

Analisis Sentimen Pada Tweet Buzzer Politik Indonesia Menggunakan Metode SVM

Umar Farauk Eka Putra^{1,*}, Dyah Ayu Nursheila Ramhan², Luthfiah Nur Alifah³, Novita Ayu⁴, Junesty Todingbua⁵, Anindita Septiarini⁶, Novianti Puspitasari⁷
^{1,2,3,4,5,6,7} Teknik Informatika, Universitas Mulawarman

*Corresponding Author e-mail: alexsey142@gmail.com

Received: May 2025; Revised: June 2025; Published: June 2025

Abstrak

Menjelang periode pemilihan umum di Indonesia, aktivitas *buzzer* politik di media sosial, khususnya Twitter, menunjukkan peningkatan signifikan. Keberadaan mereka memiliki potensi besar dalam memengaruhi opini publik dan memperkuat polarisasi politik di ruang digital. Penelitian ini bertujuan untuk melakukan analisis sentimen dan identifikasi topik terhadap *tweet* yang dipublikasikan oleh akun-akun yang terindikasi sebagai *buzzer* politik di Indonesia. Data dikumpulkan dari *tweet* akun-akun yang telah terverifikasi sebagai *buzzer*, kemudian melalui tahapan *preprocessing*, ekstraksi fitur menggunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF), klasifikasi sentimen dengan algoritma *Support Vector Machine* (SVM), serta pemodelan topik. Hasil menunjukkan bahwa model SVM mencapai akurasi sebesar 0,66, dengan precision 0,64, recall 0,66, dan F1-score 0,63. Capaian ini mengindikasikan bahwa metode SVM cukup efektif dalam mengklasifikasikan sentimen dalam konteks opini politik digital. Temuan ini memberikan kontribusi terhadap pemahaman dinamika komunikasi politik di media sosial serta peran *buzzer* dalam membentuk opini publik secara daring.

Kata kunci: Analisis Sentimen, Pemodelan Topik, *Buzzer Politik*, *Support Vector Machine*, Twitter.

Sentiment Analysis On Indonesian Political Buzzer Tweets Using Svm Method

Abstract

Ahead of Indonesia's general election period, the activities of political buzzers on social media – particularly Twitter – have intensified significantly. Their presence holds substantial potential to influence public opinion and reinforce political polarization within digital spaces. This study aims to perform sentiment analysis and topic identification on tweets published by accounts identified as political buzzers in Indonesia. Data were collected from verified buzzer accounts and processed through several stages, including preprocessing, feature extraction using Term Frequency-Inverse Document Frequency (TF-IDF), sentiment classification using the Support Vector Machine (SVM) algorithm, and topic modeling. The results indicate that the SVM model achieved an accuracy of 0.66, with a precision of 0.64, recall of 0.66, and an F1-score of 0.63. These findings suggest that the SVM method is moderately effective in classifying sentiments within the context of digital political opinion. The study contributes to a deeper understanding of political communication dynamics on social media and the role of buzzers in shaping online public opinion.

Keywords: Sentiment analysis, Topic modeling, Political buzzers, Support Vector Machine, Twitter.

How to Cite: Putra, U. F. E., Rahman, D. A. N., Alifah, L. N., Ayu, N., Todingbua, J., Septiarini, A., & Puspitasari, N. (2025). Analisis Sentimen Pada Tweet Buzzer Politik Indonesia Menggunakan Metode SVM. *Journal of Authentic Research*, 4(1), 311–326. <https://doi.org/10.36312/jar.v4i1.3046>



<https://doi.org/10.36312/jar.v4i1.3046>

Copyright© 2025, Putra et al.
This is an open-access article under the CC-BY-SA License.



PENDAHULUAN

Media sosial telah menjadi salah satu sarana utama dalam penyebaran informasi, pembentukan opini publik, dan pengaruh terhadap perilaku masyarakat, khususnya dalam konteks politik. Di Indonesia, Twitter menjadi platform yang sangat populer untuk perbincangan politik karena sifatnya yang terbuka dan real-time (Kusuma & Prasetyo, 2020). Namun, fenomena ini juga melahirkan aktor-aktor digital seperti *buzzer* politik, yaitu akun yang secara sistematis menyebarkan pesan tertentu untuk mempengaruhi opini publik (Nugroho et al., 2022). Aktivitas *buzzer* politik tidak hanya terbatas pada penyampaian informasi, tetapi sering kali bertujuan untuk membentuk persepsi publik guna memperkuat citra tokoh atau partai tertentu, bahkan menyebarkan disinformasi (Maulidiyah & Putra, 2021). Oleh karena itu, analisis sentimen dan topik menjadi penting untuk memahami kecenderungan emosi serta isu-isu dominan dalam narasi politik yang dibangun oleh *buzzer*.

Sejumlah penelitian terdahulu telah mengkaji fenomena *buzzer* politik di Indonesia. Sastramidjaja dan Wijayanto (2021) menunjukkan bahwa *buzzer* memainkan peran strategis dalam kampanye politik digital dengan memanfaatkan jaringan akun otomatis (*bot*) dan manusia untuk menciptakan *trending topic* yang menguntungkan pihak tertentu. Temuan serupa diungkapkan oleh Lim (2020), yang menyoroti penggunaan *buzzer* secara terorganisir untuk menyerang lawan politik, memicu polarisasi, dan menyebarkan disinformasi melalui narasi yang tampak organik namun sebenarnya terstruktur. Namun, penelitian-penelitian tersebut masih bersifat kualitatif atau mengandalkan analisis manual, sehingga kurang mampu menangani volume dan kompleksitas data media sosial secara efisien.

Selain itu, berbagai penelitian terbaru telah mengkaji peran dan dampak *buzzer* politik dalam lanskap komunikasi politik Indonesia. (Nurhasanah dan Naufal, 2024) melakukan klasifikasi *sentimen* terhadap aktivitas *buzzer* politik menjelang Pemilu 2024 menggunakan metode lexicon-based, menemukan bahwa 31,94% dari 1.031 tweet yang dianalisis mengandung *sentimen* negatif yang diasosiasikan dengan *buzzer* politik. Penelitian ini memberikan gambaran awal mengenai kecenderungan emosi dalam tweet yang diposting oleh *buzzer* politik, namun terbatas pada metode lexicon-based yang cenderung kurang fleksibel dalam menangani nuansa sentimen yang lebih kompleks.

Melengkapi temuan tersebut, (Mola et al., 2024) membandingkan kinerja algoritma Naïve Bayes dan SVM dalam menganalisis *sentimen* publik terhadap isu pelantikan artis sebagai anggota DPR tahun 2024. Dengan menggunakan data komentar dari berbagai video YouTube, penelitian ini menunjukkan bahwa SVM menghasilkan akurasi *klasifikasi* sebesar 91%, lebih tinggi dibandingkan Naïve Bayes yang hanya mencapai 80%. Selain itu, SVM juga terbukti lebih andal dalam mendeteksi *sentimen* negatif dan netral, menegaskan potensinya untuk data opini publik yang kompleks.

Celah metodologis dalam menangani nuansa sentimen politik yang kompleks pada data skala besar, khususnya dari *buzzer*, inilah yang menjadi fokus penelitian kami. Penelitian-penelitian sebelumnya, baik yang kualitatif maupun yang berbasis lexicon-based belum sepenuhnya mampu mengatasi tantangan ini secara efisien dan akurat karena masih menyisakan beberapa keterbatasan

metodologis yang signifikan. Studi-studi kualitatif seperti yang dilakukan oleh Sastramidjaja dan Wijayanto (2021) serta Lim (2020) berhasil mengungkap peran strategis *buzzer* dalam membentuk wacana politik digital. Namun, pendekatan kualitatif ini menghadapi kendala dalam mengolah volume data media sosial yang masif dan terus bertumbuh secara real-time.

Di sisi lain, penelitian berbasis leksikon seperti yang dilaksanakan Nurhasanah dan Naufal (2024) memang menawarkan solusi komputasional awal dengan mengklasifikasikan sentimen berdasarkan kamus kata. Sayangnya, metode ini menunjukkan keterbatasan dalam menangkap nuansa bahasa yang lebih kompleks seperti sarkasme, ironi, atau konteks politik spesifik yang khas dalam percakapan *buzzer* Indonesia.

Beberapa peneliti telah mulai beralih ke pendekatan machine learning, sebagaimana ditunjukkan Mola dan tim (2024) yang berhasil menerapkan SVM untuk analisis sentimen komentar YouTube dengan akurasi mencapai 91%. Namun demikian, penelitian ini belum menguji efektivitas metode tersebut pada data tweet *buzzer* politik yang memiliki karakteristik berbeda - lebih dinamis, sarat dengan istilah-istilah politik khusus, dan mengandung noise yang lebih tinggi akibat penggunaan bahasa informal dan singkatan khas media sosial.. Untuk mengisi celah ini, studi ini menerapkan pendekatan komputasional berbasis *Support Vector Machine (SVM)*. Pilihan pada *SVM* didasarkan pada kemampuan yang telah terbukti dalam menangani data teks berdimensi tinggi dan ketangguhannya terhadap noise yang kerap muncul dalam percakapan media sosial. Lebih dari sekedar efisiensi pengolahan data besar, pendekatan berbasis *SVM* ini di harapkan lebih sensitif dalam menangkap berbagai bentuk ekspresi sentimen yang khas dan bernuansa dalam wacana politik Indonesia.

Urgensi penelitian ini terletak pada kebutuhan mendesak akan alat analisis yang lebih canggih untuk memahami dinamika *buzzer* politik di Indonesia, terutama dalam menghadapi siklus pemilu yang semakin dipengaruhi oleh pertarungan wacana digital. Dengan demikian, penelitian ini bertujuan untuk mengisi celah metodologis pada studi-studi sebelumnya dengan menguji efektivitas metode *SVM* dalam menangani nuansa sentimen politik yang kompleks pada *tweet buzzer* yang tidak tercover oleh pendekatan kualitatif dan *lexicon-based*, mengidentifikasi pola komunikasi terstruktur *buzzer* sebagai dasar deteksi dini disinformasi dan mengidentifikasi pola komunikasi terstruktur *buzzer* sebagai indikator disinformasi. Penelitian ini diharapkan memberikan kontribusi ganda sebagai pengembangan metodologis analisis sentimen yang lebih adaptif dengan akurasi dan fleksibilitas lebih tinggi dibanding metode *lexicon-based* atau kualitatif, sekaligus sebagai dasar empiris bagi perumusan kebijakan pengelolaan ruang digital dan literasi digital yang lebih responsif.

METODE

Penelitian ini menggunakan data yang bersumber dari media sosial Twitter, berupa kumpulan tweet yang berasal dari akun-akun yang teridentifikasi sebagai *buzzer* politik di Indonesia. Dataset diperoleh melalui platform Kaggle, dan mencakup tweet-tweet yang menyinggung tokoh-tokoh politik seperti Ganjar Pranowo, Anies Baswedan, dan Prabowo Subianto, yang kerap menjadi bahan diskusi di ruang publik digital. Berdasarkan informasi yang tercantum pada halaman sumbernya, data terakhir

diperbarui pada tanggal 19 Juni 2023. Dataset terdiri dari 500 baris tweet yang telah melalui proses pelabelan manual berdasarkan sentimen, yaitu positif, negatif, dan netral. Data ini dipilih sebagai sampel representatif dari kumpulan tweet yang lebih besar dan dianggap mencerminkan opini publik terkait isu politik tertentu. Pengambilan sampel dilakukan secara acak sederhana agar setiap tweet memiliki kemungkinan yang sama untuk dipilih, sesuai dengan pendekatan sampling dari Schaeffer et al. (2012). Dataset kemudian diproses menggunakan teknik data mining untuk keperluan analisis sentimen.

Dalam kajian ini, analisis sentimen digunakan sebagai pendekatan untuk memahami opini publik yang terekspresi dalam tweet. Analisis sentimen atau opinion mining merupakan proses komputasional yang bertujuan untuk mengidentifikasi dan mengkategorikan sikap penulis terhadap suatu topik sebagai positif, negatif, atau netral (Liu, 2020). Penelitian ini didasarkan pada pendekatan data mining yang melibatkan beberapa tahap penting, dimulai dari preprocessing data, yaitu proses pembersihan dan persiapan data mentah agar dapat digunakan untuk analisis lebih lanjut. Proses ini mencakup cleansing (menghapus URL, emoji, mention, hashtag, simbol non-alfanumerik), case folding (mengubah huruf menjadi huruf kecil semua), tokenizing (memecah teks menjadi satuan kata), stopword removal (menghapus kata-kata umum tak bermakna), stemming (mengembalikan kata ke bentuk dasarnya dengan algoritma Nazief-Adriani melalui library Sastrawi), dan normalisasi (mengoreksi kata tidak baku atau singkatan informal khas media sosial Indonesia).

Setelah preprocessing, tahap berikutnya adalah pelabelan data berdasarkan kategori sentimen. Pelabelan dilakukan secara manual dengan melibatkan dua orang annotator, terdiri atas annotator utama dan sekunder, yang mengklasifikasikan tweet ke dalam tiga kategori, yaitu positif, netral, dan negatif. Untuk mengubah tweet ke dalam bentuk representasi numerik, digunakan beberapa metode ekstraksi fitur, yakni TF-IDF (Term Frequency-Inverse Document Frequency) untuk mengukur pentingnya kata dalam suatu dokumen terhadap seluruh korpus, word embeddings dari FastText yang telah dilatih untuk bahasa Indonesia (Bojanowski et al., 2017), serta fitur linguistik seperti jumlah kata, rasio kata positif/negatif, dan kehadiran kata penguat sentimen berdasarkan leksikon sentimen lokal.

Model klasifikasi yang digunakan dalam penelitian ini adalah Support Vector Machine (SVM) dengan kernel linear, yang diimplementasikan menggunakan library scikit-learn pada bahasa pemrograman Python. Model ini dipilih karena kemampuannya yang andal dalam menangani data teks berdimensi tinggi, seperti representasi dari TF-IDF. Setelah data dibagi menjadi data latih dan data uji dengan perbandingan 80:20, model dilatih pada data latih dan dievaluasi terhadap data uji. Proses pelatihan dilakukan tanpa pencarian parameter (grid search) dan belum menerapkan metode penanganan ketidakseimbangan kelas seperti SMOTE. Evaluasi performa model dilakukan menggunakan metrik-metrik standar seperti akurasi, precision, recall, f1-score (baik dalam rata-rata makro maupun berbobot), serta confusion matrix, untuk mengukur sejauh mana model mampu mengklasifikasikan sentimen secara tepat.

HASIL DAN PEMBAHASAN

Data yang digunakan dalam penelitian ini merupakan kumpulan *tweet* dari akun yang terindikasi sebagai *buzzer* politik di Indonesia. *Dataset* ini diperoleh dari platform Kaggle dalam bentuk mentah, kemudian dilakukan proses kompilasi dan pembersihan secara manual oleh peneliti. Proses ini meliputi penghapusan URL, *mention*, emoji, angka, tanda baca, hingga kata-kata tidak penting (*stopwords*) serta melakukan *stemming* agar setiap kata direduksi ke bentuk dasarnya. Setelah melalui tahap *preprocessing*, diperoleh total 500 *tweet* yang telah dibersihkan dan diberi label secara manual ke dalam tiga kategori sentimen yakni, positif, negatif, dan netral. Data tersebut terdiri dari 286 *tweet* positif, 145 *tweet* negatif, dan 69 *tweet* netral. Distribusi label terdiri dari positif, negatif, dan netral. Selanjutnya, data berbentuk teks dikonversi menjadi matriks bobot kata menggunakan metode TF-IDF. TF-IDF merupakan salah satu teknik pembobotan kata yang umum digunakan, karena mengintegrasikan frekuensi kemunculan kata dalam suatu dokumen atau kalimat dengan frekuensi kata tersebut dalam keseluruhan koleksi kalimat atau dokumen. Data kemudian dibagi menjadi dua bagian untuk keperluan pelatihan dan pengujian model, yaitu 80% untuk data latih dan 20% untuk data uji. Model klasifikasi yang digunakan adalah SVM dengan kernel linear, karena telah terbukti efektif dalam mengolah data teks pendek seperti *tweet*. Berdasarkan hasil evaluasi, model menghasilkan akurasi sebesar 66%. Evaluasi lebih lanjut menggunakan *classification report* menunjukkan bahwa model mampu mengenali masing-masing label sentimen dengan cukup baik, yang tercermin dari nilai *precision*, *recall*, dan *f1-score* yang stabil pada ketiga kelas sentimen.

Tabel 1. *Tweet* yang telah di cleaning oleh *Preprocessing*

No	<i>Tweet</i>	<i>Clean Tweet</i>
0	bener nih kata Pak Jokowi kita butuh pemimpin ...	bener nih jokowi butuh pimpin sinergi tinggal ...
1	Alhamdulillah pak Ganjar sudah memahami jadi t...	alhamdulillah ganjar paham ganti lanjut jalan ...
2	Kalo udah ada yang baik ya dilanjutkan aja, ga...	kalo udah ya lanjut aja ga ganjar lanjut kerja...
3	Napa ya..... Gue kalau liat manusia ini kok ba...	napa ya gue liat manusia bawa nya muntah ya al...
4	Musyawarah Warga NU di belahan Jawa Timur yg m...	musyawarah warga nu bahan jawa timur yg mnduku...
...
495	Untuk membuktikan ga harus jadi presiden, sela...	bukti ga presiden ketua partai sdh kasih sempa...
496	SEORANG GANJAR PRANOWO SIKAPNYA : 1. MENGHARGA... Disemua Lembaga Survei nama Erick Thohir selal...	ganjar pranowo sikap harga pluralisme spt beda... semua lembaga survei nama erick thohir terataa...

498	Kalau seorang Erick Thohir sudah berkomitmen u...	erick thohir komitmen bangun sepak bola indone...
500	Pasangan yang cocok Pasangan yang mewarisi sem...	pasang cocok pasang waris semangat juang diri ..

Dari tabel 1 tersebut dapat diketahui bahwa terjadi tahapan *preprocessing*. Kolom awal Tweet di proses pembersihan data mentah yang menjadi bentuk yang siap dianalisis menjadi kolom *clean tweet*. Tahapan *preprocessing* merupakan langkah penting dalam analisis sentimen pada penelitian kami kali ini karena data mentah dari Twitter umumnya mengandung banyak *noise* seperti URL, tagar, mention, emoji, dan simbol khusus lainnya. Langkah awal dalam *preprocessing* adalah pembersihan teks, yaitu menghapus elemen-elemen yang tidak diperlukan seperti tautan URL, tanda baca, angka, mention pengguna (seperti @username), serta simbol-simbol khusus yang tidak memberikan informasi penting bagi analisis. Setelah itu, dilakukan proses *case folding*, yakni mengubah semua huruf dalam teks menjadi huruf kecil. Hal ini bertujuan untuk menyeragamkan kata-kata agar tidak terjadi perbedaan hanya karena penggunaan huruf kapital. Kemudian tahapan berikutnya adalah tokenisasi, yaitu proses memecah kalimat menjadi kata-kata terpisah atau token. Token-token ini kemudian disaring melalui proses *stopword removal*, yang bertujuan untuk menghapus kata-kata umum yang sering muncul tetapi tidak memiliki makna signifikan dalam konteks analisis, seperti "dan", "yang", "di", dan sebagainya. Terakhir, dilakukan proses *stemming*, yaitu mengubah kata-kata ke bentuk dasarnya menggunakan algoritma stemmer Bahasa Indonesia. Misalnya, kata "berlari" akan diubah menjadi bentuk dasarnya "lari". Seluruh tahapan *preprocessing* ini memiliki tujuan utama untuk mereduksi kompleksitas data dan memastikan bahwa hanya informasi yang relevan yang masuk ke dalam proses klasifikasi sentimen dan analisis topik pada tahap berikutnya.

Tabel 2. *Tweet* bersih yang telah diberi label sentimen

<i>Tweet</i>	Sentimen
nyata bener pilih jkw yg kagum pak prabowo kita emang pas tunjuk kerja bangsa sejahtera yesprabowokita okebanget	Positif
gus muhaimin pkb tunjuk kerja nyata warga dukung gus muhaimin capres	Positif
prabowo sosok pimpin satu dukung kalanganbukan pimpin dukung kepentingansaja prabowo menangindonesia menangrakyat senang	Positif
...	...
rekam jejak hub ganjar dgn jokowi prabowo dgn jokowi ganjar dukung setia tani dukung bela jokowi prabowo silah nilai aplg kader model fadli zon dukung dr kelompok radikal keri	Netral

luhut vs anies tenaga asing vs tenaga bangsa silah rakyat nilai	Netral
iye suara anies suara prabowo klo die gak maju tu suara tumpah nye prabowo klo suara ganjar ye suara jokowi aje kontestasi jokowi prabowo peran jokowi ganti	Netral
...	...
dpr mesti malu malu banget transparansi internasional indonesia dpr lembaga korup irma hutabarat	Negatif
anies bawa motor aja ngusruk kau suruh ambil alih kemudi mobil pimpin negara butuh orang alam ahli dar jago teori aja hasil ya ngusruk bahas utang mandalika lu lupa jis utang trilyun pusat	Negatif
opini survei bayar tutup takdir anies baswedan raja survey survey polling medkos	Negatif

Pada Tabel 2 contoh *tweet* yang telah melalui proses pembersihan data dan selanjutnya diberi label sentimen berdasarkan konteks isi *tweet* tersebut. Setiap *tweet* diklasifikasikan ke dalam salah satu dari tiga kategori sentimen yaitu positif, netral, dan negatif tergantung pada nada atau makna yang terkandung dalam teks. *Tweet* yang dikategorikan sebagai positif umumnya memuat dukungan atau pujiannya terhadap tokoh atau pasangan calon tertentu. Misalnya, *tweet* seperti “nyata bener pilih jkw ye kagum pak prabowo kita emang pas tunjuk kerja bangsa” menunjukkan ekspresi kekaguman dan dukungan terhadap dua tokoh politik, sehingga secara semantik merefleksikan sentimen positif. Sementara itu, *tweet* yang termasuk dalam kategori netral cenderung bersifat informatif atau deskriptif tanpa adanya ekspresi emosional yang kuat. Contohnya adalah *tweet* “rekam jejak hub ganjar dgn jokowi prabowo dgn jokowi ganjar dukung setia t...” yang tampak menyampaikan fakta atau hubungan antar tokoh tanpa menyertakan opini pribadi.

Kategori ini penting karena dalam banyak kasus, tidak semua teks mengandung opini atau emosi yang jelas. Di sisi lain, kategori negatif ditandai dengan adanya kritik, sindiran, atau kata-kata yang menyatakan ketidakpuasan terhadap tokoh atau lembaga tertentu. Sebagai contoh, tweet seperti “dpr mestii malu malu banget transparansi internasional indonesia dpr lembaga korup...” menggambarkan kritik tajam terhadap institusi DPR, sehingga tepat diberi label negatif. Pemberian label sentimen ini dilakukan secara manual dan kontekstual, memperhatikan tidak hanya kata-kata yang muncul tetapi juga maksud dari keseluruhan pernyataan. Proses ini sangat penting sebagai data pelatihan dalam model klasifikasi sentimen berbasis algoritma pembelajaran mesin, seperti SVM yang digunakan dalam penelitian ini. Label yang akurat akan berkontribusi langsung terhadap performa model dalam mengklasifikasikan sentimen pada data baru secara otomatis.

0	1
1	0
2	0
3	2
4	2
Name: label_encoded, dtype: int64	

Gambar 2. Proses *Label Encoding* merubah label Sentimen menjadi angka

Pada Gambar 2 menampilkan hasil proses *label encoding* yang dilakukan terhadap data sentimen. Pada tahap ini, label sentimen yang sebelumnya berbentuk teks positif, netral dan diubah menjadi representasi numerik agar dapat diproses oleh algoritma *machine learning*. Proses ini penting karena sebagian besar algoritma pembelajaran mesin, termasuk SVM, hanya dapat bekerja dengan data numerik. Dalam proses *encoding* ini, masing-masing kategori sentimen diberikan angka sebagai berikut:

Positif → 0

Netral → 1

Negatif → 2

Pada hasil *encoding* dapat dilihat pada Gambar 2, di mana nilai 1, 0, dan 2 mewakili kategori sentimen yang berbeda. Misalnya, indeks ke-0 bernilai 1 yang menunjukkan sentimen netral, sedangkan indeks ke-1 dan ke-2 masing-masing bernilai 0 yang berarti keduanya merupakan *tweet* dengan sentimen positif. Baris ke-3 dan ke-4 memiliki nilai 2 yang berarti keduanya termasuk dalam kategori sentimen negatif. Konversi label ini tidak hanya menyederhanakan data, tetapi juga memungkinkan proses klasifikasi dilakukan secara efisien dan sistematis. Dengan representasi numerik ini, model dapat dengan mudah menghitung jarak antar kelas dan menemukan batas optimal dalam proses klasifikasi menggunakan SVM. Setelah *data preparation* selesai *dataset* kemudian dibagi menjadi dua bagian, yaitu data pelatihan dan data pengujian. Pembagian ini bertujuan untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Dalam penelitian ini, data dibagi dengan rasio 80% untuk pelatihan dan 20% untuk pengujian. Sebelum dilakukan pelatihan, data teks diubah menjadi representasi numerik menggunakan metode TF-IDF. Metode ini memberikan bobot pada kata-kata berdasarkan frekuensi kemunculannya dalam dokumen tertentu dibandingkan dengan keseluruhan dokumen. Dengan cara ini, kata-kata yang sering muncul tetapi kurang informatif dapat diminimalkan.

	aamiin	abdi	abis	abud	acara	acung	acungin	ada	adapt	adaptif	...
0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...
1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...
2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...
3	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...
4	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...
	yg	yo	you	yu	yuk	yukk	yusuf	yuu	zaytun	zon	
0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
1	0.093980	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2	0.192510	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
3	0.172332	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
4	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0

[5 rows x 2114 columns]

Gambar 3. Konversi Teks Huruf Menjadi Numerik Menggunakan TF-IDF

Pada Gambar 3 ditampilkan hasil dari proses konversi data teks menjadi representasi numerik menggunakan metode TF-IDF. Proses ini merupakan salah satu tahap penting dalam *text preprocessing* pada analisis sentimen. Tujuannya adalah mengubah kata-kata dalam *tweet* yang semula berbentuk teks mentah menjadi vektor angka yang dapat dipahami dan diolah oleh algoritma *machine learning*, termasuk SVM.

Metode TF-IDF menghitung nilai numerik berdasarkan dua komponen utama, yaitu: *Term Frequency* (TF): Seberapa sering kata muncul dalam suatu dokumen. *Inverse Document Frequency* (IDF): Seberapa unik kata tersebut di seluruh korpus dokumen. Nilai TF-IDF yang dihasilkan mencerminkan pentingnya suatu kata dalam dokumen tertentu relatif terhadap semua dokumen lainnya. Semakin tinggi nilainya, semakin relevan kata tersebut dalam konteks dokumen tersebut. Hasil pada Gambar 3 memperlihatkan data vektor dari 5 *tweet* yang telah dikonversi menjadi format numerik, masing-masing terdiri dari 2114 fitur (kolom), yang mewakili kata-kata unik dari keseluruhan korpus data. Misalnya, pada baris ke-1 (indeks 0), semua nilai masih 0, menunjukkan bahwa kata-kata pada kolom yang ditampilkan tidak muncul dalam *tweet* tersebut. Sementara itu, pada baris ke-2 (indeks 1), terdapat nilai seperti 0.093980 pada kata "yg", yang menunjukkan bobot TF-IDF dari kata tersebut dalam *tweet* tersebut. Proses transformasi ini sangat penting karena algoritma SVM hanya dapat bekerja dengan data numerik. Dengan representasi TF-IDF, model dapat mengenali pola kata dan frekuensinya, yang selanjutnya membantu dalam klasifikasi sentimen serta identifikasi topik yang dibahas dalam *tweet buzzer* politik Indonesia. Konversi teks ke dalam bentuk numerik seperti ini juga mendukung efisiensi dan akurasi dalam proses pelatihan dan pengujian model, serta memungkinkan proses klasifikasi dilakukan dengan pendekatan matematis dan sistematis.

Hasil prediksi data baru:		
	tweet	prediksi_label
0	Saya sangat kecewa dengan pelayanan pemerintah.	negatif
1	Luar biasa, programnya sangat membantu rakyat!	positif
2	Biasa aja sih, nggak ngaruh banget.	positif

Gambar 4. Hasil Prediksi Model terhadap Tweet Bar

Pada Gambar 4 menampilkan hasil prediksi sentimen dari model SVM terhadap data *tweet* baru. Pada tahap ini, model yang telah dilatih digunakan untuk mengklasifikasikan *tweet* yang belum pernah dilihat sebelumnya ke dalam kategori sentimen tertentu, yaitu positif, netral, atau negatif.

Model membaca teks pada setiap *tweet*, kemudian menentukan label sentimen berdasarkan pola yang telah dipelajari dari data latih. Misalnya, tweet seperti "*Saya sangat kecewa dengan pelayanan pemerintah.*" diklasifikasikan sebagai negatif, sedangkan *tweet* seperti "*Luar biasa, programnya sangat membantu rakyat!*" diklasifikasikan sebagai positif. Hal ini menunjukkan bahwa model mampu mengenali konteks emosional dari kata-kata yang digunakan dalam *tweet* tersebut. Proses ini penting karena merupakan langkah akhir dalam *pipeline* klasifikasi sentimen, di mana model digunakan untuk mengambil keputusan pada data nyata yang tidak memiliki label. Hasil prediksi ini kemudian dapat dimanfaatkan untuk berbagai analisis lanjutan, seperti pemetaan opini publik atau deteksi keberpihakan politik.

Hasil Prediksi vs Label Aktual:				
	tweet \	clean_tweet	label	prediksi_label
0	LUHUT KECEPLOSAN CAPRES TERNYATA HANYA DUA CAL...	luhut ceplos capres calon	netral	netral
1	Buzzerp suruh patungan nyicil utang proyek Man...	buzzerp suruh patungan nyicil utang proyek man...	negatif	negatif
2	Bukanya kesehjatraan yang warikan Malah utang ...	buka kesehjatraan wari utang yg waris	negatif	negatif
3	Pasti dengan kemampuan kerja yg mumpuni, Pakpr...	mampu kerja yg mumpuni pakprabowokita emangpas...	positif	positif
4	Hajar terus pak Ganjar! Kalo udah bagus buat a...	hajar ganjar kalo udah bagus diubahubah mantap...	positif	positif
5	KETIKA BUZZERP JOKOWI MIMPI BASAH JALAN TOL.....	buzzerp jokowi mimpi basah jalan tol	negatif	negatif
6	Jokowi Takut Jika Proyek Kereta Cepat Terbongk...	jokowi takut proyek kereta cepat bongkar	negatif	negatif
7	dengan tangan emas ini, bukti ET Pemimpin Peke...	tangan emas bukti et pimpin kerja sungguh pimpin	positif	positif
8	Mandalika meninggalkan luka! ❤️❤️ JIS meningga...	mandalika tinggal luka jis tinggal cerita manies	positif	positif
9	Iye lah.. Suara Anies kan, Suara Prabowo. Klo ...	iye suara anies suara prabowo klo die gak maju...	netral	netral

Gambar 5. Evaluasi Prediksi Model terhadap Label Aktual

Gambar 5 menampilkan perbandingan antara hasil prediksi sentimen yang dilakukan oleh model SVM dengan label sentimen aktual yang telah tersedia pada dataset uji. Dalam tabel tersebut, kolom *tweet* menunjukkan isi asli dari *tweet*, sedangkan kolom *clean tweet* menampilkan versi teks yang telah dibersihkan dari *noise* (seperti simbol, emoji, dan kata tidak penting). Kolom label berisi label aktual yang merupakan hasil anotasi manual, dan kolom *prediksi_label* merupakan hasil klasifikasi dari model.

Dari hasil evaluasi ini, dapat diketahui sejauh mana akurasi model dalam mengklasifikasikan sentimen *tweet*. Contohnya, pada *tweet* "Buzzerp suruh patungan nyicil utang proyek man..." model berhasil mengklasifikasikan sentimen sebagai *negatif*, sesuai dengan label aslinya. Sementara itu, jika terjadi perbedaan antara

prediksi dengan label aktual, hal ini dapat digunakan untuk mengevaluasi kesalahan klasifikasi dan meningkatkan kinerja model kedepannya. Evaluasi ini sangat penting dalam proses pengembangan model pembelajaran mesin karena dapat memberikan gambaran objektif mengenai performa model dan area yang masih memerlukan perbaikan, baik dari sisi *preprocessing*, fitur, maupun parameter model. Berdasarkan pengujian yang telah dilakukan, didapatkan perbandingan hasil perhitungan akurasi, rata-rata *precision*, rata-rata *recall*, dan rata-rata *f1-score* yang ditampilkan pada Gambar 6.

```

Accuracy: 0.66
Macro average:
Precision: 0.6111111111111111
Recall: 0.5009362486676462
F1-score: 0.5132659932659932

Weighted average:
Precision: 0.6433333333333333
Recall: 0.66
F1-score: 0.6253292929292929

Classification Report per kelas:
precision    recall    f1-score   support
negatif      0.67     0.48     0.56      29
netral        0.50     0.14     0.22      14
positif       0.67     0.88     0.76      57
accuracy      -        -        0.66      100
macro avg     0.61     0.50     0.51      100
weighted avg  0.64     0.66     0.63      100

```

Gambar 6. Hasil evaluasi kinerja model svm

Pada Gambar 6 menunjukkan hasil evaluasi performa model klasifikasi sentimen menggunakan metode SVM. Evaluasi dilakukan dengan menggunakan metrik umum dalam klasifikasi yaitu akurasi, *precision*, *recall*, dan *f1-score*, baik dalam bentuk *macro average* maupun *weighted average*, serta laporan per kelas sentimen (negatif, netral, dan positif).

Berdasarkan hasil yang ditampilkan akurasi model secara keseluruhan adalah 66%, yang menunjukkan bahwa dari seluruh *tweet* yang diuji, sebanyak 66% berhasil diklasifikasikan dengan benar.

Macro average memperlakukan semua kelas secara setara, menghasilkan nilai:

- Precision*: 0.61
- Recall*: 0.50
- F1-Score*: 0.51

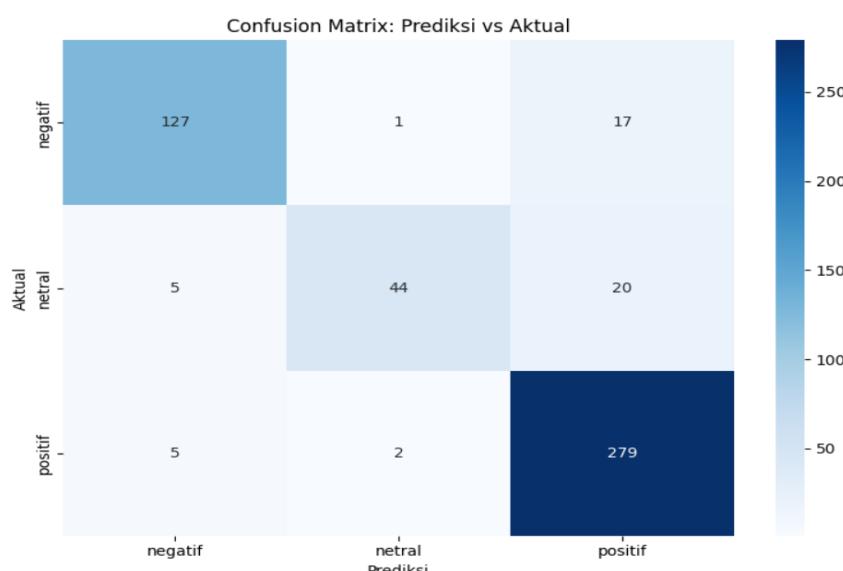
Weighted average, yang mempertimbangkan jumlah data pada tiap kelas, memberikan hasil:

- a. *Precision*: 0.64
- b. *Recall*: 0.66
- c. *F1-Score*: 0.63

Jika dilihat dari laporan klasifikasi per kelas:

- a. Kelas negatif memiliki *precision* 0.67, *recall* 0.48, dan *f1-score* 0.56.
- b. Kelas netral memiliki performa terendah, dengan *recall* hanya 0.14 dan *f1-score* 0.22, menunjukkan kesulitan model dalam mengidentifikasi *tweet* netral secara akurat.
- c. Kelas positif menunjukkan performa terbaik, dengan *recall* 0.88 dan *f1-score* 0.76.

Hasil ini mengindikasikan bahwa model SVM lebih efektif dalam mengenali *tweet* positif dibandingkan negatif dan netral. Salah satu penyebab rendahnya performa pada kelas netral bisa jadi karena jumlah data latih yang tidak seimbang atau karena kesamaan fitur dengan kelas lain, yang membuat model sulit membedakan *tweet* netral dari *tweet* bernuansa emosional. Evaluasi ini sangat penting untuk mengetahui kelemahan model dan menjadi dasar perbaikan, seperti dengan menyeimbangkan data atau menambahkan fitur representasi yang lebih kompleks seperti *word embeddings*.



Gambar 7. Confusion Matrix

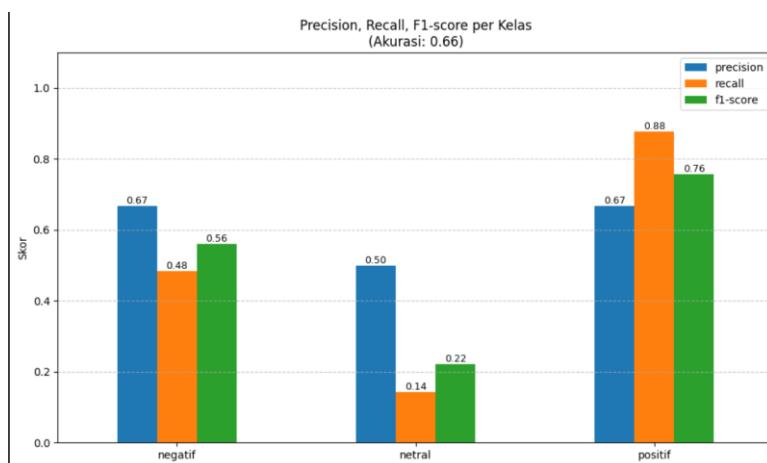
Gambar 7 menampilkan *confusion matrix* hasil evaluasi performa pada model *Support Vector Machine* (SVM) terhadap data uji. Dari matriks tersebut menunjukkan hubungan antara label aktual dan prediksi model untuk tiga kelas: negatif, netral, dan positif. Berdasarkan gambar, berikut adalah hasil klasifikasi:

- a. Negatif: Dari 145 tweet yang sebenarnya negatif, model berhasil mengklasifikasikan 127 tweet dengan benar sebagai negatif, 1 tweet salah diklasifikasikan sebagai netral, dan 17 tweet salah diklasifikasikan sebagai positif.

- b. Netral: Dari 69 tweet netral, hanya 44 yang diklasifikasikan dengan benar. Sebanyak 5 tweet diklasifikasikan sebagai negatif dan 20 sebagai positif.
- c. Positif: Dari 286 tweet positif, model mengklasifikasikan 279 tweet dengan benar. Namun, terdapat 5 tweet yang salah diklasifikasikan sebagai negatif dan 2 sebagai netral.

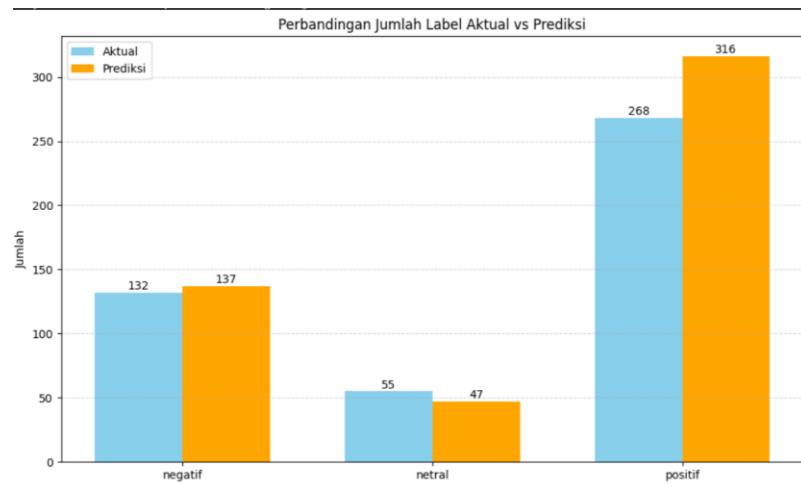
Temuan ini menunjukkan bahwa model SVM memiliki performa yang baik dalam mengenali sentimen positif, namun mengalami kesulitan dalam membedakan sentimen netral. Hal ini diperkuat oleh tingginya jumlah kesalahan klasifikasi pada tweet netral yang cenderung diklasifikasikan sebagai sentimen emosional (baik negatif maupun positif). Ketidakseimbangan jumlah data antar kelas, terutama minimnya jumlah data netral, menjadi salah satu penyebab rendahnya akurasi pada kelas ini.

Confusion matrix ini memperkuat hasil evaluasi metrik pada Gambar 6 dan Gambar 8, di mana recall dan f1-score untuk kelas netral tergolong rendah. Maka dari itu, perbaikan model dapat difokuskan pada peningkatan akurasi klasifikasi untuk sentimen netral, misalnya dengan penyeimbangan data atau pemilihan fitur yang lebih representatif.



Gambar 8. Visualisasi *precision*, *recall*, dan *f-1 score* per kelas

Pada Gambar 7 menampilkan skor evaluasi model SVM berdasarkan tiga metrik utama: *precision*, *recall*, dan *f1-score*. Berdasarkan visualisasi, terlihat bahwa kelas *positif* memperoleh performa terbaik dengan skor *f1-score* mencapai 0.76, dan *recall* tertinggi yaitu 0.88, menunjukkan bahwa model cukup andal dalam mengklasifikasi *tweet* dengan sentimen positif. Sementara itu, kelas *negatif* memiliki skor *precision* sebesar 0.67, namun untuk *recall* relatif rendah (0.48), yang berarti masih banyak *tweet* negatif yang tidak terkласifikasi dengan tepat. Kelas *netral* menunjukkan performa terendah dengan skor *recall* 0.14 dan *f1-score* 0.22, yang mengindikasikan kesulitan model dalam membedakan *tweet* netral dari sentimen positif dan negatif. Hal ini kemungkinan disebabkan oleh jumlah data yang tidak seimbang serta kemiripan semantik antara sentimen netral dengan sentimen positif dan negatif.



GAMBAR 9. Perbandingan Jumlah Label Aktual dan Prediksi

Pada Gambar 8 menggambarkan distribusi jumlah data aktual dan prediksi dari setiap kategori sentimen. Terlihat bahwa:

- Untuk kelas *positif*, model mendapatkan 316 *tweet* prediksi, sementara pada data aktual berjumlah 268 *tweet*. Ini menunjukkan adanya kecenderungan model untuk mengklasifikasikan *tweet* ke dalam kategori positif.
- Pada kelas *negatif*, model mendapatkan 137 *tweet* prediksi, sementara pada data aktual berjumlah 132 *tweet*. Hal ini menunjukkan model dapat memprediksi *tweet* negatif dengan baik.
- Namun untuk kelas *netral*, model mendapatkan 47 *tweet* prediksi, sementara pada data aktual berjumlah 55 *tweet*. Hal ini menegaskan bahwa kelas *netral* menjadi tantangan tersendiri bagi model.

Ketidakseimbangan distribusi ini menegaskan pentingnya teknik seperti *resampling* atau *class weight balancing* dalam pelatihan model agar mampu mengenali kelas minoritas secara lebih akurat

KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, klasifikasi sentimen *tweet* *buzzer* politik Indonesia menggunakan metode SVM dan TF-IDF menunjukkan hasil yang cukup baik. Dataset yang digunakan terdiri dari 500 *tweet* yang telah melalui proses *preprocessing* berupa pembersihan teks, tokenisasi, penghapusan *stopword*, dan *stemming* yang berperan penting dalam meningkatkan kualitas data. Representasi data teks kemudian diubah menjadi bentuk numerik menggunakan metode TF-IDF untuk memudahkan pemrosesan oleh model klasifikasi. Model SVM dengan kernel linear dipilih karena kemampuannya yang baik dalam menangani data berdimensi tinggi seperti TF-IDF. Hasil evaluasi menunjukkan bahwa model mampu mengklasifikasikan *tweet* ke dalam tiga kelas sentimen positif, negatif, dan netral dengan tingkat akurasi sebesar 66%. Selain itu, nilai *precision*, *recall*, dan *F1-score*

menunjukkan bahwa model cukup baik dalam mengenali sentimen positif dan negatif, namun performanya masih lemah dalam mendeteksi sentimen netral. Hal ini kemungkinan disebabkan oleh ketidakseimbangan jumlah data antar kelas, di mana kelas netral memiliki jumlah data yang jauh lebih sedikit dibandingkan kelas lainnya. Secara keseluruhan, metode SVM dapat dikatakan cukup efektif dalam melakukan klasifikasi sentimen terhadap *tweet buzzer* politik. Meskipun demikian, untuk meningkatkan performa model, diperlukan peningkatan jumlah data khususnya pada kelas yang minoritas serta eksplorasi terhadap metode klasifikasi lainnya maupun penyetelan parameter yang lebih baik.

DAFTAR PUSTAKA

- Ahmad, F., & Amin, M. (2021). Deteksi buzzer politik berbasis machine learning: Studi kasus pilpres Indonesia 2019. *Jurnal Ilmu Komputer dan Informatika*, 7(1), 45-56.
- Almohaini, M., Alotaibi, R., & Mehmood, R. (2021). A Comparative Study of Machine Learning Techniques for Sentiment Analysis. *IEEE Access*, 9, 34749-34764.
- Alsaeedi, A., & Khan, M.Z. (2021). *Text Mining and Analytics: Recent Developments*. ACM Computing Surveys.
- Bojanowski, P., Grave, E., Joulin, A., & Mikolov, T. (2017). Enriching word vectors with subword information. *Transactions of the Association for Computational Linguistics*, 5, 135-146.
- Juditha, C. (2019). Buzzer di media sosial pada Pilkada dan Pemilu Indonesia. Prosiding Seminar Nasional Komunikasi dan Informatika, 3, 43-52.
- Kalimeri, K., Beiró, M. G., Delfino, M., Raleigh, R., & Cattuto, C. (2019). Predicting demographics, moral foundations, and human values from digital behaviors. *Computers in Human Behavior*, 92, 428-445.
- Kusuma, D. S., & Prasetyo, E. (2020). Analisis Sentimen Terhadap Tokoh Politik Indonesia di Media Sosial Twitter Menggunakan Metode Naive Bayes. *Jurnal Teknologi dan Sistem Komputer*, 8(1), 29-36.
- Liu, B. (2020). *Sentiment analysis: Mining opinions, sentiments, and emotions* (2nd ed.). Cambridge University Press.
- Lim, T. (2020). Penggunaan Buzzer Politik dalam Mempengaruhi Opini Publik: Analisis Polarisasi dan Disinformasi. *Jurnal Media dan Komunikasi*, 9(2), 92-107.
- Maulidiyah, D., & Putra, F. H. (2021). Peran Buzzer dalam Dinamika Politik di Media Sosial. *Jurnal Komunikasi Politik*, 7(2), 151-165.
- Mola, F., Sutanto, T., & Rachmat, A. (2024). Perbandingan Algoritma Naïve Bayes dan Support Vector Machine untuk Analisis Sentimen pada Media Sosial: Studi Kasus Pelantikan Artis DPR 2024. *Jurnal Teknologi dan Komunikasi*, 10(4), 88-102.

- Nugroho, Y., & Syarief, S. S. (2020). Politics of buzzer: Social media activism and manufacturing consent in Indonesia. *Asian Journal of Media and Communication*, 4(1), 48-65.
- Nugroho, Y., Syarifudin, F., & Widjajanto, W. (2022). Strategi Komunikasi Buzzer Politik dalam Pemilu 2019 di Media Sosial. *Jurnal Ilmu Komunikasi*, 19(1), 47-60.
- Nurhasanah, M., & Naufal, R. (2024). Klasifikasi Sentimen Buzzer Politik pada Pemilu 2024 menggunakan Metode Lexicon-Based. *Jurnal Ilmu Komputer dan Informatika*, 14(1), 45-59.
- Pranckevičius, T., & Marcinkevičius, V. (2017). Comparison of naive Bayes, random forest, decision tree, support vector machines, and logistic regression classifiers for text reviews classification. *Baltic Journal of Modern Computing*, 5(2), 221-232.
- Saputra, N., Thamrin, H., & Wiyono, S. (2021). Political discourse analysis on Indonesian Twitter using topic modeling. *International Journal of Advanced Computer Science and Applications*, 12(8), 324-332.
- Suciati, W., Sa'adah, S., & Budiarto, A. (2020). Analisis sentimen Twitter pada pemilihan presiden Indonesia 2019 menggunakan metode Support Vector Machine. *Journal of Information Systems*, 16(2), 78-91.
- Sastramidjaja, D., & Wijayanto, W. (2021). Strategi Buzzer Politik dalam Kampanye Digital: Pengaruh Jaringan Akun Otomatis dan Manusia. *Jurnal Komunikasi Politik*, 12(3), 115-130.
- Wijayanto, A. W. (2020). Uncovering topics and their evolution in scholarly publications using dynamic topic modeling. *Scientometrics*, 125, 2451-2476.
- Wankhade, M., et al. (2022). *A Survey on NLP for Social Media Text*. IEEE Access