

# Analisis Sentimen Masyarakat Terhadap Kebijakan Undang-Undang Tentara Nasional Indonesia (UU TNI) Menggunakan Support Vector Machine

Adwin Atinna Nurhasananda\*, Mutaqin Akbar

Program Studi Informatika, Fakultas Teknologi Informasi, Universitas Mercu Buana Yogyakarta

**Abstrak:** Penelitian ini bertujuan untuk menganalisis sentimen masyarakat terhadap revisi Undang-Undang Tentara Nasional Indonesia (UU TNI) melalui data yang diperoleh dari media sosial. Data dikumpulkan dari platform X (sebelumnya Twitter) selama periode 1 hingga 31 Maret 2025 menggunakan teknik scraping dengan kata kunci “UU TNI”. Setelah dilakukan pelabelan manual menjadi sentimen positif dan negatif, data dianalisis menggunakan algoritma Support Vector Machine (SVM) dengan pendekatan pembobotan Term Frequency–Inverse Document Frequency (TF-IDF). Proses klasifikasi dilakukan dengan kernel Radial Basis Function (RBF) dan dievaluasi menggunakan metode 5-Fold Cross Validation serta confusion matrix. Hasil evaluasi menunjukkan bahwa model menghasilkan akurasi rata-rata sebesar 78,99%, dengan nilai F1-score tertinggi sebesar 0,83 untuk sentimen negatif. Dari total 500 tweet, sebanyak 58,99% diidentifikasi sebagai sentimen negatif, sementara sisanya 41,01% merupakan sentimen positif. Temuan ini mengindikasikan bahwa mayoritas masyarakat menunjukkan respons negatif terhadap revisi UU TNI, yang merefleksikan kekhawatiran publik terhadap potensi melemahnya prinsip demokrasi dan supremasi sipil. Dengan demikian, pendekatan analisis sentimen berbasis media sosial terbukti efektif dalam memberikan gambaran objektif persepsi publik terhadap kebijakan negara dan dapat dijadikan masukan penting bagi pembuat kebijakan.

**Kata Kunci:** Sentimen masyarakat, UU TNI, Support Vector Machine, TF-IDF, media sosial

DOI:

<https://doi.org/10.53697/jkomitek.v5i1.2603>

\*Correspondence: Adwin Atinna

Nurhasananda

Email: [211120100@student.mercubuana-yogya.ac.id](mailto:211120100@student.mercubuana-yogya.ac.id)

Received: 25-04-2025

Accepted: 25-05-2025

Published: 25-06-2025



**Copyright:** © 2024 by the authors. Submitted for open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

**Abstract:** This study aims to analyze public sentiment toward the revision of the Indonesian National Armed Forces Law (UU TNI) using data obtained from social media. Data were collected from the X platform (formerly Twitter) during the period of March 1 to 31, 2025, using a scraping technique with the keyword “UU TNI.” After manually labeling the data into positive and negative sentiments, the dataset was analyzed using the Support Vector Machine (SVM) algorithm with the Term Frequency–Inverse Document Frequency (TF-IDF) weighting method. The classification process applied the Radial Basis Function (RBF) kernel and was evaluated using 5-Fold Cross Validation and a confusion matrix. The evaluation results show that the model achieved an average accuracy of 78.99%, with the highest F1-score of 0.83 for negative sentiment. Out of 500 tweets, 58.99% were identified as negative sentiment, while 41.01% were positive. These findings indicate that the majority of the public expressed negative responses to the UU TNI revision, reflecting concerns about the potential weakening of democratic principles and civilian supremacy. Thus, the sentiment analysis approach based on social media has proven effective in providing an objective overview of public perception regarding government policy and can serve as valuable input for policymakers.

**Keywords:** Public sentiment, UU TNI, Support Vector Machine, TF-IDF, social media

## Pendahuluan

Tentara Nasional Indonesia (TNI) merupakan lembaga negara yang memiliki peran utama dalam menjaga kedaulatan, keutuhan wilayah, dan keselamatan bangsa dari ancaman militer maupun bersenjata. Sejak reformasi tahun 1998, peran TNI mulai dibatasi hanya dalam urusan pertahanan melalui Undang-Undang Nomor 34 Tahun 2004, yang mempertegas prinsip supremasi sipil atas militer. Undang-Undang Nomor 34 Tahun 2004 tentang Tentara Nasional Indonesia (TNI) merupakan landasan hukum utama yang mengatur peran, fungsi, struktur organisasi, dan kewenangan TNI dalam menjaga kedaulatan serta keutuhan Negara Kesatuan Republik Indonesia (Amran et al, 2022). UU inipun menegaskan prinsip-prinsip dasar reformasi sektor pertahanan, termasuk pemisahan peran TNI dan Polri, serta penegakan supremasi sipil atas militer dalam sistem demokrasi. Selama hampir dua dekade, UU TNI telah menjadi acuan dalam pengelolaan kekuatan pertahanan nasional yang profesional dan netral dari politik (Kariawan et al, 2022).

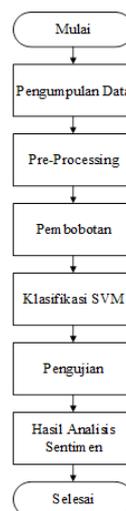
Namun, pada tahun 2025, muncul Rancangan Undang-Undang (RUU) tentang Perubahan atas UU No. 34 Tahun 2004 yang menimbulkan berbagai kontroversi di tengah masyarakat. Beberapa poin dalam RUU tersebut, seperti perluasan tugas TNI di luar operasi militer tanpa keterlibatan otoritas sipil serta ketentuan mengenai masa dinas prajurit aktif, menuai kritik dari sejumlah kalangan (Nuzulianto & Sukalumba, 2025). Banyak pihak menilai bahwa RUU ini berpotensi membuka ruang kembalinya dwifungsi TNI serta melemahkan prinsip demokrasi dan akuntabilitas publik (Oktavianus dkk., 2025). Reaksi masyarakat pun sangat beragam, mulai dari dukungan hingga penolakan yang disuarakan secara masif melalui media sosial.

Melihat fenomena tersebut, diperlukan suatu pendekatan berbasis data untuk menganalisis bagaimana sentimen masyarakat terhadap UU TNI secara objektif. Analisis sentimen adalah kegiatan pengolahan data teks dalam upaya mengetahui opini, emosi, atau sikap pengguna terhadap suatu isu atau kebijakan (Yusanto & Akbar, 2024). Beberapa metode yang umum dimanfaatkan dalam analisis sentimen diantaranya mencakup seperti Naive Bayes, Decision Tree, dan Support Vector Machine (SVM). Metode Naive Bayes memiliki kelebihan yaitu cepat, efisien, serta cukup akurat untuk data teks dengan fitur yang relatif independen. Namun, kelemahan utamanya adalah asumsi independensi antar fitur yang jarang terpenuhi dalam praktik, serta sensitivitas terhadap data noise atau fitur langka (Dzulkarnain dkk., 2024; Rofiqi & Akbar, 2024). Sementara itu, Decision Tree memiliki keunggulan dalam hal interpretabilitas karena hasilnya dapat divisualisasikan sebagai pohon keputusan yang mudah dipahami. Meski demikian, metode ini rentan terhadap overfitting, khususnya terhadap data latih yang kompleks atau memiliki banyak fitur (Hardyatman & Hasan, 2025; Octa Nuryawan dkk., 2023). Adapun Support Vector Machine (SVM) dikenal dengan kemampuannya dalam menghasilkan akurasi tinggi pada data berdimensi besar dan bisa mengatasi data yang tidak linear melalui penggunaan kernel. Namun, kelemahan SVM terletak pada proses pelatihan yang memakan waktu dan sumber daya, serta tingkat kesulitan dalam interpretasi model akhir (Kuswandaru & Akbar, 2024) (Pratama & Prasetyaningrum, 2025) (Putra et al, 2021).

Beberapa penelitian menggunakan SVM diantaranya yaitu penelitian yang dilakukan oleh Syadza & Alit (2023) untuk menganalisis respons masyarakat terhadap kebijakan kenaikan harga BBM, dengan akurasi model mencapai 82,88% dan F1-score 83,83% (Adilah & Alit, 2023). Romadhona & Isnain (2024) menerapkan SVM dengan pendekatan Recursive Feature Elimination (RFE) untuk isu pajak hiburan, mencapai akurasi hingga 95% (Romadhona & Isnain, 2024). Studi Sriani, Gultom, & Suhardi (2023) menunjukkan efektivitas SVM dalam menganalisis sentimen terhadap subsidi motor listrik, dengan akurasi sebesar 86,43% (Gultom et al, 2023). Penelitian oleh Fremmuzar & Baita (2023) mengkaji pengaruh berbagai kernel SVM pada layanan Telkomsel dan menemukan bahwa kernel sigmoid memberikan kinerja terbaik (Fremmuzar & Baita, 2023). Sementara itu, Adhitya & Junadhi (2022) menunjukkan tantangan dalam klasifikasi data sentimen kompleks seperti kasus Bjorka, dengan akurasi lebih rendah (62,33%) (Adhitya Karel Maulaya & Junadhi, 2022). Studi-studi tersebut menunjukkan bahwa algoritma SVM, dengan dukungan pembobotan TF-IDF, secara konsisten mampu memberikan performa yang baik dalam klasifikasi sentimen media sosial (Firdaus et al, 2024) (Karo et al, 2023).

Dalam penelitian ini metode yang digunakan yakni algoritma Support Vector Machine (SVM). Algoritma SVM ialah algoritma machine learning yang mampu mengklasifikasikan data teks kedalam kriteria positif atau negatif dengan akurasi tinggi (Putra et al, 2021). Dengan demikian, hasil kajian studi ini mampu memberikan gambaran umum persepsi publik terhadap kebijakan UU TNI, sekaligus menjadi masukan yang konstruktif bagi para pemangku kebijakan dalam menyusun regulasi yang responsif dan sesuai dengan aspirasi masyarakat.

## Metodologi



Gambar 1. Diagram Alir Penelitian

Penelitian ini memanfaatkan teknik *text mining* untuk menganalisa sentiment di media sosial terhadap opini masyarakat. Media sosial dipilih karena sifatnya yang terbuka, real-time, dan memungkinkan masyarakat mengekspresikan pandangan secara langsung terhadap isu kebijakan publik. Platform X (dahulu Twitter) digunakan sebagai sumber data

utama karena memiliki volume percakapan tinggi dan kontennya dapat diakses serta diolah dengan teknik web scraping ('Adilah & Alit, 2023).

### 1. Pengumpulan Data & Pelabelan

Pengumpulan menggunakan bahasa pemrograman Python dengan pustaka sncrape, yang memungkinkan scraping tweet tanpa batasan API. Proses scraping dilakukan pada rentang waktu 1–31 Maret 2025 dengan kata kunci “UU TNI”. Untuk menjaga relevansi isu data dibatasi pada tweet berbahasa Indonesia. Dari proses ini, berhasil dikumpulkan sebanyak 500 tweet. Selanjutnya memberikan label pada data tweet tersebut, yaitu sentimen positif dan negatif. Diberi label 0 pada sentiment positif, sementara diberi label 1 pada sentiment negatif.

### 2. Preprocessing Data

Sebelum dianalisis lebih lanjut dalam proses klasifikasi maka tahap ini bertujuan untuk melakukan pembersihan data serta menstandartkan data. Tahapan ini meliputi beberapa proses penting. Pertama, cleaning, yaitu pembersihan pada elemen-elemen yang tidak diperlukan seperti mention, tautan, tanda baca, hastag, dan angka. Kedua, case folding, dimana semua huruf dalam teks jika ada huruf kapital akan diubah menjadi huruf kecil untuk menyeragamkan bentuk kata. Ketiga, proses tokenizing untuk memisahkan kalimat menjadi kata-kata individu. Tahap selanjutnya adalah normalisasi, yaitu mengganti kata tidak baku dengan padanan kata yang sesuai dengan bahasa Indonesia standar. Setelah itu dilakukan stopword removal untuk mengeliminasi kata umum yang kurang bermakna dalam konteks analisa. Terakhir, untuk mengembalikan kata ke bentuk dasar menggunakan pustaka sastrawi maka digunakan proses stemming (Sari et al, 2020).

### 3. Pembobotan Fitur

Setelah melalui tahap preprocessing, teks kemudian dikonversi menjadi format numerik dengan memanfaatkan metode Term Frequency–Inverse Document Frequency (TF-IDF). Teknik pembobotan ini membantu dalam mengenali kata-kata yang memiliki peran signifikan dalam mengklasifikasikan sentimen pada tweet (Hatta, 2021). Salah satu komponen utama untuk melakukan perhitungan TF-IDF adalah Inverse Document Frequency (IDF), yang dapat dihitung dengan rumus (Wibowo dkk., 2024):

$$idf(t) = \text{Log} \left( \frac{N}{df(t)} \right)$$

Dalam hal ini,  $N$  menunjukkan jumlah total dari semua dokumen dalam korpus, sementara  $df(t)$  merupakan dokumen yang mengandung term  $t$ . Untuk menghitung nilai TF-IDF dari sebuah term  $t$  dalam dokumen  $d$  dihitung dengan mengalikan frekuensi kemunculan term tersebut dalam dokumen (TF) dengan nilai IDF menggunakan rumus :

$$tf - idf(t, d) = tf(t, d) * idf(t)$$

Dengan demikian, kata yang memiliki frekuensi tinggi atau sering muncul dalam suatu dokumen namun jarang ditemukan pada dokumen lain akan memperoleh bobot TF-IDF yang tinggi, menandakan bahwa istilah tersebut memiliki signifikansi yang lebih besar dalam konteks analisis sentimen.

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

Support Vector Machine (SVM) merupakan salah satu algoritma dalam machine learning (pembelajaran mesin) yang pengaplikasiannya untuk regresi maupun klasifikasi. Algoritma ini bekerja dengan cara menentukan hyperlane yang mampu memisahkan data ke dalam dua kategori secara optimal dengan margin maksimal (Rifqi dkk., 2024). Dalam penerapannya untuk analisis sentimen, SVM dapat dimanfaatkan perannya sebagai pembeda tweet dengan sentimen positif (+1) dan tidak positif (-1) menggunakan vektor pendukung sebagai penentu batas klasifikasi. Fungsi klasifikasi dinyatakan dalam  $f(x) = w^T x + b$ , di mana margin ditentukan berdasarkan jarak antara hyperplane dengan data terdekat dari masing-masing kelas (Widowati, 2020).

Dalam menghadapi data yang tidak terdistribusi secara linear, SVM menggunakan teknik kernel, yang bertujuan untuk mentransformasikan data ke dalam ruang fitur berdimensi lebih tinggi sehingga pemisahan secara linear menjadi memungkinkan. Pada penelitian ini, digunakan kernel Radial Basis Function (RBF), yang dirumuskan sebagai  $K(x_i, x) = \exp(-\gamma \|x_i - x\|^2)$ . Hasil dari fungsi kernel ini digunakan dalam optimasi melalui metode Lagrange Dual untuk menentukan support vector yang relevan. Pemilihan kernel dan parameter seperti C dan Gamma ( $\gamma$ ) sangat memengaruhi kinerja klasifikasi, terutama ketika data memiliki pola yang kompleks (Adilah & Alit, 2023).

Algoritma SVM dengan kernel linear digunakan untuk melakukan klasifikasi karena memiliki kemampuan yang efektif dalam mengolah data berdimensi tinggi seperti teks, serta telah terbukti memberikan performa yang baik dalam berbagai penelitian analisis sentimen. Untuk memastikan evaluasi model yang lebih andal dan mengurangi potensi bias, data dibagi menggunakan metode 5-Fold Cross Validation (Fremmuzar & Baita, 2023).

#### 5. Evaluasi Model

Menggunakan confusion matrix dilakukan evaluasi terhadap kinerja model, yaitu matriks perbandingan antara hasil prediksi model dengan label aktual (Sathyanarayanan, 2024). Berdasarkan matriks ini dapat dilakukan perhitungan sejumlah matrik utama, yaitu akurasi, presisi, recall, dan F1-score. Akurasi menggambarkan sejauh mana prediksi model sesuai dengan label sebenarnya, dan dihitung dengan rumus :

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN}$$

di mana TP (True Positive) merupakan jumlah prediksi yang benar saat model mengklasifikasikan data sebagai positif, sementara TN (True Negative) adalah jumlah prediksi yang tepat ketika data diklasifikasikan sebagai negatif. FP (False Positive) menunjukkan jumlah kesalahan prediksi ketika data seharusnya negatif namun diprediksi positif, sedangkan FN (False Negative) adalah jumlah kesalahan saat data yang sebenarnya positif diprediksi sebagai negatif. Untuk menggambarkan sejauh mana model dapat secara akurat mengklasifikasikan data ke dalam teks yang benar maka dapat dihitung dengan rumus presisi sebagai:

$$Precision = \frac{TP}{TP + FP}$$

Sementara itu, recall menunjukkan sensitivitas model terhadap data aktual, khususnya kemampuandalam mengenali semua data positif, dengan rumus:

$$Recall = \frac{TP}{TP + FN}$$

Untuk mendapatkan keseimbangan antara presisi dan recall, digunakan metrik F1-score, yang merupakan rata-rata harmonis dari keduanya dan dihitung dengan rumus :

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Hasil dari evaluasi menunjukkan bahwa model cukup dapat mengidentifikasi secara efektif terhadap opini masyarakat yang bersifat negatif. Hal ini penting karena opini-opini negatif cenderung lebih beragam dalam bentuk ungkapan, sehingga keberhasilan model dalam mengidentifikasikannya mencerminkan ketajaman dan ketepatan analisis sentimen yang dilakukan.

### Hasil dan Pembahasan

Data dikumpulkan dari platform Twitter / X melalui menggunakan Twitter API bearer token dan library Tweepy di Python dari tanggal 1 Maret 2025 hingga 31 Maret 2025. Data mentah hasil scrappingnya dengan kata kunci 'UU TNI' mendapatkan hasil 500 data, kemudian data tersebut diberi label secara manual terhadap 500 tweet yang didapat dari proses scraping, diperoleh 295 tweet (58,99%) yang mengandung sentimen negatif dan 205 tweet (41,01%) yang mengandung sentimen positif terhadap UU TNI. Hal ini mencerminkan kecenderungan masyarakat untuk merespons isu ini secara kritis dan skeptis. Sample dari data tersebut adalah sebagai berikut :

**Tabel 1.** Hasil Scraping dan Pelabelan

Text	Label
Para pemohon menilai bahwa pembentukan revisi UU TNI tersebut tidak dilakukan secara terbuka dan minim partisipasi masyarakat. Salah satu yang mereka soroti adalah proses pembahasan dalam rapat konsinyering yang dilakukan di luar gedung DPR. Padahal sidang tersebut bersifat erga <a href="https://t.co/LkZiJOVDFg">https://t.co/LkZiJOVDFg</a>	1
@_AnakKolong @Puspen_TNI Perlu dikaji lebih mendalam , terutama oleh Presiden @prabowo, seperti dibuatkannya UU yg ketat dan tegas untuk hal tsb. #JasMerahdenganAngkatanKelima	0
@03__nakula Harusnya uu TNI yg lu pertanyakan, bukan malah uu perampasan asset koruptor. Kek gini logika berpikirnya anggota dewan yg terhormat????	1
@165Hati RUU ini tetap mengedepankan supremasi sipil. Peran TNI dalam jabatan sipil akan diatur dan diawasi secara ketat, bukan seperti yang dibayangkan oleh pihak yang menolak tanpa membaca keseluruhan isi revisi UU ini <a href="https://t.co/xgXbqiEoCj">https://t.co/xgXbqiEoCj</a>	1
@AdayangViralnic UU TNI yang baru adalah bukti negara serius memodernisasi pertahanan	0

Text	Label
@anaknegeri Revisi UU TNI memperjelas batasan dan tanggung jawab TNI	0
@analisismerdeka Terlalu banyak pasal karet dalam UU TNI.	1

Setelah data tweet dikumpulkan, tahap selanjutnya adalah melakukan preprocessing agar data siap dianalisis menggunakan teknik pemrosesan teks. Proses ini melibatkan beberapa tahapan penting, dimulai dari *cleaning*, yaitu membersihkan tweet dari elemen-elemen yang tidak diperlukan seperti URL, mention, hashtag, angka, dan karakter non-alfabet untuk mengurangi noise dalam proses klasifikasi. Misalnya, teks "@user UU TNI ini #berbahaya!!! https://t.co/..." dibersihkan menjadi "UU TNI ini berbahaya". Setelah itu dilakukan *case folding* dengan mengubah seluruh huruf dalam teks menjadi huruf kecil agar konsisten dan menghindari perbedaan makna akibat huruf kapital, contohnya "Saya Mendukung UU TNI!" menjadi "saya mendukung UU TNI!". Selanjutnya, *tokenizing* dilakukan untuk memecah teks menjadi bagian-bagian kata atau token, seperti "UU TNI ini berbahaya" menjadi ['ruu', 'tni', 'ini', 'berbahaya']. Kemudian, dilakukan *normalisasi kata tidak baku* untuk mengubah kata-kata seperti "gk", "nggak", "ga", dan "tdk" menjadi bentuk baku "tidak". Proses dilanjutkan dengan *filtering* atau *stopword removal*, yaitu mengeliminasi kata umum yang kurang bermakna seperti "ini", sehingga token ['ruu', 'tni', 'ini', 'berbahaya'] menjadi ['ruu', 'tni', 'berbahaya']. Tahap terakhir adalah *stemming*, yakni mengubah kata menjadi bentuk dasarnya menggunakan alat seperti Sastrawi, misalnya "berbahaya" dan "mendukung" menjadi "bahaya" dan "dukung". Setelah melalui seluruh tahapan tersebut, data teks mentah berubah menjadi data yang bersih, seragam, dan siap digunakan dalam analisis sentimen, dengan hasil akhir berupa daftar token dalam bentuk dasar seperti ['ruu', 'tni', 'bahaya'].

Tahap preprocessing telah selesai maka langkah selanjutnya adalah mengubah data teks menjadi representasi numerik dengan metode Term Frequency–Inverse Document Frequency (TF-IDF). Dimulai dengan menyusun dokumen teks. Misalnya, tiga dokumen sebagai berikut:

**Tabel 2.** Contoh Teks Dokumen

Dokumen	Kalimat
D1	tni bahaya ruu
D2	tni revisi ruu kontroversi
D3	rakyat tolak bahaya revisi

Langkah pertama adalah membuat vocabulary, yaitu daftar kata unik dari seluruh dokumen. Kata-kata tersebut adalah: ['tni', 'bahaya', 'ruu', 'revisi', 'kontroversi', 'rakyat', 'tolak'] Jumlah term unik: 7. Selanjutnya, dilakukan perhitungan Term Frequency (TF), yaitu jumlah kemunculan kata dalam satu dokumen dibagi jumlah total kata dalam dokumen tersebut. Contoh perhitungan untuk D1:

**Tabel 3.** TF untuk Dokumen D1

Term	Jumlah Muncul	TF
tni	1	$1/3 \approx 0.333$
bahaya	1	$1/3 \approx 0.333$
ruu	1	$1/3 \approx 0.333$
revisi	0	0.000
kontroversi	0	0.000
rakyat	0	0.000
tolak	0	0.000

Kemudian dihitung Document Frequency (DF), yaitu jumlah dokumen yang mengandung masing-masing term:

**Tabel 4.** DF untuk Seluruh Dokumen

Term	DF (Jumlah Dokumen Mengandung Term)
tni	2 (D1, D2)
bahaya	2 (D1, D3)
ruu	2 (D1, D2)
revisi	2 (D2, D3)
kontroversi	1 (D2)
rakyat	1 (D3)
tolak	1 (D3)

Langkah berikutnya adalah menghitung Inverse Document Frequency (IDF).

**Tabel 5.** IDF untuk Seluruh Term

Term	IDF (log base 10)
tni	$\log(3/2) \approx 0.1761$
bahaya	$\log(3/2) \approx 0.1761$
ruu	$\log(3/2) \approx 0.1761$
revisi	$\log(3/2) \approx 0.1761$
kontroversi	$\log(3/1) \approx 0.4771$
rakyat	$\log(3/1) \approx 0.4771$
tolak	$\log(3/1) \approx 0.4771$

Setelah memperoleh nilai TF dan IDF, dilakukan perhitungan TF-IDF untuk masing-masing term pada dokumen.

**Tabel 6.** TF-IDF untuk Dokumen D1

Term	TF	IDF	TF-IDF
tni	0.333	0.1761	$0.333 \times 0.1761 \approx 0.0587$
bahaya	0.333	0.1761	$0.333 \times 0.1761 \approx 0.0587$
ruu	0.333	0.1761	$0.333 \times 0.1761 \approx 0.0587$
revisi	0.000	0.1761	0.000
kontroversi	0.000	0.4771	0.000
rakyat	0.000	0.4771	0.000
tolak	0.000	0.4771	0.000

Dengan demikian, vektor TF-IDF untuk dokumen D1 berdasarkan urutan vocabulary adalah: ['tni', 'bahaya', 'ruu', 'revisi', 'kontroversi', 'rakyat', 'tolak']  $\approx$  [0.35, 0.35, 0.35, 0.00, 0.00, 0.00, 0.00]. Model SVM kemudian dilatih dan diuji menggunakan 5-Fold Cross Validation. Hasil pengujian menunjukkan bahwa model memiliki akurasi rata-rata sebesar 78,99%. Fold ke-5 menunjukkan performa tertinggi dengan akurasi sebesar 83,54%.

**Tabel 7.** Hasil Pengujian Cross Validation

Fold	Akurasi
1	0.7722
2	0.8101
3	0.7595
4	0.7722
5	0.8354
Rata-rata	0.7899
Terbaik di Fold	5 (0.8354)

Tabel ini menunjukkan hasil akurasi per fold pada pengujian model dengan teknik cross validation. Selain akurasi, evaluasi dilakukan menggunakan confusion matrix dan classification report. Hasil evaluasi menunjukkan F1-score tertinggi diperoleh pada sentimen negatif sebesar 0,83, sedangkan sentimen positif berada pada 0,78. Hal ini menunjukkan bahwa model lebih efektif mengidentifikasi tweet bernada negatif.

**Tabel 8.** Hasil Pengujian Confusion Matrix

	Prediksi: 0	Prediksi: 1
Aktual: 0	33	12
Aktual: 1	7	47

Tabel ini menampilkan hasil evaluasi klasifikasi meliputi precision, recall, dan F1-score. Secara keseluruhan, hasil analisis mendukung temuan bahwa mayoritas masyarakat memiliki persepsi negatif terhadap revisi UU TNI. Kecenderungan ini dapat dilihat sebagai bentuk kekhawatiran atas potensi tergerusnya supremasi sipil dan masuknya kembali TNI ke dalam urusan sipil, sebagaimana pernah terjadi pada masa Orde Baru (Romadhona & Isnain, 2024). Penelitian ini juga mengkonfirmasi efektivitas penggunaan metode SVM dalam analisis sentimen terhadap isu-isu kebijakan publik. Studi sebelumnya juga menunjukkan hasil serupa dalam konteks isu subsidi motor listrik (Sriani, Gultom, &

Suhardi, 2023), serta kenaikan harga BBM ('Adilah & Alit, 2023). Oleh karena itu, pendekatan ini dapat diandalkan sebagai alat bantu pengambilan keputusan yang berbasis data publik.

Media sosial, dalam hal ini Twitter, terbukti menjadi kanal penting dalam merepresentasikan suara masyarakat secara langsung. Data yang diperoleh melalui platform ini dapat menjadi masukan berharga bagi para legislator dan pengambil kebijakan untuk menimbang kembali muatan dalam RUU yang menuai polemik di publik.

Langkah selanjutnya adalah menerapkan model *Support Vector Machine* (SVM) untuk mendapatkan hasil dari data uji, di mana data uji ini diambil sebanyak 20% dari keseluruhan data pelatihan. Hasil dari proses pelatihan menunjukkan bahwa terdapat 233 data berlabel negatif (label 1) dengan distribusi sebesar 58,99%, dan 162 data berlabel positif (label 0) sebesar 41,01%.

**Tabel 9.** Hasil Train

Label	Data	Akurasi
Label 1 (negatif)	233	58.99%
Label 0 (positif)	162	41.01%
Total		100%

Perlu dicatat bahwa angka persentase ini bukan merupakan akurasi keseluruhan model, melainkan hanya menggambarkan proporsi distribusi label dalam data pelatihan yang digunakan. Selanjutnya, pengujian dilakukan terhadap data uji dan hasilnya disajikan dalam sebagai berikut :

**Tabel 10.** Hasil test

Label	Data	Akurasi
Label 1 (negatif)	54	54.55%
Label 0 (positif)	45	45.45%
Total		100%

Di mana terdapat 54 data berlabel negatif (54,55%) dan 45 data berlabel positif (45,45%). Hasil ini menunjukkan bahwa pada data baru, model SVM mengenali data negatif sedikit lebih baik daripada data positif, meskipun distribusi antar label masih cukup seimbang. Berikutnya model diuji menggunakan data uji (test set) dan diukur menggunakan k-fold cross validation dan confusion matriks guna mengetahui akurasi dari model SVM ini. Terdapat pula hasil dari pengujian yang dilaksanakan yakni dibawah ini.

**Tabel 11.** Hasil Pengujian Cross Validation

Fold	Akurasi
1	0.7722
2	0.8101
3	0.7595
4	0.7722
5	0.8354
Rata-rata	0.7899
Terbaik di Fold	5 (0.8354)

**Tabel 12.** Hasil Pengujian Confusion Matrix

	Prediksi: 0	Prediksi: 1
Aktual: 0	33	12
Aktual: 1	7	47

**Tabel 13.** Hasil Pengujian Classification

Class	Precision	Recall	F1-Score	Support
0	0.82	0.73	0.78	45
1	0.80	0.87	0.83	54
Accuracy			0.81	99
Macro Avg	0.81	0.80	0.80	99
Weighted Avg	0.81	0.81	0.81	99

Berdasarkan tabel 11 sampai dengan 13 yaitu hasil evaluasi model, diperoleh akurasi rata-rata sebesar 78,99% dari lima kali cross-validation, dengan nilai tertinggi sebesar 83,54% pada fold ke-5. Hasil confusion matrix memperlihatkan bahwasanya model dapat mengklasifikasikan data dengan cukup baik, di mana 33 data kelas 0 dan 47 data kelas 1 berhasil diklasifikasikan dengan benar, sementara terdapat 12 kesalahan klasifikasi untuk kelas 0 dan 7 untuk kelas 1. Dari classification report, diketahui bahwa precision untuk kelas 0 adalah 0,82 dan recall-nya 0,73, sedangkan untuk kelas 1 memiliki precision 0,80 dan recall lebih tinggi yakni 0,87. Nilai f1-score yang lebih tinggi pada kelas 1 (0,83) memperlihatkan bahwasanya model lebih baik dalam mengenali data kelas 1 dibanding kelas 0. Secara keseluruhan, model memiliki performa yang cukup seimbang dengan nilai macro dan weighted average f1-score sebesar 0,80–0,81, menandakan model bekerja cukup baik di kedua kelas dengan distribusi data yang relatif seimbang.

## Simpulan

Penelitian ini menyajikan analisis sentimen masyarakat terhadap kebijakan undang-undang tentara nasional indonesia (UU TNI) menggunakan support vector machine (SVM). Penelitian ini membuktikan bahwa metode SVM dengan TF-IDF dapat digunakan secara efektif untuk analisis sentimen masyarakat terhadap kebijakan pemerintah. Dengan akurasi rata-rata 78,99%, temuan menunjukkan bahwa mayoritas masyarakat memiliki sentimen negatif terhadap UU TNI. Hasil ini menjadi penting bagi pembuat kebijakan untuk mengkaji ulang substansi revisi UU TNI agar tetap sejalan dengan prinsip demokrasi dan supremasi sipil.

Untuk penelitian selanjutnya disarankan agar untuk cakupan data lebih diperluas baik dari segi periode waktu pengambilan maupun sumber platform media sosial lainnya seperti TikTok, Youtube atau Instagram comments. Selain itu, metode lain seperti deep learning (misalnya LSTM atau BERT) dapat dicoba agar dapat meningkatkan akurasi klasifikasi, Sebagai rekomendasi penelitian ini dapat menjadi pertimbangan bagi pembuat kebijakan untuk lebih melibatkan masyarakat dalam berpartisipasi dalam proses legislasi, serta melakukan kajian dampak bagi sosial terhadap setiap perubahan kebijakan. Analisis berbasis data dapat dimanfaatkan sebagai sistem yang mendukung keputusan dalam merumuskan kebijakan yang responsif terhadap masyarakat.

## Daftar Pustaka

- 'Adilah, H. S., & Alit, R. (2023). Analisis Sentimen Masyarakat Twitter Terhadap Kebijakan Pemerintah Dalam Menaikkan Harga Bahan Bakar Minyak Dengan Menggunakan Metode Support Vector Machine. *Journal of Informatics and Computer Science (JINACS)*, 5(02), 201–215. <https://doi.org/10.26740/jinacs.v5n02.p201-215>
- Amran, A., Tamrin, A., Pasanda, D., & Haba, R. (2022). Analisis Hukum Terhadap Perubahan Norma Undang-Undang No.34 Tahun 2004 Tentang Tentara Nasional Indonesia. *Sawerigading Law Journal*, 1(1), Article 1. <https://doi.org/10.62084/slj.v1i1.124>
- Dzulkarnain, T., Ratnawati, D. E., & Rahayudi, B. (2024). Penggunaan Metode Naïve Bayes Classifier pada Analisis Sentimen Penilaian Masyarakat Terhadap Pelayanan Rumah Sakit di Malang. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(5), 993–1000. <https://doi.org/10.25126/jtiik.2024117979>
- Firdaus, M. F., Ratnawati, D. E., & Setiawan, N. Y. (2024). Analisis Sentimen Berbasis Aspek Pada Ulasan Pelanggan Restoran Menggunakan Algoritma Support Vector Machine (Studi Kasus: Depot Bamara). *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(6), 1265–1272. <https://doi.org/10.25126/jtiik.2024117564>
- Fremmuzar, P., & Baita, A. (2023). Uji Kernel SVM dalam Analisis Sentimen Terhadap Layanan Telkomsel di Media Sosial Twitter. *Komputika : Jurnal Sistem Komputer*, 12(2), 57–66. <https://doi.org/10.34010/komputika.v12i2.9460>
- Frianda, G. I., Sriani, & Suhardi. (2023). Analisis Sentimen Kebijakan Pemberian Subsidi Motor Listrik Menggunakan Metode Support Vector Machine. *JURNAL FASILKOM*, 13(3), 511–517. <https://doi.org/10.37859/jf.v13i3.6225>
- Hardyatman, I. D., & Hasan, F. N. (2025). Analisis Sentimen Masyarakat Terhadap Rencana Kenaikan PPN 12% Di Indonesia Pada Media Sosial X Menggunakan Metode Decision Tree. *Journal of Information System Research (JOSH)*, 6(2), Article 2. <https://doi.org/10.47065/josh.v6i2.6573>
- Hatta, M. S. (2021). Clustering Pada Data Sentimen Penggunaan Transportasi Online Menggunakan Algoritma Spectral Clustering [Telkom University]. <https://repository.telkomuniversity.ac.id/pustaka/174184/clustering-pada-data-sentimen-penggunaan-transportasi-online-menggunakan-algoritma-spectral-clustering.html>
- Kariawan, I. M., Haerani, H., & Karyati, S. (2022). Peranan Tentara Nasional Indonesia Dalam Penyelenggaraan Pertahanan Keamanan Menurut Undang-Undang Nomor 34 Tahun 2004 Tentang Tentara Nasional Indonesia. *Unizar Recht Journal (URJ)*, 1(4). <https://urj.unizar.ac.id/urj/article/view/27>
- Karo, I. M. K., Karo, J. A. K., Yuniyanto, Y., Hariyanto, H., Falah, M., & Ginting, M. (2023). Analisis Sentimen Ulasan Aplikasi Info BMKG di Google Play Menggunakan TF-IDF dan Support Vector Machine. *Journal of Information System Research (JOSH)*, 4(4), Article 4. <https://doi.org/10.47065/josh.v4i4.3943>

- Kuswandaru, K., & Akbar, M. (2024). Klasifikasi Dialek Bahasa Inggris British dan Amerika menggunakan Support Vector Machine. *TIN: Terapan Informatika Nusantara*, 4(10), 652–659. <https://doi.org/10.47065/tin.v4i10.4965>
- Maulaya, A. K. & Junadhi. (2022). Analisis Sentimen Menggunakan Support Vector Machine Masyarakat Indonesia Di Twitter Terkait Bjorka. *Jurnal CoSciTech (Computer Science and Information Technology)*, 3(3), 495–500. <https://doi.org/10.37859/coscitech.v3i3.4358>
- Nuzulianto, F. M., & Sukalumba, I. S. (2025). Analisis Dampak UU TNI 2025 Terhadap Potensi Terbentuknya Junta Militer. *Jurnal Studi Ilmu Sosial Dan Politik*, 5(1), Article 1. <https://doi.org/10.35912/jasispol.v5i1.4481>
- Octa Nuryawan, A. T., Hasbullah, M., Rizal, M., Rajab, M. F., & Agustina, N. (2023). Algoritma Decision Tree Untuk Analisis Sentimen Public Terhadap Marketplace Diindonesia. *Naratif: Jurnal Nasional Riset, Aplikasi dan Teknik Informatika*, 5(1), 18–25. <https://doi.org/10.53580/naratif.v5i1.186>
- Oktavianus, A., Sinabutar, R. O. F., & Shafa, A. B. (2025). Implikasi Perubahan Undang-Undang TNI Terhadap Struktur Ketatanegaraan Indonesia “Sebuah Kajian Terhadap Pengaruh Dwi Fungsi ABRI.” *Khatulistiwa: Jurnal Pendidikan Dan Sosial Humaniora*, 5(2), Article 2. <https://doi.org/10.55606/khatulistiwa.v5i2.5896>
- Pratama, H. I., & Prasetyaningrum, P. T. (2025). Penerapan Support Vector Machine untuk Analisis Sentimen pada Google Review Hotel. *Journal of Information System Research (JOSH)*, 6(2), Article 2. <https://doi.org/10.47065/josh.v6i2.6645>
- Putra, A., Haeirudin, D., Khairunnisa, H., & Latifah, R. (2021). Analisis Sentimen Masyarakat Terhadap Kebijakan PPKM Pada Media Sosial Twitter Menggunakan Algoritma Svm. *Seminar Nasional Sains dan Teknologi*.
- Rifqi, M. R. A. F., Armansyah, & Rifqi Al Fauzan, M. (2024). Kombinasi TF-IDF dan Neural Network Untuk Pelayanan Informasi Al-Qur’an Dalam Bentuk Chatbot. *JURNAL FASILKOM*, 14(2), 318–324. <https://doi.org/10.37859/jf.v14i2.7286>
- Rofiqi, L., & Akbar, M. (2024). Analisis Sentimen Terkait RUU Perampasan Aset dengan Support Vector Machine. *JEKIN - Jurnal Teknik Informatika*, 4(3), 529–538. <https://doi.org/10.58794/jekin.v4i3.824>
- Romadhona, W., & Isnain, A. R. (2024). Analisis Sentimen Pengguna Media Sosial Terhadap Kebijakan Kenaikan Pajak Hiburan Menggunakan Metode SVM (Support Vector Machine). *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 9(4), 2185–2195. <https://doi.org/10.29100/jupi.v9i4.5603>
- Sari, D. I., Wati, Y. F., & Widiastuti. (2020). Analisis Sentimen Dan Klasifikasi Tweets Berbahasa Indonesia Terhadap Transportasi Umum Mrt Jakarta Menggunakan Naïve Bayes Classifier. *Jurnal Ilmiah Informatika Komputer*, 25(1), 64–75. <https://doi.org/10.35760/ik.2020.v25i1.2427>
- Sathyanarayanan, S. (2024). Confusion Matrix-Based Performance Evaluation Metrics. *African Journal of Biomedical Research*, 4023–4031. <https://doi.org/10.53555/AJBR.v27i4S.4345>

- 
- Wibowo, I. S., Witanti, A., & Susilawati, I. (2024). Keyword Extraction Judul Berita Online Di Indonesia Menggunakan Metode *TF-IDF* | *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*. <https://jurnal.mdp.ac.id/index.php/jatisi/article/view/6718>
- Widowati, T. T. (2020). Analisis Sentimen Twitter Terhadap Tokoh Publik Dengan *Algoritma Naïve Bayes Dan Support Vector Machine* [S1, Universitas Mercu Buana Jakarta]. <https://repository.mercubuana.ac.id/61623/>
- Yusanto, Y., & Akbar, M. (2024). Analisis Sentimen Jogja Darurat Sampah di Twitter menggunakan Ekstraksi Fitur Model Word2Vec dan Convolutional Neural Network. *TIN: Terapan Informatika Nusantara*, 4(10), 679–686. <https://doi.org/10.47065/tin.v4i10.4952>