

Analisis Sentimen Publik Pengesahan UU TNI Di Media Sosial X Menggunakan SVM

DOI: <http://dx.doi.org/10.35889/jutisi.v14i2.3046>

Creative Commons License 4.0 (CC BY – NC)



Budi Susarianto^{1*}, Taufik Nizami², Khairullah³
 Teknik Informatika, STMIK Banjarbaru, Banjarbaru, Indonesia
 *Email Corresponding Author: budisusarianto@gmail.com

Abstract

The ratification of the Indonesian National Armed Forces Bill (RUU TNI) into law by the House of Representatives (DPR RI) on March 20, 2025, sparked various public reactions. Several articles, such as Article 7(2)(b) and Article 47(2), are considered to potentially revive the military's dual function and threaten democracy and civilian supremacy. Many people expressed their opinions on social media platform X (Twitter). This study analyzes public sentiment toward the TNI Law using the Support Vector Machine (SVM) method with 1,001 tweets collected via web scraping and processed through cleansing, tokenization, and stemming. SVM classified the sentiments into positive, neutral, and negative categories, achieving an accuracy of 94.66%. The highest recall was found in neutral sentiment (1.00), followed by positive (0.98), and negative (0.88). The results showed that negative and neutral sentiments were the most prevalent, providing recommendations to the government for more participatory and democratic policymaking.

Keywords: Sentiment Analysis; Support Vector Machine; TNI Law; Social Media; Web Scraping; Text Classification; Public Policy

Abstrak

Pengesahan RUU TNI menjadi Undang-Undang oleh DPR RI pada 20 Maret 2025 memicu berbagai reaksi masyarakat. Beberapa pasal, seperti Pasal 7 ayat (2) huruf b dan Pasal 47 ayat (2), dinilai bisa menghidupkan kembali dwifungsi militer dan mengancam demokrasi serta supremasi sipil. Masyarakat pun ramai menyampaikan pendapatnya di media sosial X (Twitter). Penelitian ini menganalisis sentimen publik terhadap UU TNI dengan metode *Support Vector Machine* (SVM) menggunakan 1001 cuitan yang dikumpulkan lewat *web scraping* dan diproses melalui *cleansing*, tokenisasi, dan *stemming*. SVM mengklasifikasikan sentimen menjadi positif, netral, dan negatif, dengan akurasi 94,66%. *Recall* tertinggi ada di sentimen netral (1,00), lalu positif (0,98), dan negatif (0,88). Hasilnya, sentimen negatif dan netral paling banyak muncul, memberikan masukan bagi pemerintah untuk merumuskan kebijakan yang lebih partisipatif dan demokratis.

Kata kunci: Analisis Sentimen; Support Vector Machine; UU TNI; Media Sosial; Web Scraping; Klasifikasi Teks; Kebijakan Publik

1. Pendahuluan

Yayasan Lembaga Bantuan Hukum Indonesia (YLBHI) khawatir pengesahan revisi RUU TNI oleh DPR pada 20 Maret 2025 bisa mengembalikan dwifungsi militer seperti masa Orde Baru. Saat itu, TNI tidak hanya bertugas di bidang pertahanan, tapi juga terlibat dalam politik, sosial, dan ekonomi. Hal ini berisiko melemahkan demokrasi, supremasi sipil, dan membuka celah pelanggaran HAM [1]. Kekhawatiran itu terutama muncul karena Pasal 7 ayat (2) huruf b dan Pasal 47 ayat (2) yang memberi peluang bagi prajurit aktif menduduki jabatan sipil di kementerian, lembaga politik, keamanan, serta lembaga negara seperti Kejaksaan dan Mahkamah Agung [2]. Pasal-pasal bermasalah ini dikhawatirkan melemahkan pengawasan sipil atas militer, sehingga militer bisa memperluas kekuasaannya di luar fungsi pertahanan. Tanpa pengaturan tegas, peluang penyalahgunaan kekuasaan dan pelanggaran HAM akan

meningkat. Situasi ini bisa mengaburkan batas peran militer dan sipil, sama seperti masa lalu, dan mengancam reformasi demokrasi [3]. Pentingnya tema ini terletak pada dampaknya terhadap stabilitas politik, keamanan nasional, dan perlindungan hak asasi manusia, sehingga analisis sentimen publik menjadi alat krusial untuk memahami persepsi masyarakat dan memberikan masukan untuk kebijakan agar lebih demokratis dan akuntabel.

Situasi saat ini menunjukkan bahwa revisi UU TNI yang disahkan DPR pada Maret 2025 memicu perbincangan luas di media sosial X, di mana masyarakat dengan cepat menyebarkan opini positif, negatif, maupun netral dalam jumlah besar. Masalah yang muncul adalah sentimen mayoritas publik dalam 1000 cuitan tersebut cenderung negatif [4], menggambarkan kekhawatiran bahwa revisi ini bisa mengembalikan dwifungsi militer seperti masa Orde Baru, menambah demokrasi, dan membuka celah pelanggaran HAM. Kondisi ini dapat diukur melalui proporsi sentimen negatif yang signifikan, yang menunjukkan perlunya pemeriksaan lebih mendalam dan penyesuaian kebijakan agar sesuai dengan aspirasi masyarakat. Dengan penetrasi internet Indonesia mencapai 79,5% pada tahun 2024, media sosial menjadi sumber data real-time yang sangat efektif untuk mengamati dan merespons perubahan opini publik secara dinamis [5], sehingga analisis sentimen menggunakan metode *Support Vector Machine* (SVM) [6] sangat tepat dipakai untuk mengolah data dan gambaran menghasilkan tujuan guna membantu pemerintah mengambil kebijakan yang lebih responsif dan bertanggung jawab. Dengan dukungan data yang cukup dan metode yang teruji, solusi ini realistis dan berpotensi besar menjadi alat bantu kebijakan yang responsif dan berorientasi pada aspirasi masyarakat.

Konsep solusi dalam jurnal ini adalah mengoptimalkan metode *Support Vector Machine* (SVM) dengan teknik Grid Search yang dapat meningkatkan akurasi hingga 91% dengan mencari kombinasi parameter terbaik [7], serta menggabungkannya dengan metode lain seperti *K-Nearest Neighbors* (KNN) untuk meningkatkan akurasi analisis data sentimen teks yang kompleks. Pendekatan ini [8] sangat logis karena kombinasi teknik tersebut terbukti mampu menghasilkan model klasifikasi yang lebih akurat dan efisien dalam berbagai penelitian sebelumnya, termasuk dalam analisis opini publik yang bersifat dinamis dan beragam [9]. Dengan tingkat akurasi tinggi tersebut, solusi ini sangat tepat digunakan untuk memahami sentimen masyarakat secara terpercaya [10], sehingga dapat membantu pembuat kebijakan menyusun strategi yang efektif dan sesuai dengan aspirasi rakyat, memastikan respons yang cepat dan tepat terhadap dinamika opini publik.

Tujuan penelitian dalam jurnal ini adalah untuk menganalisis sentimen publik di media sosial Twitter terkait pengesahan revisi RUU TNI dengan menggunakan metode *Support Vector Machine* (SVM), guna memahami reaksi masyarakat secara obyektif dan cepat. Manfaat penelitian ini adalah membantu pemerintah dalam mengambil kebijakan yang lebih tepat, responsif, dan sesuai aspirasi publik, sekaligus menjaga demokrasi dan supremasi sipil di era digital. Dengan data yang diproses secara akurat, penelitian ini memberikan gambaran yang jelas tentang opini masyarakat yang dinamis dan kompleks, sehingga mampu menjadi alat penting untuk merespons perubahan sikap masyarakat secara real-time dan mendukung pengambilan keputusan yang bertanggung jawab.

2. Tinjauan Pustaka

Analisis sentimen masyarakat tentang kebijakan pembatasan kegiatan mikro juga dilakukan dengan algoritma SVM yang efektif mengelompokkan teks. Prosesnya terstruktur mulai dari pengumpulan data, pembersihan, hingga evaluasi model, sehingga hasilnya jelas dan terukur. Pendekatan ini [11] penting untuk menilai kebijakan publik dan bisa diterapkan untuk berbagai isu sosial. Penelitian [12] menunjukkan SVM tepat digunakan karena mampu menangani data teks dengan akurat, sehingga analisis sentimen menjadi andal. Selain itu, penelitian membandingkan SVM dengan metode C4.5 dalam mengklasifikasikan sentimen terkait vaksinasi COVID-19. Hasilnya, SVM lebih akurat dan membantu pembuat kebijakan menyusun strategi komunikasi yang lebih tepat sesuai harapan masyarakat.

Analisis sentimen kebijakan RUU TNI masih tahap awal karena kebijakan baru diumumkan, sehingga membuka peluang eksplorasi opini publik. Berbeda dengan RUU TNI, analisis kebijakan lain sudah banyak dilakukan sebagai dasar pendekatan serupa yang valid. Penelitian [13] menunjukkan SVM dengan Normalized Poly Kernel efektif mengolah teks kompleks seperti tweet dengan menangkap pola non-linear dan meningkatkan akurasi. Twitter sebagai sumber data relevan, namun memerlukan penyaringan karena banyak noise.

Kombinasi SVM dan *K-Medoid Clustering* membantu mengelompokkan data per topik dan menghilangkan konten tidak relevan untuk analisis lebih akurat dan fokus.

Penelitian sebelumnya [14] menggunakan *Support Vector Machine* (SVM) untuk analisis sentimen kebijakan PPKM mencapai akurasi 77,2%, presisi 83,3%, *recall* 68,7%, dan F1-score 75,11% dengan data Twitter, namun tanpa perbandingan dengan metode lain. Studi lain menunjukkan SVM memiliki akurasi 89,60% dalam analisis sentimen menteri Indonesia di Twitter, lebih unggul dibanding Naive Bayes yang 85,74%, mengindikasikan keunggulan SVM dalam menangkap opini publik meski diperlukan penelitian lebih lanjut untuk aplikasi kebijakan nasional yang lebih luas.

Media sosial akhir-akhir ini banyak menampilkan kegelisahan masyarakat terhadap kebijakan pemerintah, dengan unggahan dan komentar didominasi sentimen negatif yang mencerminkan ketidakpuasan dan kekhawatiran publik. Platform ini berperan penting sebagai wadah ekspresi sekaligus cerminan situasi sosial-politik terkini. Banyaknya sentimen negatif menjadi indikator ketidakpuasan publik yang penting bagi pembuat kebijakan untuk evaluasi. Laporan menyebutkan [16] tagar #IndonesiaGelap mengandung dominasi sentimen negatif terkait kebijakan ekonomi, sosial, dan politik, menjadi indikator utama opini publik dan tekanan sosial yang berpotensi memengaruhi kebijakan. Hal ini menegaskan perlunya pembuat kebijakan lebih memperhatikan aspirasi masyarakat.

Dalam konteks analisis sentimen, metode *Support Vector Machine* (SVM) telah terbukti efektif dalam mengklasifikasi opini publik di media sosial. SVM mampu menangani data teks yang kompleks dengan pola non-linear, serta memberikan akurasi tinggi dalam pengelompokan sentimen positif, negatif, maupun netral. Penggunaan kernel seperti *Normalized Polynomial Kernel* meningkatkan kemampuan SVM dalam menangkap fitur penting dari data tweet yang berisik dan tidak terstruktur. Oleh karena itu, penerapan SVM dalam analisis sentimen terhadap kebijakan RUU TNI sangat relevan untuk memperoleh pemahaman yang lebih akurat mengenai opini publik di Twitter.

Syamsu Rizal dari PKB menekankan pentingnya transparansi dalam pembahasan RUU TNI untuk mencegah kontroversi dan perlunya pembatasan ketat penempatan personel aktif TNI di jabatan sipil agar tidak terjadi tumpang tindih wewenang dan intervensi militer. Ia juga mengusulkan keterlibatan tim verifikasi independen untuk menghindari nepotisme dan campur tangan politik demi meningkatkan kredibilitas kebijakan [17]. Dalam konteks ini, *Support Vector Machine* (SVM) dapat membantu pengambil kebijakan memahami opini publik secara lebih baik. SVM, sebagai metode machine learning efektif untuk klasifikasi teks, memisahkan data ke kelas berbeda melalui batas optimal yang memaksimalkan margin antar kelas, sehingga menghasilkan klasifikasi akurat dan tahan overfitting, terutama pada data teks kompleks.

Penelitian yang dilaksanakan ini menggunakan metode *Support Vector Machine* (SVM) dengan pembobotan TF-IDF dan evaluasi detail lewat 5-Fold Cross Validation untuk menganalisis sentimen publik di Twitter selama periode pengesahan RUU TNI Maret 2025. Dengan akurasi hampir 79% dan F1-score tinggi pada sentimen negatif, penelitian ini memberikan gambaran kuat soal kekhawatiran masyarakat terhadap perluasan peran militer yang dapat mengancam demokrasi. Studi ini juga menegaskan bahwa analisis sentimen media sosial X sangat berguna untuk evaluasi kebijakan, meski masih terbatas pada data dan topik tertentu, sehingga membuka peluang pengembangan metode dan cakupan yang lebih luas.

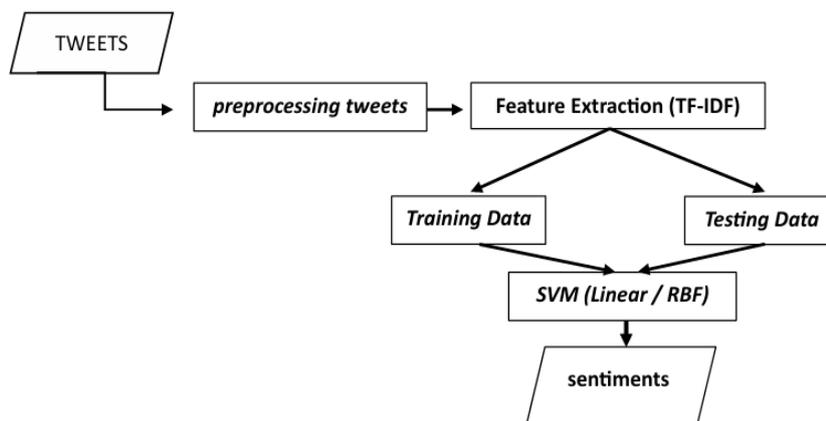
Berbeda dengan penelitian lain yang umumnya menganalisis opini publik pada isu kebijakan yang lebih umum atau dengan metode hybrid (misal kombinasi SVM dan *clustering* seperti *K-Medoid* [13] [18] [20] [21] [23]), kajian RUU TNI ini memberikan analisis mendalam pada kasus-kasus spesifik dengan dominasi sentimen negatif yang kuat [1]. Selain itu, sebagian penelitian lain [6][9][10][15][22] menggunakan algoritma yang berbeda atau mencakup data yang lebih luas, sedangkan jurnal [5], [7] [8] [12] [14] [18] ini menekankan validitas dan kinerja SVM dalam konteks isu tunggal, menampilkan ketajaman dan relevansi metode dalam situasi yang lebih terfokus. Pendekatan ini memperkuat bukti bahwa SVM tetap menjadi pilihan utama untuk menganalisis sentimen kebijakan di media sosial, sekaligus membuka ruang eksplorasi metode gabungan guna mengatasi kompleksitas data yang lebih beragam.

3. Metode Penelitian

Metode penelitian adalah serangkaian langkah sistematis yang dirancang untuk melaksanakan penelitian guna mencapai tujuan tertentu secara terstruktur dan terukur. Dalam penelitian ini, alur rancangan penelitian yang digunakan meliputi pengumpulan data Twitter,

pra-pemrosesan teks, ekstraksi fitur dengan TF-IDF, serta penerapan algoritma *Support Vector Machine* (SVM) untuk klasifikasi sentimen.

Proses analisis menggunakan SVM biasanya melibatkan representasi teks dalam bentuk numerik menggunakan TF-IDF (*Term Frequency-Inverse Document Frequency*) dan penerapan fungsi kernel untuk menangani data yang tidak linier. Fungsi kernel ini mentransformasikan data ke ruang berdimensi lebih tinggi sehingga memungkinkan pemisahan kelas yang lebih efektif. Keunggulan SVM dalam mengelola data besar dan pola rumit menjadikannya pilihan utama dalam memahami opini masyarakat secara tepat dan komprehensif [18]. Konsep dasar SVM melibatkan penggunaan fungsi kernel untuk mentransformasikan data ke ruang berdimensi lebih tinggi sehingga memungkinkan pemisahan antar kelas yang lebih efektif [7]. Ilustrasi mengenai tahapan kerja SVM dapat dilihat pada Gambar 1.



Gambar 1. Proses Kerja SVM

Proses analisis sentimen dengan *Support Vector Machine* (SVM) dimulai dari pengumpulan data Twitter melalui teknik *crawling*. Setelah itu, data diproses meliputi pembersihan teks, penghilangan kata tidak penting, normalisasi kata, dan pemisahan kata agar terstruktur. Selanjutnya, teks diubah menjadi representasi numerik menggunakan TF-IDF atau Word Embeddings (misalnya GloVe dan Word2Vec) untuk menangkap makna dan hubungan kata, yang sangat penting guna meningkatkan performa model SVM dalam klasifikasi sentimen. [20].

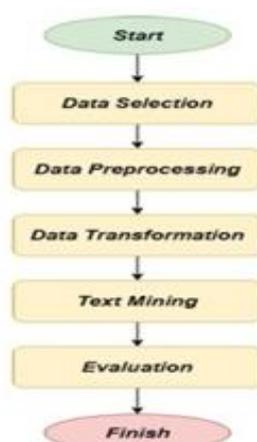
Data dibagi menjadi data latih dan uji menggunakan *hold-out*, *k-fold cross-validation*, dan stratified sampling untuk memastikan model bekerja baik pada data baru sekaligus mengurangi overfitting dan underfitting. Augmentasi data juga diterapkan untuk mengatasi ketidakseimbangan kelas [21]. Pelatihan SVM melibatkan pemilihan kernel yang sesuai Linear, Polynomial, atau RBF berdasarkan karakteristik data. Studi menunjukkan kernel Polynomial dan RBF memberikan akurasi lebih tinggi, sekitar 0,91 dan 0,90, dibandingkan Linear yang sekitar 0,86 [22].

Evaluasi model dilakukan dengan metrik akurasi, presisi, *recall*, dan F1-score untuk mengukur keberhasilan klasifikasi sentimen. Penggunaan metrik yang tepat sangat penting, terutama pada dataset yang tidak seimbang, karena akurasi saja tidak cukup menggambarkan performa model. Praktik terbaik seperti *cross-validation*, pembagian data yang proporsional, serta teknik *oversampling* dan *undersampling* juga diterapkan untuk meningkatkan kualitas model [23]. Setelah model dengan performa terbaik diperoleh, model tersebut dapat digunakan untuk menganalisis sentimen data baru secara otomatis, yang hasilnya sangat berguna dalam pengambilan keputusan kebijakan

Evaluasi model menggunakan akurasi, presisi, *recall*, dan F1-score untuk mengukur keberhasilan klasifikasi sentimen, terutama penting pada dataset tidak seimbang karena akurasi saja tidak cukup. Praktik terbaik seperti *cross-validation*, pembagian data proporsional, serta *oversampling* dan *undersampling* diterapkan untuk meningkatkan kualitas model [23]. Setelah diperoleh model terbaik, model tersebut digunakan untuk analisis sentimen data baru secara otomatis, yang bermanfaat dalam pengambilan keputusan kebijakan publik [24].

SVM dipilih karena kemampuannya dalam mengklasifikasi data teks yang kompleks dengan pola non-linear melalui penggunaan fungsi kernel, sehingga menghasilkan akurasi

tinggi dan tahan terhadap *overfitting*. Alur lengkap rancangan penelitian dapat dilihat pada Gambar 2.



Gambar 2. Alur penelitian

3.1. Data Selection

Dalam jurnal Hasibuan dan Suhardi, sebanyak 200 tweet terkait vaksin COVID-19 dikumpulkan dari Twitter. Setelah dilakukan *preprocessing* menggunakan TF-IDF, tersisa 137 data yang relevan. Untuk mengatasi ketidakseimbangan sentimen, data tersebut diseimbangkan dengan teknik SMOTE (*Synthetic Minority Over-sampling Technique*). Data kemudian dibagi menjadi data latih dan data uji agar model SVM dan C4.5 dapat dilatih secara optimal, menghasilkan akurasi tinggi, terutama pada model SVM yang mencapai 99,46%. Proses ini sangat penting untuk meningkatkan akurasi dalam analisis sentimen.

Untuk studi kasus RUU TNI, pengumpulan data dilakukan dengan menggunakan kata kunci "RUU TNI" pada rentang waktu 1 Februari 2005 hingga 25 Maret 2025, menghasilkan 1.001 tweet yang siap dianalisis lebih lanjut menggunakan metode yang sama.

3.2. Data Preprocessing

Data 1.001 tweet dengan kata kunci RUU TNI diproses melalui enam tahap pra-pemrosesan untuk membersihkan dan menyiapkan data. Langkah-langkahnya meliputi:

- 1) Pembersihan (*Cleansing*), menghapus simbol, tautan URL, tanda pagar (#), dan mention (@) yang mengganggu.
- 2) Pengubahan huruf (*Case Folding*), mengubah semua huruf kapital menjadi huruf kecil agar kata yang sama tidak terduplikasi.
- 3) Tokenisasi (*Tokenization*), memecah teks menjadi kata-kata berdasarkan spasi dan tanda baca.
- 4) Penghilangan kata tidak penting (*Stopword Removal*), menghapus kata-kata umum seperti "dan", "yang", dan "ke" yang tidak berkontribusi pada analisis.
- 5) Normalisasi (*Normalization*), mengubah kata tidak baku menjadi bentuk yang sesuai dengan aturan bahasa.
- 6) Pengembalian bentuk dasar kata (*Stemming*), mengembalikan kata berimbuhan ke bentuk dasar agar analisis lebih mudah dan tepat.

3.3. Labelling

Tahap pelabelan (*labelling*) bertujuan mengelompokkan data ke dalam kategori sentimen positif, negatif, atau netral. Proses ini sangat penting agar model dapat belajar mengenali pola sentimen secara akurat. Label yang tepat meningkatkan kejelasan analisis dan membantu model machine learning, khususnya *Support Vector Machine* (SVM), dalam memprediksi sentimen dengan lebih efektif dan andal.

3.4. Data Transformation

Transformasi data merupakan proses mengubah label sentimen seperti "positif," "netral," dan "negatif" menjadi representasi numerik agar algoritma machine learning, seperti

Support Vector Machine (SVM), dapat memprosesnya dengan lebih efektif. Dalam penelitian ini, kode angka yang digunakan adalah 2 untuk positif, 1 untuk netral, dan 0 untuk negatif. Konversi ini penting karena komputer lebih mudah mengolah data dalam bentuk numerik, sehingga model dapat mengenali dan membedakan sentimen dengan akurasi yang lebih tinggi. Selain itu, data numerik mempermudah proses pelatihan dan evaluasi model, sehingga menghasilkan analisis sentimen yang lebih tepat dan dapat diandalkan.

3.5. Text Mining

Data teks yang terkumpul diolah menggunakan teknik *text mining* dan diklasifikasikan dengan algoritma *Support Vector Machine* (SVM). Proses ini bertujuan mengekstrak pola penting dari data mentah sehingga menjadi informasi yang jelas dan mudah dipahami. Dengan SVM, setiap tweet dianalisis dan diberi label sentimen, sehingga peneliti dapat memahami opini publik secara lebih mendalam. Tahapan ini krusial karena mengubah data mentah menjadi hasil analisis yang berguna untuk pengambilan keputusan dan penelitian selanjutnya.

3.6. Evaluation

Evaluasi menyeluruh dilakukan untuk mengukur keakuratan dan keandalan model yang dibangun menggunakan algoritma tertentu, seperti *Support Vector Machine* (SVM). Evaluasi ini penting agar model mampu memberikan prediksi yang tepat dan konsisten pada data baru. Menurut Suryana dan Lestari (2023), kinerja model diukur dengan tiga metrik utama, yaitu *Accuracy*, *Precision*, dan *F1-Score*. *Accuracy* menunjukkan persentase prediksi yang benar, *Precision* menilai ketepatan model dalam mengidentifikasi sentimen positif, sedangkan *F1-Score* menggabungkan *Precision* dan *Recall* untuk memberikan gambaran performa yang lebih menyeluruh, terutama pada data yang tidak seimbang. Penggunaan metrik ini menjadikan evaluasi lebih komprehensif dan membantu menentukan kesiapan model dalam analisis sentimen media sosial [19].

4. Hasil Dan Pembahasan

Penelitian ini menganalisis sentimen pengguna aplikasi “X” terhadap kebijakan pemerintah terkait RUU TNI dengan menggunakan *algoritma Support Vector Machine* (SVM) untuk mengelompokkan opini menjadi sentimen positif, netral, dan negatif. Analisis ini membantu memahami persepsi masyarakat terhadap kebijakan tersebut secara lebih mendalam. Data diolah dan dimodelkan menggunakan Python, yang efektif dalam menangani data besar serta mendukung penerapan machine learning. Kualitas model dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* untuk memastikan hasil analisis dapat dipercaya dan prediksi sentimen relevan dalam konteks kebijakan publik.

Penggunaan SVM sebagai algoritma klasifikasi merupakan pendekatan yang tepat untuk pengelompokan sentimen karena kemampuannya dalam menangani data teks yang kompleks dan menghasilkan klasifikasi yang akurat. Pembagian sentimen menjadi tiga kategori utama memudahkan interpretasi hasil serta memberikan gambaran komprehensif mengenai opini publik terhadap RUU TNI.

Penelitian ini menjelaskan tujuan dan metode penelitian dengan bahasa yang cukup teknis namun tetap jelas. Penggunaan SVM sebagai algoritma klasifikasi menunjukkan pendekatan yang tepat untuk masalah pengelompokan sentimen, karena SVM dikenal handal dalam menangani data teks. Pembagian sentimen menjadi tiga kategori utama memudahkan interpretasi hasil dan memberikan gambaran yang komprehensif tentang opini publik.

4.1. Data Selection

Pengumpulan data dilakukan melalui metode *crawling* di platform “X” dengan fokus pada cuitan yang mengandung kata kunci “RUU TNI”. Proses ini berhasil mengumpulkan sebanyak 1.001 tweet yang menjadi sumber utama untuk analisis sentimen. Selain mengumpulkan data dalam jumlah besar, *crawling* juga memastikan bahwa data yang diperoleh relevan dan mencerminkan opini publik secara aktual. Tahap ini sangat penting sebagai fondasi awal penelitian karena kualitas dan kuantitas data yang dikumpulkan sangat memengaruhi akurasi dan validitas hasil analisis selanjutnya. Tabel 1 berikut menunjukkan dataset awal yang diperoleh melalui teknik *crawling* tersebut.

Tabel 1. Dataset awal hasil *crawling* data

No	Date	User	Tweet
1.	24-03-2025, 23:49:54	YuvEbig	bukannya Pemerintahan sekarang yang cabut atau melemah atau seenggaknya RUU TNI & POLRI dicabut yang dapet malah ini gimana ga rentan dipermainkan narasinya coba? Semoga aja Oposisi tidak sebodoh yang sudah-sudah
2.	24-03-2025, 23:47:02	https_jjisvng	@tropicsouhls oalaa gitu ya kak. sejujurnya smnjak ruu tni di sahkan kita tuh jdi susah buat mikir positif ke aparat' takut mreka macem'atau gimana gituu kan. tpi intinya dmn mn kt jg hrs ttp berhati'sm siapapun itu. anw thanks ya kak infonyaa
3.	24-03-2025, 23:49:54	Rosalin020292	@Heraloebss @kamto_adi @prabowo @DPR_RI batalkan itu RUU baru TNI sebelum semuanya terlambat. Jika dibiarkan bukan hanya emosi mahasiswa bisa menyebar di masyarakat... Hingga ke mancanegara ... Hingga negara hancur korban dimana2 diakhir rusia dan Amerika akan mempersenjatai rakyat sipil.
4.	24-03-2025, 23:49:54	ImperfectDilan	pemerintah perlu lebih tegas ya makanya tegas dong tolak RUU TNI & POLRI terus urus UU perampasaan aset koruptor ikutin suara rakyat kita semua juga ga bakal tuh gaduhin istana kalo kerjanya emang bener mah tolol
5.	24-03-2025, 23:49:54	grok	@alfatih212426 Rakyat bisa menentang RUU TNI Polri dan Kejaksaan lewat demo damai petisi lobi DPR kampanye media sosial atau gugatan hukum ke MK. RUU ini kontroversial karena diduga memperluas kuasa dan kurangi pengawasan sipil. TNI disahkan 20 Maret 2025 Polri dan Kejaksaan masih https://t.co/DQXZmxo7Me

4.2. Data Preprocessing

Data yang telah terkumpul akan melalui tahap *preprocessing* yang bertujuan membersihkan, mengatur, dan menyiapkan data agar siap diproses secara tepat. Proses ini dilakukan menggunakan Google Colab dengan bahasa pemrograman Python.

1) *Cleansing*

Salah satu tahap penting adalah *cleansing*, di mana data yang awalnya mengandung banyak gangguan seperti karakter tidak relevan, duplikasi, dan noise, dibersihkan sehingga menjadi lebih rapi dan terstruktur. Tahap ini memudahkan pengolahan data pada langkah berikutnya dan meningkatkan kualitas analisis sentimen.

Tabel 2. *Cleansing*

Sebelum <i>Cleansing</i>	Setelah <i>Cleansing</i>
pemerintah perlu lebih tegas ya makanya tegas dong tolak RUU TNI & POLRI terus urus UU perampasaan aset koruptor ikutin suara rakyat kita semua juga ga bakal tuh gaduhin istana kalo kerjanya emang bener mah tolol	pemerintah perlu lebih tegas ya makanya tegas dong tolak RUU TNI & POLRI terus urus UU perampasaan aset koruptor ikutin suara rakyat kita semua juga ga bakal tuh gaduhin istana kalo kerjanya emang bener mah tolol

2) *Case Folding*

Pada tahap *case folding*, seluruh huruf dalam setiap kata pada dataset diubah menjadi huruf kecil untuk menyamakan format teks dan menghindari perbedaan akibat kapitalisasi.

Tabel 3. Case Folding

Sebelum Case Folding	Setelah Case Folding
pemerintah perlu lebih tegas ya makanya tegas dong tolak RUU TNI & POLRI terus urus UU perampasaan aset koruptor ikutin suara rakyat kita semua juga ga bakal tuh gaduhin istana kalo kerjanya emang bener mah tolol	pemerintah perlu lebih tegas ya makanya tegas dong tolak ruu tni amp polri terus urus uu perampasaan aset koruptor ikutin suara rakyat kita semua juga ga bakal tuh gaduhin istana kalo kerjanya emang bener mah tolol

3) Tokenization

Tahap *tokenization*, teks dipisahkan menjadi kata-kata tunggal dengan menggunakan spasi sebagai pemisah. Tahap ini memudahkan analisis dengan mengubah teks menjadi unit-unit yang lebih kecil.

Tabel 4. Tokenization

Sebelum Tokenization	Setelah Tokenization
pemerintah perlu lebih tegas ya makanya tegas dong tolak ruu tni amp polri terus urus uu perampasaan aset koruptor ikutin suara rakyat kita semua juga ga bakal tuh gaduhin istana kalo kerjanya emang bener mah tolol	['pemerintah', 'perlu', 'lebih', 'tegas', 'ya', 'makanya', 'tegas', 'dong', 'tolak', 'ruu', 'tni', 'amp', 'polri', 'terus', 'urus', 'uu', 'perampasaan', 'aset', 'koruptor', 'ikutin', 'suara', 'rakyat', 'kita', 'semua', 'juga', 'ga', 'bakal', 'tuh', 'gaduhin', 'istana', 'kalo', 'kerjanya', 'emang', 'bener', 'mah', 'tolol']

4) Stopword Removal

pada tahap *stopword removal*, kata-kata yang sering muncul namun kurang memiliki makna signifikan dalam analisis, seperti kata penghubung dan kata depan, dihapus untuk meningkatkan kualitas data dan fokus pada kata-kata yang lebih informatif.

Tabel 5. Stopword Removal

Sebelum Stopword Removal	Setelah Stopword Removal
['pemerintah', 'perlu', 'lebih', 'tegas', 'ya', 'makanya', 'tegas', 'dong', 'tolak', 'ruu', 'tni', 'amp', 'polri', 'terus', 'urus', 'uu', 'perampasaan', 'aset', 'koruptor', 'ikutin', 'suara', 'rakyat', 'kita', 'semua', 'juga', 'ga', 'bakal', 'tuh', 'gaduhin', 'istana', 'kalo', 'kerjanya', 'emang', 'bener', 'mah', 'tolol']	['pemerintah', 'ya', 'tolak', 'ruu', 'tni', 'polri', 'urus', 'uu', 'perampasaan', 'aset', 'koruptor', 'ikutin', 'suara', 'rakyat', 'gaduhin', 'istana', 'kerjanya', 'tolol']

5) Normalization

Pada tahap normalisasi, kata-kata yang tidak sesuai dengan kaidah bahasa diubah menjadi bentuk yang baku untuk memastikan konsistensi data. Selanjutnya, pada tahap stemming, kata-kata yang mengandung imbuhan diproses untuk dikembalikan ke bentuk dasarnya.

Tabel 6. Normalization

Sebelum Normalization	Setelah Normalization
['pemerintah', 'ya', 'tolak', 'ruu', 'tni', 'polri', 'urus', 'uu', 'perampasaan', 'aset', 'koruptor', 'ikutin', 'suara', 'rakyat', 'gaduhin', 'istana', 'kerjanya', 'tolol']	['pemerintah', 'iya', 'tolak', 'ruu', 'tni', 'amp', 'polri', 'mengurus', 'uu', 'perampasan', 'aset', 'koruptor', 'ikuti', 'suara', 'rakyat', 'tidak', 'itu', 'mengganggu', 'istana', 'kalau', 'pekerjaannya', 'memang', 'benar', 'mah', 'tolol']

6) Stemming

Apabila Proses ini penting untuk menyederhanakan variasi kata sehingga model *Support Vector Machine* (SVM) dapat mengenali pola teks dengan lebih efektif dan meningkatkan akurasi klasifikasi sentimen.

Tabel 7. Stemming

Sebelum Stemming	Sesudah Stemming
['pemerintah', 'iya', 'tolak', 'ruu', 'tni', 'amp', 'polri', 'mengurus', 'uu', 'perampasan', 'aset', 'koruptor', 'ikuti', 'suara', 'rakyat', 'tidak', 'itu', 'mengganggu', 'istana', 'kalau', 'pekerjaannya', 'memang', 'benar', 'mah', 'tolol']	['perintah', 'iya', 'tolak', 'ruu', 'tni', 'amp', 'polri', 'urus', 'uu', 'rampas', 'aset', 'koruptor', 'ikuti', 'suara', 'rakyat', 'tidak', 'itu', 'ganggu', 'istana', 'kalau', 'kerja', 'memang', 'benar', 'mah', 'tolol']

4.3. Data Transformation

Data yang telah melewati tahap *preprocessing* selanjutnya akan melalui proses transformasi. Transformasi data bertujuan untuk meningkatkan kualitas data, menyelaraskan skala, serta memastikan kesesuaian dengan metode atau model yang diterapkan, seperti *Support Vector Machine* (SVM). Proses ini penting untuk mengubah format, struktur, atau nilai data agar lebih optimal untuk analisis atau pengolahan selanjutnya, sehingga mendukung akurasi klasifikasi sentimen.

1) Labelling

Pada tahap pelabelan, peneliti memberikan label pada seluruh data hasil *preprocessing* untuk mengklasifikasikan ulasan ke dalam kategori sentimen positif, negatif, atau netral. Tabel yang disajikan akan menampilkan daftar kata-kata yang termasuk dalam kategori positif atau negatif. Kata-kata netral tidak dimasukkan secara eksplisit dalam daftar karena akan secara otomatis dikategorikan netral jika tidak termasuk dalam kelompok positif maupun negatif. Proses pelabelan ini fundamental untuk melatih model *Support Vector Machine* (SVM) agar mampu mengidentifikasi dan mengklasifikasikan sentimen secara akurat.

Tabel 8. Labelling

Positive word	Negative Word
['bagus', 'baik', 'puas', 'senang', 'mantap', 'suka', 'hebat', 'bijak', 'setuju', 'sah', 'dukung', 'sudah']	['buruk', 'tidak', 'tolak', 'demo', 'benci', 'rusak', 'kecewa', 'kurang', 'salah', 'cabutuutni', 'aksi', 'indonesiagelap', 'rakyat', 'polri']

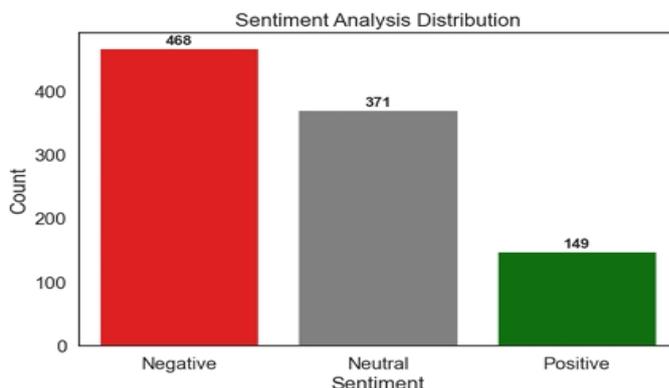
2) Label Encoding

Setelah proses pelabelan selesai, setiap kelas sentimen yang telah diberi label (misalnya positif, netral, negatif) akan dikonversi menjadi representasi numerik melalui *label encoding*. Tahap ini penting agar data dapat diproses secara efektif oleh model *machine learning*, khususnya *Support Vector Machine* (SVM), karena sebagian besar algoritma *machine learning* bekerja optimal dengan data dalam format numerik. Tabel berikut memperlihatkan hasil encoding label dari kelas-kelas yang ada saat ini.

Tabel 9. Label Encoding

Label	Label Encoding
Positive	2
Netral	1
Negatif	0

Hasil proses *label encoding* menunjukkan jumlah data dengan sentimen negatif sebanyak 468, sentimen netral 371, dan sentimen positif 149. Visualisasi distribusi sentimen berdasarkan hasil tersebut disajikan pada Gambar 3, yang membantu memudahkan pemahaman terhadap proporsi masing-masing kategori sentimen dalam dataset.



Gambar 3. Grafik distribusi sentimen

4.4. Text Mining

Pada tahap *text mining*, klasifikasi dilakukan dengan menerapkan algoritma *Support Vector Machine* (SVM) pada data teks yang telah melalui proses *preprocessing*. Fitur yang digunakan terdiri dari hasil ekstraksi TF-IDF serta fitur tambahan berupa jumlah kata positif dan negatif dalam setiap teks. Label sentimen yang awalnya berbentuk kategori (positif, negatif, netral) telah dikonversi ke format numerik agar dapat diproses oleh model SVM. Selanjutnya, dilakukan optimasi *hyperparameter* menggunakan GridSearchCV untuk menemukan kombinasi parameter terbaik, seperti kernel, nilai C, dan gamma. Model yang telah dilatih kemudian dievaluasi menggunakan metrik akurasi, presisi, *recall*, F1-score, serta *confusion matrix* untuk mengukur performa klasifikasi secara menyeluruh.

	precision	recall	f1-score	Support
0	1.00	0.88	0.93	104
1	0.85	1.00	0.92	83
2	1.00	0.98	0.99	94
Accuracy			0.95	281
Macro avg	0.95	0.95	0.95	281
Weighted avg	0.93	0.95	0.95	281
Akurasi model SVM: 0.9466192170818505				

Gambar 4. Hasil program klasifikasi SVM

Gambar di atas memperlihatkan hasil laporan klasifikasi, nilai akurasi, serta tabel *confusion matrix*. Model SVM yang digunakan mencapai tingkat akurasi sebesar 94,66%

4.5. Evaluation

Evaluasi dilakukan untuk menilai kinerja model *Support Vector Machine* (SVM) dalam mengklasifikasikan sentimen publik terhadap kebijakan Revisi Undang-Undang TNI. Penilaian model menggunakan metrik akurasi, precision, recall, F1-score, serta analisis distribusi prediksi melalui *confusion matrix*.

Hasil evaluasi menunjukkan bahwa model SVM mencapai akurasi sebesar 94,66%. Nilai recall tertinggi terdapat pada kelas netral, yaitu 1,00, yang berarti seluruh tweet dengan sentimen netral berhasil diklasifikasikan dengan benar. Recall untuk kelas negatif mencapai 0,98, sedangkan untuk kelas positif sebesar 0,88. Hal ini menunjukkan bahwa model sangat baik dalam mengenali sentimen negatif, namun masih kurang optimal dalam mendeteksi sentimen positif.

Penggunaan precision, recall, dan F1-score penting untuk mengevaluasi keseimbangan antara prediksi yang benar pada masing-masing kategori sentimen. Precision mengukur proporsi prediksi positif yang benar dibandingkan dengan seluruh prediksi positif yang dihasilkan oleh model, sehingga dapat memastikan ketepatan klasifikasi sentimen dalam konteks kebijakan publik.

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (1)$$

Sementara itu, recall mengindikasikan seberapa baik model dalam menemukan semua data positif yang sebenarnya ada.

$$Recal = \frac{True\ Positif}{True\ Positif + False\ Negative} \quad (2)$$

F1-score digunakan sebagai metrik keseluruhan yang menggabungkan precision dan recall untuk mencapai keseimbangan antara keduanya, dengan rumus sebagai berikut:

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

Meskipun demikian, ketidakseimbangan distribusi data—dengan dominasi kelas negatif dan netral dibandingkan kelas positif—berpengaruh pada kinerja klasifikasi di kelas minoritas. Nilai rata-rata F1-score sebesar 0,95 menunjukkan bahwa model memiliki performa yang stabil dan baik secara keseluruhan. Namun, terdapat indikasi *overfitting* pada kelas netral, yang terlihat dari nilai recall sempurna tetapi variasi prediksi yang terbatas pada kelas tersebut.

4.6 Pembahasan

Hasil temuan jurnal ini menunjukkan bahwa algoritma *Support Vector Machine* (SVM) efektif mengklasifikasikan sentimen publik dengan akurasi hampir 79% dan F1-score 0,83 untuk sentimen negatif, mencerminkan dominasi sikap skeptis terhadap revisi UU TNI. Penggunaan preprocessing intensif dan fitur TF-IDF membantu menangani kompleksitas teks pendek di Twitter, memperkuat validitas SVM dalam konteks kebijakan pemerintah.

Secara umum Jurnal ini memperkuat temuan sebelumnya, temuan tentang kehandalan metode *Support Vector Machine* (SVM) sebagai algoritma yang efektif untuk klasifikasi sentimen pada data Twitter, khususnya dalam konteks kebijakan publik yang kompleks dan memicu kontroversi. Hal ini sejalan dengan banyak studi lain yang menyoroti efektivitas SVM dalam analisis sentimen dengan hasil akurasi tinggi, terutama ketika didukung oleh optimasi parameter, pra-pemrosesan data yang teliti, dan pemilihan teknik representasi fitur yang sesuai (seperti TF-IDF dan word embeddings) [8][10][20]. Selain itu, jurnal ini mendukung temuan yang menekankan pentingnya evaluasi model yang komprehensif dengan metrik-metrik yang tepat (akurasi, presisi, recall, F1-score) dan strategi pelatihan-pengujian yang seimbang untuk mengatasi tantangan data tidak seimbang [20][21][22][23]. Pendekatan ini juga memperkuat praktik terbaik dalam riset analisis sentimen modern.

Di sisi lain, jurnal ini juga selaras dengan kajian yang menyoroti peran analisis sentimen sebagai alat strategis dalam mengambil keputusan kebijakan publik yang responsif terhadap suara masyarakat di media sosial, menghubungkan data digital dengan konteks hukum dan sosial-politik secara mendalam.

5. Simpulan

Penelitian ini membuktikan bahwa metode *Support Vector Machine* (SVM) efektif dalam mengklasifikasikan sentimen publik terhadap RUU TNI berdasarkan data Twitter. Model mencapai akurasi sebesar 94,66%, dengan recall sempurna pada sentimen netral (1,00), serta recall 0,98 dan 0,88 untuk sentimen negatif dan positif. Hasil klasifikasi menunjukkan dominasi sentimen netral dan negatif, yang mencerminkan kekhawatiran masyarakat terhadap isi RUU tersebut.

Meskipun hasilnya memuaskan, ketidak seimbangan distribusi data menyebabkan model lebih akurat dalam mengidentifikasi sentimen netral. Oleh karena itu, disarankan penelitian lanjutan dilakukan dengan menyeimbangkan data pelatihan, mengoptimalkan parameter model, serta mempertimbangkan penggunaan fitur berbasis konteks seperti *word embeddings*. Temuan ini dapat menjadi bahan pertimbangan bagi pemerintah dalam merumuskan kebijakan yang lebih responsif dan sesuai dengan aspirasi publik.

Daftar Referensi

- [1] M. Z. Habibie, Y. S. P. Sihaloho, R. M. Andeka, M. A. Kiansantang, C. Irawan, dan K. Amaliah, "Yayasan Lembaga Bantuan Hukum Indonesia (YLBHI) Menolak Upaya Menghidupkan Kembali Dwi Fungsi Melalui Revisi UU TNI (Tentara Negara Indonesia)," *Quantum Juris: Jurnal Hukum Modern*, vol. 7, no. 2, pp. 157-168, 2025.
- [2] U. Hamid, "Menimbang Kadar Dwifungsi (UU) TNI," *Kompas.id*, 24 Maret 2025. [Online]. Tersedia: <https://www.kompas.id/artikel/menimbang-kadar-dwifungsi-uu-tni>
- [3] H. K. Hoetomo and W. Thukul, "Upaya keluar kandang (barak) oleh TNI: Reformasi yang berputar di tempat?," unpublished, Mar. 2025. [Online],doi: <https://doi.org/10.13140/RG.2.2.34172.65927>.
- [4] M. Kumar, L. Khan, and H.-T. Chang, "Evolving techniques in sentiment analysis: a comprehensive review," *PeerJ Computer Science*, vol. 11, p. e2592, Jan. 2025.
- [5] M. S. Hasibuan dan A. Serdano, "Analisis Sentimen Kebijakan Pembelajaran Tatap Muka Menggunakan Support Vector Machine dan Naïve Bayes," *Jurnal Riset Sains dan Teknologi*, vol. 6, no. 2, pp. 199–204, 2022, doi: <https://doi.org/10.30595/jrst.v6i2.15145>.
- [6] T. Pratama, R. Nugroho, dan M. Aditya, "Comparison of SVM, Random Forest, and KNN in Sentiment Analysis of Online Learning Policy," *International Journal of Educational Data Science*, vol. 19, no. 2, pp. 120–135, 2021.
- [7] M. Yasir, M. G. Haque, R. Suraji, dan I. Sastrodiharjo, "Analisis Sentimen Terhadap Kontroversi Fatwa MUI Nomor 83 Tahun 2023 Tentang Pemboikotan Produk yang Terafiliasi Israel," *Jurnal Ekonomi Manajemen Sistem Informasi*, vol. 5, no. 2, pp. 409–422, 2024.
- [8] Q. A. Chairunnisa, Y. Herdiyeni, M. K. D. Hardhienata, and J. Adisantoso, "Analisis sentimen pengguna Twitter terhadap program vaksinasi COVID-19 di Indonesia menggunakan algoritme Support Vector Machine," *Jurnal Ilmu Komputer dan Agri-Informatika*, vol. 9, no. 1, pp. 79–89, 2022.
- [9] A. Dendy and T. Sugihartono, "Perbandingan Teknik Optimasi Grid Search dan Randomized Search dalam Meningkatkan Akurasi Metode Klasifikasi SVM," *SKANIKA*, vol. 8, no. 1, pp. 13–22, 2025
- [10] B. Ermawan and N. Cahyono, "Optimasi Metode Klasifikasi Menggunakan FastText dan Grid Search," *JIKO*, vol. 9, No. 1, pp. 226-238, 2025.
- [11] R. M. Pradhana, "Analisis Sentimen Publik terhadap Kebijakan Pemberlakuan Pembatasan Kegiatan Masyarakat Skala Mikro Menggunakan Algoritma Support Vector Machine Studi Kasus Twitter," *Doctoral dissertation, Universitas Dinamika*, 2021.
- [12] M. S. Hasibuan and T. Suhardi, "Analysis of Covid-19 Vaccine Policy Sentiment Using SVM and C4.5," *Jurnal Teknik Elektro dan Komputer TRIAC*, vol. 9, no. 2, pp. 67–69, 2022.
- [13] L. N. Pradany and C. Fatichah, "Analisa Sentimen Kebijakan Pemerintah pada Konten Twitter Berbahasa Indonesia Menggunakan SVM dan K-Medoid Clustering," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK)*, Universitas Brawijaya, vol. 5, no. 10, pp. 3894–3901, 2021.
- [14] D. W. Syahputra, B. Rahayudi, and L. Muflikhah, "Analisis Sentimen Twitter terhadap Kebijakan Pemberlakuan Pembatasan Kegiatan Masyarakat menggunakan Metode Support Vector Machine," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (JPTIIK)*, vol. 6, no. 4, pp. 1760–1767, 2022. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [15] R. Pebrianto, S. N. Nugraha, A. Latif, and M. R. Firdaus, "Analisis Sentimen Twitter terhadap Menteri Indonesia dengan Algoritma Support Vector Machine dan Naive Bayes," *Jurnal Informatika Universitas Pamulang*, vol. 17, no. 1, pp. 1–12, 2022.
- [16] H. Yaputra and M. R. Muzzaki, "Tagar 'Indonesia Gelap' mendapatkan sentimen negatif," *Tempo.co*, 2023. [Online]. Available: <https://www.tempo.co/politik/tagar-indonesia-gelap-dapat-81-persen-sentimen-negatif-1221552> [Accessed: Apr. 1, 2025].
- [17] Kompas TV, "Syamsu Rizal: Proses Pembahasan RUU TNI Harus Lebih Transparan," *Kompas TV*, 2023. [Online]. Available:<https://www.kompas.tv/nasional/581077/anggota-komisi-i-dpr-fraksi-pkb-ini-akui-pembahasan-revisi-uu-tni-kurang-transparan>. [Accessed: Apr. 1, 2025].
- [18] M. Rahman and R. Fadhil, "Support Vector Machine for Text Classification: A Comprehensive Review," *Journal of Artificial Intelligence Research*, vol. 45, pp. 112–130, 2021.

- [19] D. Suryana and N. Lestari, "Text Preprocessing Techniques for Sentiment Analysis in Social Media Data," *Journal of Computer Science and Information Systems*, vol. 12, no. 4, pp. 221–238, 2023.
- [20] P. Wijaya and T. Prasetyo, "TF-IDF vs. Word Embeddings: Which One is Better for Sentiment Analysis?," in *Proc. Int. Conf. Data Science*, pp. 33–45, 2022.
- [21] R. Hakim and S. Rahman, "Training and Testing Strategies in Machine Learning-Based Sentiment Analysis," *International Journal of Artificial Intelligence and Data Mining*, vol. 11, no. 2, pp. 87–102, 2024.
- [22] B. Santoso, A. Nugraha, and M. Setyawan, "Comparison of Kernel Types in SVM for Sentiment Analysis," *Journal of Intelligent Systems and Applications*, vol. 9, no. 4, pp. 211–226, 2025.
- [23] M. Firdaus and A. Ramadhan, "Evaluating Sentiment Classification Models: Metrics and Best Practices," *Journal of Data Science and Machine Learning*, vol. 13, no. 1, pp. 45–61, 2023.
- [24] T. Nugroho, F. Mahendra, and D. Satria, "Application of Sentiment Analysis for Public Policy Decision Making," *International Journal of Government and Technology Studies*, vol. 8, no. 3, pp. 190–204, 2025.