

# ANALISIS SENTIMEN KOMENTAR YOUTUBE PIDATO KEMENANGAN PRABOWO SUBIANTO MENGGUNAKAN NAÏVE BAYES OPTIMASI PARTICLE SWARM OPTIMIZATION

1<sup>st</sup> Ikhtiar Oktafio Wibowo

Fakultas Informatika  
Universitas Telkom

Purwokerto, Indonesia

tiaroktafio@student.telkomuniversity.a  
c.id

2<sup>nd</sup> Paradise, S.Kom., M.Kom

Fakultas Informatika  
Universitas Telkom

Purwokerto, Indonesia

paradise@telkomuniversity.ac.id

3<sup>rd</sup> Dian Kartika Sari, S.Si.,M.Pd

Fakultas Informatika  
Universitas Telkom

Purwokerto, Indonesia

dianks@telkomuniversity.ac.id

**Abstrak** — Pilpres 2024 menjadi momentum penting dalam dinamika politik Indonesia yang memicu diskusi luas, terutama di media sosial seperti YouTube. Penelitian ini bertujuan untuk menganalisis sentimen publik terhadap pidato pertama Prabowo Subianto pasca-kemenangan Pilpres 2024 dengan menggunakan algoritma Naïve Bayes yang dioptimasi melalui Particle Swarm Optimization (PSO). Metode ini dipilih untuk meningkatkan akurasi dan keseimbangan performa analisis sentimen dibandingkan Naïve Bayes klasik. Data penelitian diambil dari 4.035 komentar video di kanal YouTube KompasTV kemudian melalui tahapan preprocessing meliputi case folding, tokenizing, stemming, dan pembobotan menggunakan Term Frequency-Inverse Document Frequency (TF-IDF). Dataset ini dibagi menjadi data latih dan data uji dengan perbandingan 75:25. Hasil penelitian menunjukkan bahwa penerapan PSO pada model Naïve Bayes memberikan peningkatan akurasi global dari 74,73% menjadi 75,16%. Pada kategori sentimen negatif, presisi meningkat dari 56% menjadi 59%, meskipun recall menurun dari 67% menjadi 64%. Untuk sentimen netral, presisi menurun dari 75% menjadi 71%, namun recall meningkat dari 55% menjadi 61%, menghasilkan kenaikan F1-Score dari 64% menjadi 66%. Pada sentimen positif, presisi meningkat dari 79% menjadi 81%, sementara recall menurun dari 90% menjadi 87%, dengan F1-Score yang tetap konsisten di 84%. Secara keseluruhan, optimasi PSO berhasil meningkatkan keseimbangan antara presisi dan recall, terutama pada kelas netral dan positif, menunjukkan efektivitasnya dalam mengoptimalkan parameter model.

**Kata kunci**— analisis sentimen, naïve bayes, particle swarm optimization, youtube, pilpres 2024

## I. PENDAHULUAN

Pilpres 2024 merupakan salah satu peristiwa politik terbesar di Indonesia yang menarik perhatian luas dari masyarakat. Seiring dengan berkembangnya teknologi digital, diskusi mengenai hasil Pilpres 2024 tidak hanya berlangsung di dunia nyata tetapi juga di dunia maya, khususnya di media sosial seperti YouTube[1]. Platform ini menjadi tempat utama bagi masyarakat untuk mengungkapkan opini mereka, baik dalam bentuk dukungan

maupun kritik terhadap hasil pemilu serta pidato kemenangan kandidat yang terpilih [2].

Analisis sentimen merupakan metode yang digunakan untuk memahami opini publik dengan mengklasifikasikan sentimen menjadi kategori positif, negatif, atau netral. Salah satu algoritma yang umum digunakan dalam analisis sentimen adalah Naïve Bayes, yang dikenal dengan efisiensi dan akurasinya dalam klasifikasi teks[3]. Namun, algoritma ini memiliki keterbatasan dalam menangani ketidakseimbangan data serta fitur teks yang kompleks. Oleh karena itu, diperlukan metode optimasi untuk meningkatkan kinerjanya, salah satunya dengan menggunakan Particle Swarm Optimization (PSO). PSO adalah teknik optimasi berbasis metaheuristik yang meniru perilaku kawanan dalam mencari solusi optimal[4].

Penelitian ini bertujuan untuk menganalisis sentimen komentar publik terhadap pidato kemenangan Prabowo Subianto setelah Pilpres 2024 yang diunggah di kanal YouTube KompasTV[5]. Dengan menggabungkan Naïve Bayes dan PSO, penelitian ini berupaya meningkatkan akurasi dan keseimbangan dalam klasifikasi sentimen dibandingkan dengan penggunaan Naïve Bayes secara konvensional.

Masalah utama yang diangkat dalam penelitian ini adalah bagaimana performa algoritma Naïve Bayes sebelum dan sesudah dilakukan optimasi dengan PSO dalam menganalisis sentimen publik. Selain itu, penelitian ini juga bertujuan untuk mengevaluasi efektivitas optimasi PSO dalam meningkatkan akurasi klasifikasi sentimen di media sosial[6]. Dengan adanya penelitian ini, diharapkan dapat memberikan wawasan lebih lanjut mengenai pola opini publik dalam ranah politik digital serta menjadi referensi bagi pengembangan model analisis sentimen yang lebih akurat dan efisien di masa depan[7].

II. KAJIAN TEORI

A. Naïve Bayes Classifier

Naïve Bayes adalah algoritma klasifikasi berbasis probabilitas yang menggunakan Teorema Bayes dengan asumsi bahwa setiap fitur dalam data bersifat independen satu sama lain [1]. Algoritma ini sering digunakan dalam analisis sentimen, pemfilteran spam, dan klasifikasi dokumen karena kemampuannya dalam menangani dataset berukuran besar dengan efisiensi tinggi. Teorema Bayes dinyatakan sebagai berikut[8]:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

- P(A|B) adalah probabilitas hipotesis A diberikan kepada data B.
- P(B|A) adalah probabilitas data B terjadi jika hipotesis A benar.
- P(A) adalah probabilitas awal hipotesis A.
- P(B) adalah probabilitas data B.

B. Particle Swarm Optimization(PSO)

PSO merupakan algoritma optimasi berbasis metaheuristik yang dikembangkan oleh James Kennedy dan Russell Eberhart pada tahun 1995 [5]. PSO terinspirasi dari perilaku sosial kawanan burung yang mencari makanan secara kolektif [6]. Dalam algoritma ini, setiap solusi potensial disebut partikel, dan sekelompok partikel membentuk swarm[9].

C. Confussion Matrix

Confusion Matrix adalah cara yang digunakan untuk mengevaluasi model klasifikasi dengan memperkirakan objek yang diklasifikasikan dengan benar atau salah. Matriks ini membandingkan prediksi dengan kelas asli dari data input, atau dengan kata lain, berisi informasi tentang nilai aktual dan prediksi dalam klasifikasi. Hasil klasifikasi yang diperoleh kemudian dievaluasi, dan nilai yang didapat dari evaluasi ini digunakan untuk mengukur tingkat keberhasilan metode yang digunakan dalam pengujian.[10]

TABEL 1 (CONFUSION MATRIX)

	Prediksi Positif	Prediksi Negatif	Prediksi Netral
Aktual Positif	TP	FN	FN
Aktual Negatif	FP	TP	TN
Aktual Netral	FP	TN	TP

Keterangan :

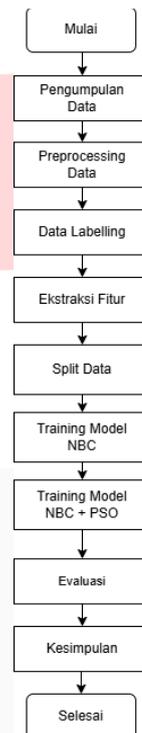
- TP (*true positive*) : mengacu pada jumlah data yang diklasifikasikan sebagai positif dan benar-benar positif sesuai dengan data aktual.
- FP (*false positive*) : mengacu pada jumlah data yang diklasifikasikan sebagai negatif, tetapi sebenarnya data tersebut adalah positif.

- TN (*true negative*) : mengacu pada jumlah data yang diklasifikasikan sebagai negatif dan benar-benar negatif sesuai dengan data aktual.
- FN (*false negative*) : mengacu pada jumlah data yang diklasifikasikan sebagai positif, tetapi sebenarnya data tersebut adalah negatif.

III. METODE

A. Diagram Alir Penelitian

Berikut adalah urutan dalam penelitian ini :



GAMBAR 1 (DIAGRAM ALIR PENELITIAN)

B. Pengumpulan Data

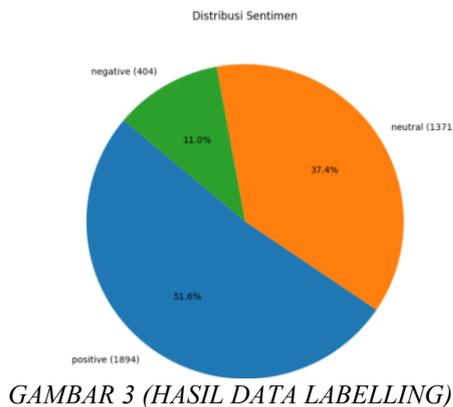
Pengumpulan data telah dilakukan pada komentar video Youtube yang berjudul “Pidato Pertama Prabowo Usai Dinyatakan Menang Pilpres 2024 oleh KPU” dengan url <https://www.youtube.com/watch?v=5DbCvqfg-9I>. Pengumpulan dataset berjumlah sebanyak 4035 komentar yang diambil dari Youtube menggunakan Google Colab, dan Youtube Data Application Programming Interface (API). Proses ini melibatkan inisialisasi API, pengambilan komentar berdasarkan ID video, dan penyimpanan hasilnya ke dalam file CSV.

GAMBAR 2 (DATASET)

C. Preprocessing Data

Preprocessing adalah tahapan awal dalam pengolahan data teks merupakan serangkaian langkah penting dalam pengolahan data teks yang bertujuan untuk membersihkan, menyederhanakan, dan meningkatkan kualitas data sebelum dilakukan analisis mendalam. Tahapan preprocessing meliputi case folding, cleaning, tokenizing, normalisasi, filtering/stopword removal, stemming. Tahapan ini sangat penting karena dapat mengurangi noise, redundansi, dan kompleksitas data, sehingga meningkatkan akurasi dalam analisis teks selanjutnya.

IV. HASIL DAN PEMBAHASAN



GAMBAR 3 (HASIL DATA LABELLING)

Pada gambar 3 didapatkan bahwa hasil setelah pelabelan dengan menggunakan kamus lexicon didapatkan data sebesar 1894 bermuatan positif, 1371 bermuatan netral dan 404 bermuatan negatif dari total keseluruhan data yang diperoleh dari hasil preprocessing yaitu berjumlah 3669 kata. Setelah melalui tahapan labelling selanjutnya dataset akan divisualisasikan kedalam bentuk wordcloud dari kelas positif, negatif, dan netral.



Gambar 4 Wordcloud

Selanjutnya split dataset dilakukan menggunakan library scikit-learn dengan parameter untuk menjamin konsistensi hasil. Selanjutnya, untuk mengatasi permasalahan ketidakseimbangan distribusi label pada dataset, diterapkan Oversampling pada data training menggunakan library imbalanced-learn. Proses oversampling ini dilakukan dengan cara menduplikasi sampel dari kelas minoritas secara acak hingga jumlahnya setara dengan kelas mayoritas, sehingga menghasilkan distribusi kelas yang seimbang pada data training. split dataset menjadi data training dan data testing dengan rasio 75:25, dimana 75% data digunakan sebagai data

training dan 25% digunakan sebagai data testing metode split data dengan rasio 75:25 terbukti menghasilkan akurasi terbaik untuk klasifikasi data[28].

TABEL 2 (SPLIT DATASET)

Data Training	Data Testing
7227	918

Selanjutnya Peneliti melakukan pembobotan kata-kata dengan cara memberikan nilai pada setiap text yang telah melalui proses preprocessing dan pelabelan menggunakan pendekatan berbasis lexicon. Langkah ini bertujuan agar metode Term Frequency-Inverse Document Frequency (TF IDF) dapat digunakan untuk menghitung serta mengukur relevansi kata-kata yang terdapat dalam suatu dokumen terhadap keseluruhan koleksi dokumen.

format: (row, col)	TF	IDF	TF-IDF
(0, 12616)	TF: 1	IDF: 2.7622	TF-IDF: 0.11877648419640381
(0, 15684)	TF: 1	IDF: 2.3868	TF-IDF: 0.10263471755127014
(0, 11647)	TF: 1	IDF: 4.0094	TF-IDF: 0.17240738826677954
(0, 6169)	TF: 1	IDF: 3.3330	TF-IDF: 0.1433205633642555
(0, 10820)	TF: 1	IDF: 5.3367	TF-IDF: 0.22948146213622936
(0, 17246)	TF: 1	IDF: 7.5985	TF-IDF: 0.326737863253651
(0, 834)	TF: 1	IDF: 3.5346	TF-IDF: 0.15198973670482832
(0, 19553)	TF: 1	IDF: 4.9884	TF-IDF: 0.21450418374996014
(0, 1364)	TF: 1	IDF: 3.7830	TF-IDF: 0.16266985099929046
(0, 12759)	TF: 1	IDF: 5.7740	TF-IDF: 0.24828176945409938
(0, 15827)	TF: 1	IDF: 4.6541	TF-IDF: 0.200126221823645
(0, 11656)	TF: 1	IDF: 4.3176	TF-IDF: 0.18565782819223842
(0, 6224)	TF: 1	IDF: 8.5148	TF-IDF: 0.36613860288878897
(0, 10837)	TF: 1	IDF: 8.5148	TF-IDF: 0.36613860288878897
(0, 17247)	TF: 1	IDF: 8.5148	TF-IDF: 0.36613860288878897
(0, 945)	TF: 1	IDF: 4.9884	TF-IDF: 0.21450418374996014
(0, 19556)	TF: 1	IDF: 6.8101	TF-IDF: 0.29283399182020364

GAMBAR 5 (HASIL TF IDF)

Setiap term memiliki nilai TF (Term Frequency) yang sama yaitu 1, namun memiliki nilai IDF yang berbeda-beda. Untuk mendapatkan nilai TF-IDF yang ternormalisasi, pertama kita kalikan TF dengan IDF untuk setiap term. Kemudian, untuk mendapatkan nilai L2 normalisasi, kita kuadratkan setiap hasil perkalian TF×IDF tersebut dan menjumlahkan semuanya. Setelah itu, kita mengambil akar kuadrat dari total penjumlahan tersebut, yang menghasilkan nilai L2 norm sebesar 23.2554. Nilai L2 norm ini kemudian digunakan sebagai pembagi untuk setiap hasil perkalian TF×IDF awal, sehingga menghasilkan nilai TF-IDF ternormalisasi. Sebagai contoh, untuk term pertama (0, 12616), nilai TF×IDF adalah 2.7622, yang setelah dibagi dengan L2 norm menghasilkan nilai TF-IDF ternormalisasi sebesar 0.1187764841964038. Proses normalisasi ini penting untuk memastikan bahwa panjang vektor setiap dokumen menjadi sama dan menghilangkan bias yang mungkin muncul akibat perbedaan panjang dokumen.

Selanjutnya Peneliti melakukan pemodelan menggunakan dua metode yang saling terintegrasi, yaitu Naïve Bayes Classifier (NBC) sebagai algoritma klasifikasi dan Particle Swarm Optimization (PSO) sebagai metode optimasi untuk seleksi fitur. Penerapan PSO bertujuan untuk mengoptimalkan kinerja klasifikasi dari algoritma NBC dengan cara memilih kombinasi fitur yang paling optimal.

TABEL 3 (CONFUSION MATRIX NAIVE BAYES)

Confusion Matrix		Predicted		
		Positive	Negative	Neutral
Actual	Positive	435	10	106
	Negative	14	69	41
	Neutral	37	24	182

Dapat dilihat tabel 3 hasil evaluasi model yang ditunjukkan dalam confusion matrix, distribusi prediksi untuk tiga kelas sentimen yaitu positif, negatif, dan netral. Model berhasil memprediksi dengan tepat 435 data positif, 69 data negatif, dan 182 data netral yang ditunjukkan pada diagonal utama matrix. Terdapat beberapa kesalahan klasifikasi dimana 14 data positif diprediksi sebagai negatif dan 37 data positif diprediksi sebagai netral. Untuk kelas negatif, 10 data diprediksi sebagai positif dan 106 data diprediksi sebagai netral. Sementara untuk kelas netral, 41 data salah diklasifikasikan sebagai negatif dan 24 data sebagai positif. Hasil ini menunjukkan bahwa model memiliki performa yang cukup baik dalam mengklasifikasikan sentimen positif, namun masih memiliki tantangan dalam membedakan antara sentimen netral dan negatif.

TABEL 4 (CONFUSION MATRIX NAIVE BAYES + PSO)

Confusion Matrix		Predicted		
		Positive	Negative	Neutral
Actual	Positive	422	7	92
	Negative	11	66	35
	Neutral	53	30	202

Berdasarkan tabel 4.5 hasil evaluasi model Naïve Bayes yang telah dioptimasi menggunakan Particle Swarm Optimization (PSO), confusion matrix menunjukkan performa klasifikasi untuk tiga kelas sentimen. Model berhasil mengklasifikasikan dengan tepat 422 data positif, 66 data negatif, dan 202 data netral yang terlihat pada diagonal

utama matrix. Terdapat beberapa kesalahan klasifikasi dimana 7 data positif diprediksi sebagai negatif dan 92 data positif diprediksi sebagai netral. Untuk kelas negatif, 11 data diprediksi sebagai positif dan 35 data diprediksi sebagai netral. Sementara untuk kelas netral, 53 data salah diklasifikasikan sebagai positif dan 30 data sebagai negatif. Berdasarkan perbandingan kedua confusion matrix, terlihat adanya penurunan true positive dari 435 menjadi 422 setelah optimasi menggunakan PSO, penurunan ini terjadi karena beberapa faktor penting.

Pertama, optimasi PSO yang dilakukan mencoba untuk menyeimbangkan performa model secara keseluruhan, tidak hanya fokus pada kelas positif. Hal ini terlihat dari peningkatan akurasi prediksi untuk kelas netral (neutral) yang naik dari 182 menjadi 202 kasus. Artinya, model hasil optimasi lebih baik dalam mengidentifikasi sentimen netral, meskipun dengan konsekuensi sedikit mengorbankan akurasi pada sentimen positif.

Kedua, trade-off ini sebenarnya menunjukkan model menjadi lebih robust dan seimbang. Terlihat dari berkurangnya misklasifikasi pada kelas negatif, di mana jumlah kasus yang salah diklasifikasikan sebagai positif turun dari 10 menjadi 7 kasus. Hal ini menunjukkan bahwa model hasil optimasi lebih berhati-hati dalam memberikan label positif, yang mungkin lebih diinginkan dalam banyak aplikasi analisis sentimen di dunia nyata.

Ketiga, perubahan parameter alpha melalui PSO (yang dibatasi antara 0.4 hingga 0.6) telah menghasilkan model yang lebih konservatif dalam klasifikasinya. Ini terlihat dari distribusi prediksi yang lebih merata di antara kelas-kelas yang ada, yang meskipun mengurangi true positive, tetapi meningkatkan keseimbangan dan reliabilitas model secara keseluruhan. Penting untuk dicatat bahwa penurunan 13 kasus (dari 435 ke 422) relatif kecil dibandingkan dengan peningkatan akurasi pada kelas-kelas lain, yang menunjukkan bahwa optimasi telah berhasil menemukan trade-off yang lebih optimal untuk performa model secara keseluruhan.

TABEL 5 (CLASSIFICATION REPORT NAIVE BAYES)

Label	Precision	Recall	F1-Score
Negatif	56%	67%	61%
Netral	75%	55%	64%
Positif	79%	90%	84%
Accuracy	74,73%		

TABEL 6 (CLASSIFICATION REPORT NAIVE BAYES + PSO)

Label	Precision	Recall	F1-Score
Negatif	59%	64%	61%
Netral	71%	61%	66%
Positif	81%	87%	84%

Akurasi	75,16%
---------	--------

Pada tabel 5 dan tabel 6 menunjukkan performa klasifikasi antara model Naïve Bayes standar dan model Naïve Bayes yang dioptimasi menggunakan PSO (Particle Swarm Optimization). Dari hasil yang ditampilkan, terlihat bahwa optimasi PSO memberikan peningkatan akurasi keseluruhan dari 74,73% menjadi 75,16%. Untuk kelas negatif, presisi meningkat dari 56% menjadi 59%, meskipun recall sedikit menurun dari 67% menjadi 64%, dengan F1-Score tetap stabil di 61%. Pada kelas netral, terjadi perubahan yang cukup signifikan dimana presisi sedikit menurun dari 75% menjadi 71%, namun recall meningkat dari 55% menjadi 61%, yang menghasilkan peningkatan F1-Score dari 64% menjadi 66%. Sementara untuk kelas positif, presisi mengalami peningkatan dari 79% menjadi 81%, meskipun recall sedikit menurun dari 90% menjadi 87%, dengan F1-Score tetap stabil di 84%.

Secara keseluruhan, penggunaan PSO berhasil meningkatkan keseimbangan antara presisi dan recall pada model, terutama untuk kelas Netral dan Positif. Meskipun beberapa metrik mengalami sedikit penurunan, peningkatan akurasi global menunjukkan bahwa optimasi PSO memberikan dampak positif terhadap performa klasifikasi model Naive Bayes. Hasil ini mengindikasikan bahwa penerapan PSO efektif dalam mengoptimalkan parameter model untuk mencapai hasil klasifikasi yang lebih baik.

## V. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, penggunaan algoritma Naive Bayes dalam klasifikasi sentimen menunjukkan performa yang cukup baik dengan tingkat akurasi mencapai 74,73%. Dalam implementasinya, model Naive Bayes mampu mengklasifikasikan sentimen positif dengan sangat baik, ditunjukkan oleh nilai recall 90% dan presisi 79% yang menghasilkan F1-Score 84%. Untuk klasifikasi sentimen netral, model mencapai presisi 75% meskipun recall-nya lebih rendah di angka 55% dengan F1-Score 64%. Sementara untuk sentimen negatif, model mencatatkan presisi 56% dan recall 67% dengan F1-Score 61%. Hasil ini menunjukkan bahwa Naive Bayes memiliki kemampuan yang baik dalam membedakan sentimen, terutama untuk kasus sentimen positif, meskipun masih ada ruang untuk peningkatan dalam klasifikasi sentimen netral dan negatif.

Setelah dilakukan optimasi menggunakan Particle Swarm Optimization (PSO), model Naive Bayes menunjukkan peningkatan performa secara keseluruhan dengan akurasi meningkat menjadi 75,16%. Optimasi PSO berhasil meningkatkan keseimbangan antara presisi dan recall pada beberapa kelas sentimen, seperti terlihat pada peningkatan presisi sentimen negatif menjadi 59% dan presisi sentimen positif menjadi 81%. Meskipun terdapat sedikit penurunan pada beberapa metrik, seperti recall sentimen positif yang turun menjadi 87%, namun secara umum penerapan PSO berhasil mengoptimalkan kinerja model dengan memberikan peningkatan yang signifikan pada F1-Score sentimen netral dari 64% menjadi 66%. Hal ini membuktikan bahwa penggunaan PSO sebagai metode optimasi mampu meningkatkan performa klasifikasi sentimen pada model

Naive Bayes dengan menciptakan keseimbangan yang lebih baik antara presisi dan recall pada setiap kelas sentimen.

## REFERENSI

- [1] A. Majid and A. Sugitanata, "Sistem Pemilu Sebagai Wujud Demokrasi Di Indonesia: Antara Orde Lama, Orde Baru Dan Reformasi," *Qaumiyah: Jurnal Hukum Tata Negara*, vol. 2, no. 1, pp. 1–21, Jun. 2021, doi: 10.24239/qaumiyah.v2i1.18.
- [2] J. Pendidikan Transformatif, M. Kafka Razaqa, F. Rafa Prawira, G. Santoso, and U. Muhammadiyah Jakarta, "Pengaruh Media Sosial Terhadap Orientasi Politik Pemilih Pemula Siswa Pada Pemilu".
- [3] D. A. Firdlous, R. Andrian, and S. Widodo, "Sentiment Analysis Public Twitter on 2024 Election using the Long Short Term Memory Model," *SISTEMASI*, vol. 12, no. 1, p. 52, Jan. 2023, doi: 10.32520/stmsi.v12i1.2145.
- [4] Sharazita Dyah Anggita and Ikma, "Algorithm Comparison of Naive Bayes and Support Vector Machine based on Particle Swarm Optimization in Sentiment Analysis of Freight Forwarding Services," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 4, no. 2, pp. 362–369, Apr. 2020, doi: 10.29207/resti.v4i2.1840.
- [5] T. M. Tinambunan, "Pemanfaatan Youtube Sebagai Media Komunikasi Massa Dikalangan Pelajar," *Jurnal Mutakallimin : Jurnal Ilmu Komunikasi*, vol. 5, no. 1, May 2022, doi: 10.31602/jm.v5i1.6756.
- [6] H. B. Jatmiko, N. Tedi Kurniadi, and D. Maulana, "Optimasi Naïve Bayes Dengan Particle Swarm Optimization Untuk Analisis Sentimen Formula E-Jakarta," *Journal Automation Computer Information System*, vol. 2, no. 1, pp. 22–30, Jun. 2022, doi: 10.47134/jacis.v2i1.35.
- [7] A. R. Lubis, M. K. M. Nasution, O. S. Sitompul, and E. M. Zamzami, "The feature extraction for classifying words on social media with the Naïve Bayes algorithm," *IAES International Journal of Artificial Intelligence (IJ-AI)*, vol. 11, no. 3, p. 1041, Sep. 2022, doi: 10.11591/ijai.v11.i3.pp1041-1048.
- [8] O. Irnawati and K. Solecha, "Analisis Sentimen Ulasan Aplikasi Flip Menggunakan Naïve Bayes dengan Seleksi Fitur PSO," *Jurnal Ilmiah Intech : Information Technology Journal of UMUS*, vol. 4, no. 02, pp. 189–199, Nov. 2022, doi: 10.46772/intech.v4i02.868.
- [9] Sharazita Dyah Anggita and Ikma, "Algorithm Comparison of Naive Bayes and Support Vector Machine based on Particle Swarm Optimization in Sentiment Analysis of Freight Forwarding Services," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 4, no. 2, pp. 362–369, Apr. 2020, doi: 10.29207/resti.v4i2.1840.
- [10] K. H. Yuniur, A. V. Vitianingsih, S. Kacung, A. Lidya Maukar, and A. Dwi Arumsari, "Sentiment Analysis of Cyberbullying Detection on Social Networks using the Sentistrength Method,"

*Sistemasi*, vol. 13, no. 4, p. 1587, 2024, doi:  
10.32520/stmsi.v13i4.4226.

