performa yang stabil di semua kelas sentimen. Kelas positif memiliki hasil terbaik (*precision* 0.93, *recall* 0.97), diikuti netral (0.92, 0.94) dan negatif (0.96, 0.90), menandakan model mampu mengenali tiap sentimen dengan baik meski masih terdapat sedikit kesalahan pada kelas negatif.

## 2. Model Support Vector Machine (SVM)

Model *Support Vector Machine (SVM)* dengan *kernel linear* menunjukkan performa yang sangat baik dengan akurasi mencapai 95,33% dalam klasifikasi sentimen terhadap RUU TNI. Secara keseluruhan, model ini mampu memberikan hasil yang konsisten di seluruh kelas dengan nilai *precision*, *recall*, dan *F1-score* yang seimbang. Kelas positif menunjukkan performa tertinggi dengan *precision* 0.99 dan *recall* 0.97, diikuti oleh kelas netral dengan *precision* 0.93 dan *recall* 0.94, serta kelas negatif dengan *precision* 0.92 dan *recall* 0.96. Hasil ini menunjukkan bahwa *SVM* efektif dalam mengenali berbagai jenis sentimen, baik positif, netral, maupun negatif, dengan tingkat kesalahan klasifikasi yang sangat rendah.



Gambar 5 Confusion Matrix SVM

Berikut adalah hasil tabel *Confusion Matrix* dari Algoritma *Support Vector Machine*.

Tabel 8 Confusion Matrix SVM

Actual \ Predicted	Negatif	Netral	Positif
Negatif	96	4	0
Netral	6	93	1
Positif	2	1	97

Dengan demikian, akurasi model dapat dihitung berdasarkan total prediksi benar sebesar 286 dibandingkan dengan keseluruhan data sebanyak 300, yang kemudian dapat digunakan sebagai dasar untuk evaluasi metrik performa lainnya seperti *precision*, *recall*, dan *F1-score*.


Berikut adalah Perhitungan Persamaan dari Akurasi Model *Support Vector Machine*.

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Jumlah total data}} = \frac{96 + 93 + 97}{300} = \frac{286}{300} = 95,33\%$$

Secara keseluruhan, model *SVM* ini memiliki kecenderungan yang seimbang dalam mengenali data positif, netral, dan negatif, dengan nilai akurasi yang sangat tinggi sebesar 95,33%. Hal ini menunjukkan bahwa model mampu melakukan klasifikasi dengan tingkat kesalahan yang sangat rendah. Meskipun demikian, masih terdapat sedikit kesalahan klasifikasi antara kelas negatif dan netral, yang menunjukkan adanya kemiripan konteks antar kedua kelas tersebut.

## 3. Model Ensembling Soft Voting

Metode *Weighted Soft Voting* menghasilkan akurasi tertinggi sebesar 96,00% dengan kombinasi bobot optimal [*SVM* = 0.4, *NB* = 0.6], menunjukkan bahwa sinergi antara *Support Vector Machine (SVM)* dan *Multinomial Naïve Bayes (NB)* mampu meningkatkan kinerja klasifikasi sentimen. Model ini mencatat nilai *precision* tertinggi pada kelas positif sebesar 0.99, diikuti kelas netral 0.96 dan negatif 0.93, serta *recall* tertinggi pada kelas negatif sebesar 0.98. Nilai *F1-score* rata-rata 0.96 pada *macro* dan *weighted average* mengindikasikan keseimbangan yang baik antara *precision* dan *recall* di seluruh kelas. Secara keseluruhan, pendekatan *ensemble learning* ini terbukti lebih unggul dibandingkan model tunggal karena mampu memadukan kekuatan *SVM* dalam pemisahan *margin* yang tegas dengan keandalan *NB* dalam menangani distribusi probabilistik teks.



Gambar 6 Confusion Matrix Weighted Soft Voting

Berikut adalah hasil tabel *Confusion Matrix* dari Algoritma *Support Vector Machine*.

Tabel 9 Confusion Matrix Weighted Soft Voting

Actual \ Predicted	Negatif	Netral	Positif
Negatif	96	4	0
Netral	5	94	1
Positif	2	0	98

Analisis hasil menunjukkan bahwa model masih mengalami tantangan dalam membedakan sentimen *netral* dan *positif* dari sentimen *negatif*, namun secara keseluruhan model mampu memberikan hasil klasifikasi yang kuat dan konsisten.

Berikut adalah perhitungan persamaan dari akurasi model *ensemble* dengan pendekatan *Weighted Soft Voting*.

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Jumlah total data}} = \frac{96 + 94 + 98}{300} = \frac{288}{300} = 96,00\%$$


Secara keseluruhan, model *Ensemble Weighted Soft Voting* menunjukkan keseimbangan yang sangat baik antara *precision* dan *recall* di ketiga kelas. Hasil ini memperlihatkan bahwa model mampu melakukan generalisasi dengan baik tanpa indikasi *overfitting* yang signifikan, serta memiliki performa yang kuat dalam mengidentifikasi sentimen secara proporsional di setiap kategori.

#### 4. Implementasi Model Terbaik

Dalam perbandingan performa antar model sentimen, *Multinomial Naïve Bayes* mencapai akurasi sebesar 93,67%, dengan performa terbaik pada kelas positif (*precision* = 0.93; *recall* = 0.97), menunjukkan kemampuan tinggi dalam mengenali *tweet* bernada positif. *Support Vector Machine (SVM)* juga menunjukkan performa yang baik dengan akurasi 95,33%, serta hasil

yang seimbang di ketiga kelas sentimen. Namun, model *Ensemble Weighted Soft Voting* menjadi yang paling unggul dengan akurasi tertinggi sebesar 96%, serta nilai *precision* dan *recall* yang konsisten di semua kelas (positif, netral, dan negatif).

Pendekatan *Soft Voting* ini efektif karena mampu mengombinasikan kekuatan dari kedua model dasar, yaitu *SVM* dan *Naïve Bayes*, dengan memberikan bobot lebih besar pada model yang lebih kuat (*SVM*), sehingga menghasilkan prediksi yang lebih stabil, akurat, dan mampu melakukan generalisasi yang lebih baik terhadap data uji.



Gambar 7 Pie Chart Hasil Prediksi

Hasil prediksi ini disimpan dalam sebuah *DataFrame* bernama *df\_predicted*, yang berisi kolom *stemmed*, *predicted label*, dan *confidence*. Berdasarkan distribusi hasil prediksi tersebut, sentimen negatif mendominasi dengan total 7.224 *tweet* (47,87%), diikuti oleh sentimen netral sebanyak 5.111 *tweet* (33,87%), dan sentimen positif sebesar 2.755 *tweet* (18,26%), dengan total keseluruhan 15.090 *tweet* yang berhasil diprediksi.

#### IV. KESIMPULAN

Berdasarkan hasil penelitian yang dilakukan, diperoleh beberapa kesimpulan sebagai berikut:

1. Hasil analisis sentimen terhadap RUU TNI di platform *X (Twitter)* menunjukkan bahwa opini publik didominasi oleh sentimen negatif sebesar 47,87%, diikuti sentimen netral 33,87%, dan positif 18,26%. Dominasi sentimen negatif ini mengindikasikan bahwa sebagian besar masyarakat digital menolak atau menunjukkan ketidaksetujuan terhadap rancangan undang-undang tersebut. Dengan demikian, hasil penelitian ini dapat menjadi acuan bagi pembuat kebijakan dan pengambil keputusan dalam memahami persepsi publik secara lebih komprehensif berbasis data.
2. Model *Ensemble Weighted Soft Voting* terbukti menghasilkan performa terbaik dengan akurasi sebesar 96,00%, melampaui model tunggal *Multinomial Naïve Bayes* (93,67%) dan *Support Vector Machine (SVM)* (95,33%). Kombinasi bobot optimal [*SVM* = 0.4, *NB* =



0.6] menunjukkan bahwa integrasi dua algoritma berbeda mampu saling melengkapi—*SVM* unggul dalam pemisahan *margin* antar kelas, sementara *Naïve Bayes* efektif dalam menangani distribusi probabilistik fitur teks. Hal ini menegaskan bahwa pendekatan *ensemble learning* meningkatkan stabilitas dan akurasi klasifikasi sentimen secara signifikan.

#### V. REFERENSI

- [1] B. Habibie and R. S. Putra, "Peran Militer dalam Reformasi dan Tantangan Supremasi Sipil di Indonesia," *Jurnal Ilmu Sosial dan Ilmu Politik*, vol. 21, no. 3, pp. 211–225, 2019.
- [2] A. Ramadhani and L. Pratama, "Analisis Sentimen Publik di Twitter Menggunakan Naïve Bayes," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 6, no. 1, pp. 45–53, 2019.
- [3] We Are Social & Hootsuite, "Digital 2020: Indonesia," DataReportal, 2020.
- [4] A. Permana and N. Kurniawati, "Analisis Sentimen untuk Evaluasi Kebijakan Publik di Media Sosial," *Jurnal Sistem Informasi dan Komputerisasi Administrasi*, vol. 8, no. 2, pp. 112–120, 2019.
- [5] D. Wicaksono and L. Sari, "Penerapan Naïve Bayes untuk Deteksi Teks Berita Hoaks pada Media Sosial," *Jurnal Komputer dan Informatika (KOMPUTA)*, vol. 7, no. 1, pp. 15–22, 2020.
- [6] E. Octaviani, A. Yuliana, and D. Pratomo, "Penerapan SVM untuk Klasifikasi Data Akreditasi Sekolah," *Jurnal Sains dan Teknologi Informasi*, vol. 2, no. 4, pp. 102–110, 2019.
- [7] S. Amalia and H. Nurfalah, "Klasifikasi Opini Publik terhadap Kebijakan Pemerintah Menggunakan SVM," *Jurnal Data Mining Indonesia*, vol. 4, no. 2, pp. 65–72, 2020.
- [8] M. Zhou and L. Zhang, "Soft Voting Ensemble for Text Classification," *International Journal of Computer Applications*, vol. 177, no. 4, pp. 10–16, 2019.
- [9] R. Puspaningrum and D. Raharjo, "Implementasi Web Scraping pada Media Sosial Twitter untuk Analisis Sentimen," *Jurnal Teknologi Informasi dan Sains Komputer*, vol. 6, no. 1, pp. 45–54, 2020.
- [10] Setiawan, R., & Pratama, A. (2020). Implementasi metode SEMMA dalam analisis data penjualan pada e-commerce menggunakan data mining. *Jurnal Teknologi dan Sistem Informasi*, 8(2), 123–131.
- [11] D. Lestari and T. Nugroho, "Analisis Preprocessing Data Teks untuk Klasifikasi Sentimen pada Media Sosial," *Jurnal Informatika dan Sistem Cerdas*, vol. 4, no. 1, pp. 55–62, 2021.
- [12] N. R. Amelia and I. S. Pertiwi, "Implementasi Normalisasi Data pada Pemrosesan Teks Bahasa Indonesia," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 9, no. 3, pp. 201–210, 2022.
- [13] M. R. Wijayanto and D. S. Ramadhan, "Optimasi Tokenisasi pada Pemrosesan Bahasa Alami untuk Analisis Sentimen," *Jurnal Sistem Cerdas dan Informatika*, vol. 5, no. 2, pp. 87–94, 2022.
- [14] F. Kurniawan and R. Hidayat, "Penerapan Stemming Bahasa Indonesia Menggunakan Algoritma Nazief–Adriani," *Jurnal Sains Komputer dan Informatika*, vol. 11, no. 1, pp. 34–41, 2023.
- [15] E. Putri and A. Nugraha, "Pelabelan Data Sentimen Berbasis Lexicon untuk Bahasa Indonesia," *Jurnal Teknologi Informasi dan Aplikasi Komputer*, vol. 12, no. 1, pp. 75–83, 2024.
- [16] M. F. Rahman and A. Pratomo, "Penerapan Metodologi SEMMA untuk Klasifikasi Data Teks pada Analisis Sentimen," *Jurnal Teknologi dan Sistem Informasi*, vol. 10, no. 2, pp. 110–118, 2021.
- [17] R. Saputra and N. Wulandari, "Pengaruh Proporsi Pembagian Dataset terhadap Kinerja Model Machine Learning," *Jurnal Sains Data dan Analitika*, vol. 2, no. 1, pp. 45–53, 2022.
- [18] T. Hidayah and M. Ramadhan, "Analisis Pembobotan TF-IDF untuk Klasifikasi Dokumen Berita Bahasa Indonesia," *Jurnal Sistem Informasi dan Informatika*, vol. 9, no. 2, pp. 84–92, 2023.
- [19] D. L. Putra and A. Santoso, "Implementasi Naïve Bayes untuk Analisis Sentimen pada Ulasan Pengguna," *Jurnal Teknologi Komputer dan Aplikasi*, vol. 11, no. 1, pp. 66–73, 2022.
- [20] S. K. Rahmawati and R. Firmansyah, "Penerapan Support Vector Machine (SVM) untuk Klasifikasi Sentimen Media Sosial," *Jurnal Komputer dan Sains Informasi (KOMIK)*, vol. 8, no. 3, pp. 101–109, 2023.
- [21] F. L. Nugroho and R. P. Syahputra, "Penerapan Ensemble Soft Voting pada Analisis Sentimen Review Produk," *Jurnal Informatika dan Sistem Cerdas*, vol. 5, no. 1, pp. 72–80, 2024.
- [22] I. K. Sari and A. Prabowo, "Evaluasi Model Machine Learning Menggunakan Confusion Matrix dan Akurasi," *Jurnal Ilmu Komputer Terapan*, vol. 7, no. 2, pp. 88–96, 2021.
- [23] N. A. Hapsari and A. D. Indriyanti, "Analisis Sentimen pada Aplikasi Dompot Digital Menggunakan Algoritma Random Forest," *Journal of Emerging Information Systems and Business Intelligence (JEISBI)*, vol. 4, no. 3, pp. 186–192, 2023.