

Analisis Sentimen menggunakan Algoritma Machine Learning terhadap Isu Gencatan Senjata Iran-Trump di YouTube

Yeremia Agung Chandra^{1)*}, Jeremy Allegrato Hartono²⁾ & Hafiz Irsyad³⁾

^{1,2,3)}Prodi Informatika, Fakultas Ilmu Komputer dan Rekayasa,
Universitas Multi Data Palembang, Indonesia

*Corresponding Email: *1yeremiaagungchandra_2327250032@mhs.mdp.ac.id,
2jeremyallegratohartono_2327250004@mhs.mdp.ac.id, hafizirsyad@mdp.ac.id

Abstrak

Penelitian ini bertujuan untuk mengklasifikasikan sentimen publik di platform YouTube terkait isu gencatan senjata antara Iran dan mantan Presiden Amerika Serikat, Donald Trump. Dataset yang diambil dari komentar YouTube berjumlah 2000 dianalisis dan menghasilkan 576 data uji dengan distribusi sentimen yang tidak seimbang, pelabelan dataset menggunakan RoBERTa dengan 2 (dua) kelas, yaitu 428 label negatif, 114 netral, dan 34 positif. Ekstraksi fitur menggunakan pendekatan Bag-of-Words kombinasi *unigram* dan *bigram* untuk melatih algoritma machine learning, dengan fokus pada komparasi Support Vector Machine (SVM) dan Naïve Bayes. Hasil pengujian secara numerik menunjukkan bahwa Naïve Bayes memperoleh akurasi lebih tinggi sebesar 78.6% dengan skor macro F1 sebesar 0.503 akibat bias pada kelas mayoritas, sedangkan untuk SVM menghasilkan akurasi sebesar 74% dengan macro F1 mencapai 0.539. Penelitian ini berhasil mengimplementasikan model dengan baik meskipun Naïve Bayes unggul dalam akurasi umum karena dominasi data bersentimen negatif, SVM terbukti lebih seimbang dalam memetakan polarisasi sentimen publik yang kompleks di media sosial.

Kata Kunci: Analisis Sentimen, Machine Learning, SVM, RoBERTa, Opini Publik

Abstract

This study aims to classify public opinion sentiment on the YouTube platform regarding the ceasefire issue between Iran and former United States President Donald Trump. A dataset of 2,000 YouTube comments was analyzed, yielding 576 test data with an imbalanced sentiment distribution consisting of 428 negative, 114 neutral, and 34 positive labels. Following text cleaning, slang normalization, and stopword removal, automatic labeling was conducted using RoBERTa deep learning. Feature extraction utilized the Bag-of-Words approach combining unigrams and bigrams to train machine learning algorithms, focusing on a comparison between Support Vector Machine (SVM) and Naïve Bayes. Numerical test results showed that Naïve Bayes achieved a higher accuracy of 78.6% with a macro F1-score of 0.503 due to bias toward the majority class, whereas SVM produced an accuracy of 74.0% with a macro F1-score reaching 0.539. In conclusion, although Naïve Bayes excelled in overall accuracy due to the dominance of negative sentiment data, SVM proved to be more balanced in mapping the complex polarization of public sentiment on social media.

Keywords: Sentiment Analysis, Machine Learning, SVM, RoBERTa, Public Opinion

PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi dalam beberapa tahun terakhir telah mendorong meningkatnya penggunaan media sosial sebagai sarana utama dalam penyebaran informasi dan opini publik (Yadav, 2023). Platform seperti YouTube tidak hanya berfungsi sebagai media hiburan, tetapi juga menjadi ruang diskusi terbuka bagi masyarakat global dalam menanggapi berbagai isu, termasuk isu politik dan konflik internasional. Salah satu isu yang menarik perhatian publik adalah wacana gencatan senjata antara Iran dan Amerika Serikat yang melibatkan tokoh politik seperti Donald Trump. Opini masyarakat terhadap isu tersebut banyak tercermin dalam komentar pengguna di Youtube dapat dimanfaatkan sebagai sumber data untuk analisis lebih lanjut (Susanti et al., 2025).

Analisis sentimen merupakan salah satu teknik dalam bidang *Natural Language Processing* (NLP) yang digunakan untuk melakukan identifikasi dan juga klasifikasi opini ataupun emosi dalam teks ke dalam kategori tertentu, seperti positif, negatif, ataupun netral (Rajesh Kanna & Santhi, 2021). Teknik ini digunakan untuk memahami perspektif publik terhadap suatu topik tertentu, khususnya pada data yang berasal dari media sosial (Aftab et al., 2023). Dengan memanfaatkan data yang didapat dari komentar YouTube, analisis sentimen dapat memberikan gambaran yang komprehensif mengenai respons masyarakat terhadap isu gencatan senjata Iran-Trump.

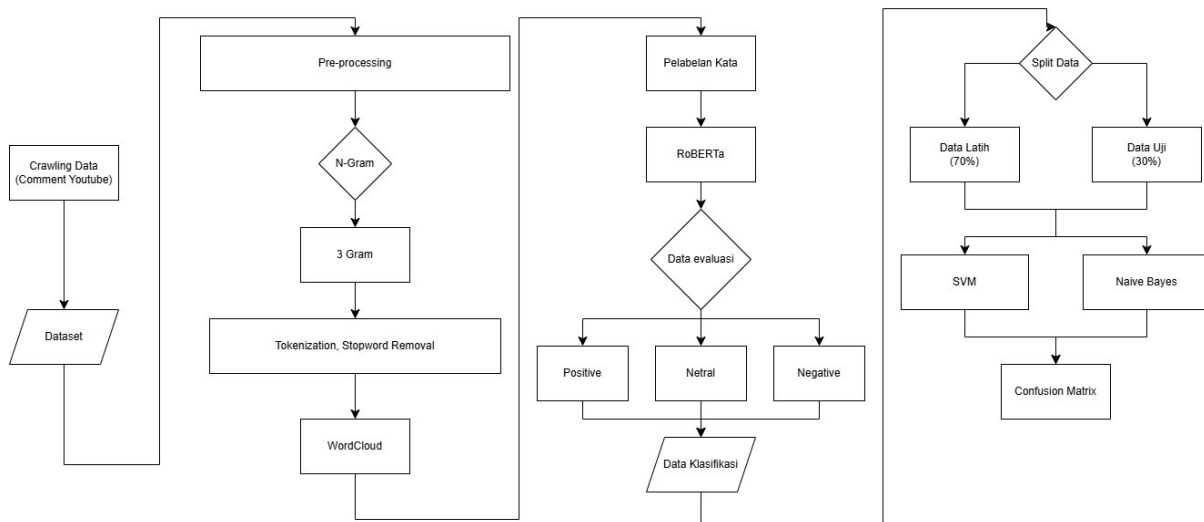
Dalam kasus analisis sentimen pada komentar YouTube, banyak metode *machine learning* yang digunakan pada beberapa penelitian terkait. Penelitian oleh (Rahman et al., 2020) menyatakan bahwa algoritma Naïve Bayes mampu digunakan untuk mengklasifikasikan sentimen komentar YouTube dengan tingkat akurasi yang cukup baik pada data bertema isu global dan sosial. Hasil penelitian tersebut menunjukkan bahwa pendekatan berbasis probabilitas masih efektif dalam menangani data teks yang sederhana namun jumlahnya besar.

Penelitian oleh (Arsi et al., 2021), menggunakan Naïve Bayes untuk melakukan analisis sentimen masyarakat terhadap pemindahan ibu kota melalui komentar YouTube. Hasil dari penelitian menunjukkan bahwa Naïve Bayes mampu bekerja dengan baik dalam mengklasifikasikan sentimen meskipun data bersifat tidak seimbang. Perkembangan model berbasis *transformer* seperti RoBERTa juga telah meningkatkan akurasi dalam proses pelabelan sentimen secara signifikan dibandingkan metode konvensional (Liu et al., 2019).

Walaupun berbagai penelitian telah dilakukan, sebagian besar masih berfokus pada topik umum seperti hiburan, bencana, ataupun isu sosial, sehingga penelitian yang membahas tentang isu geopolitik secara spesifik seperti konflik Iran dan Amerika Serikat masih terbatas. Untuk perbandingan kinerja algoritma *machine learning* pada dataset komentar YouTube yang bersifat *real-time* menjadi topik yang relevan untuk diuji lebih lanjut.

Berdasarkan permasalahan diatas, penelitian ini bertujuan untuk menganalisis sentimen publik terhadap isu gencatan senjata Iran-Trump berdasarkan komentar YouTube menggunakan pendekatan *machine learning*. Penelitian ini bertujuan mengetahui bagaimana sentimen publik terhadap isu gencatan senjata Iran-Trump dan algoritma mana yang memberikan performa klasifikasi terbaik.

METODE PENELITIAN



Gambar 1. Tahapan Penelitian

Penelitian ini menggunakan pendekatan *text mining* dan *machine learning* untuk menganalisis sentimen publik terhadap isu gencatan senjata Iran-Trump berdasarkan komentar pada platform Youtube. Analisis sentimen merupakan teknik dalam NLP yang bertujuan untuk mengidentifikasi opini dalam bentuk teks dan diklasifikasi ke dalam kategori sentimen seperti positif, negatif dan netral (Moro & Rita, 2022). Dalam penelitian ini, proses untuk menganalisis dilakukan dalam beberapa tahapan yaitu pengambilan data, prapemrosesan data, pelabelan data, ekstraksi fitur, proses klasifikasi, serta evaluasi model.

Data yang dalam penelitian kali ini berupa komentar dari pengguna YouTube yang diambil dari video terkait isu gencatan senjata Iran-Trump. Pengumpulan data dilakukan menggunakan *web scrapping* dengan bantuan library Python *youtube-comment-downloader* (Mehta & Deshmukh, 2022). Data yang diperoleh kemudian diproses menjadi dataset terstruktur untuk dapat digunakan dalam analisis lebih lanjut.

1. Pengumpulan Data

Tahap awal penelitian adalah pengambilan data komentar dari YouTube menggunakan teknik *crawling*. Data diambil dari video yang berkaitan dengan isu Iran-Trump dan disimpan sebagai dataset awal. Penggunaan data dari platform YouTube umum digunakan dalam penelitian analisis sentimen karena sifatnya yang real-time dan kaya opini pengguna (Mehta & Deshmukh, 2022).

2. Preprocessing Data

Tahap data preprocessing dilakukan untuk membersihkan data teks agar siap dianalisis. Proses yang dilakukan meliputi penghapusan duplikat, pembersihan teks dari URL dan simbol, *case folding*, normalisasi kata tidak baku, tokenisasi penghapusan stopword, dan penghapusan data kosong. Tahapan ini penting karena kualitas preprocessing sangat mempengaruhi performa model klasifikasi (Nur et al., 2025).

3. N-Gram

Pada tahap N-Gram akan dilakukan pemecahan kalimat menjadi rangkaian potongan kata yang berurutan. Hal ini bertujuan untuk mengatasi kelemahan Bag-of-Words yang sering menghilangkan makna semantik karena pemisahan teks menjadi kata tunggal secara acak. Pada penelitian ini, *Unigram* dan *Bigram* digabung saat proses pembentukan matriks fitur (Count Vectorizer). Melalui pendekatan ini, matriks yang telah dilatih dalam model akan mampu mempertahankan konteks lokal dan makna asli dari sentimen publik (Wankhade et al., 2022).

4. Labeling Data

Tahap pelabelan data ini, diberi label sentimen menggunakan model *pre-trained RoBERTa (Robustly Optimized BERT Pretraining Approach)* yang dimana model ini melakukan klasifikasi teks ke dalam kategori positif, negatif, dan netral berdasarkan konteks kalimat. Penggunaan model RoBERTa dalam pelabelan juga didukung dalam penelitian (Muhammad Mutawakkil Alallah et al., 2026), dimana dilakukan klasifikasi sentimen secara otomatis dan juga untuk meningkatkan kualitas proses pelabelan data melalui pemanfaatan model bahasa berbasis transformer yang telah dilatih menggunakan RoBERTa.

5. Ekstraksi Fitur

Untuk tahap ekstraksi fitur, akan dilakukan perubahan teks menjadi representasi numerik menggunakan metode *CountVectorizer* dengan pendekatan unigram dan bigram. Metode ini digunakan untuk menangkap frekuensi serta pola kemunculan kata dalam teks berbasis machine learning (Jamil et al., 2024).

6. *Splitting Data*

Pada proses *splitting data*, pembagian akan dibagi menjadi data latih dan data uji terlebih dahulu menggunakan metode *train-test split* dimana memiliki persentase data latih 70% dan data uji 30%. Pemilihan rasio 70:30 dilakukan karena sebagian besar data 70% digunakan untuk data latih agar model memiliki cukup informasi dalam mempelajari pola dan karakteristik data, lalu untuk 30% data uji digunakan untuk mengukur kemampuan model dalam melakukan prediksi terhadap data baru yang belum pernah dilihat. Tahap ini bertujuan menguji kemampuan generalisasi model terhadap data baru yang belum pernah dipelajari. Pembagian data yang tepat sangat penting untuk menghindari *overfitting* dan memastikan hasil evaluasi yang objektif (Iedwan et al., 2024).

7. Klasifikasi Data

Pada tahap klasifikasi data akan dilakukan pelatihan model menggunakan algoritma SVM dan Naïve Bayes (MultinomialNB). Kedua

algoritma ini banyak digunakan dalam analisis sentimen karena efisien dan memiliki performa yang baik pada data teks. SVM cenderung unggul dalam data kompleks, sedangkan Naïve Bayes lebih cepat dan sederhana dalam komputasi (Iedwan et al., 2024; Mahfudza & Ihksan, 2025).

SVM merupakan algoritma machine learning yang bertugas memetakan data ke dalam ruang berdimensi tinggi untuk menemukan batas pemisah (hyperlane) yang paling optimal antar kelas klasifikasi. Formula yang dipakai untuk SVM *linier* dapat dilihat pada persamaan 1 dibawah ini.

$$f(x) = \text{sign}(w \times x + b) \quad (1)$$

Naïve Bayes (*Multinomial*) adalah algoritma klasifikasi probabilistik dimana merujuk pada asumsi kuat bahwa setiap fitur kata dalam sebuah dokumen teks muncul secara independen, tanpa terpengaruh oleh kehadiran kata lainnya. Formula yang dipakai untuk Naïve Bayes (*Multinomial*) dapat dilihat pada persamaan 2 dibawah ini.

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)} \quad (2)$$

8. Evaluasi Model

Tahap terakhir yaitu adalah evaluasi performa antara 2 model algoritma yaitu SVM dan Naive Bayes menggunakan metrik akurasi, classification report, dan confusion matrix. Dalam Confusion Matrix terdapat 4 kondisi, yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN) yang berguna untuk mengukur tingkat keberhasilan klasifikasi (Nur et al., 2025).

Akurasi digunakan untuk menguji kesesuaian nilai hasil prediksi model dengan nilai sampel data yang dibandingkan. Perhitungan akurasi dilakukan dengan persamaan (3).

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

Precision digunakan untuk tingkat ketepatan informasi antara yang diminta oleh user dengan jawaban yang dihasilkan model. Perhitungan *precision* dapat dilakukan menggunakan persamaan (4).

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

Recall adalah tingkat banyak sedikitnya informasi sesuai dari hasil model berdasarkan label yang digunakan. Perhitungan *recall* dapat dilakukan menggunakan persamaan (5).

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

F1-Score digunakan untuk mengukur keseimbangan atau *harmonic* dari rata-rata antara *precision* dan *recall*. *F1-score* dapat dihitung menggunakan persamaan (6).

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision+Recall} \quad (6)$$

HASIL DAN PEMBAHASAN

Pengumpulan Data

Pada tahap ini digunakan data komentar YouTube yang diperoleh dari video terkait isu gencatan senjata Iran-Trump. Proses pengambilan data dilakukan menggunakan teknik *web scrapping* sehingga diperoleh data mentah berupa teks komentar pengguna. Setelah dilakukan proses penghapusan duplikasi dan pembersihan data, diperoleh dataset yang siap untuk dianalisis lebih lanjut. Data komentar ini mencerminkan opini publik yang bersifat beragam dan tidak terstruktur, sehingga diperlukan teknik *text mining* untuk mengolahnya menjadi informasi yang bermakna. Berikut merupakan beberapa hasil dari pengumpulan data yang ditaruh dalam Tabel 1 berikut ini.

Tabel 1. Hasil Pengumpulan Data

No.	Comment_text
0	Trump says he will extend ceasefire with Iran ...
1	This is an urgent prayer call for several Unde...
2	It means 1000+ precision slashes consistently ...
...	...
1915	CNN viewers are insufferable, FIRST, TRUMP is ...

Pre-Processing Data

Pada tahap pre-processing ini, data yang dihasilkan menjadi lebih bersih dan juga terstruktur. Proses seperti *cleaning*, *case folding*, normalisasi tokenisasi, dan *stopword removal* berhasil mengurangi noise dalam data teks. Selain itu penggunaan analisis n-gram menunjukkan pola kata yang lebih sering muncul dalam komentar terkait isu politik dan konflik internasional. Hasil ini menunjukkan bahwa data telah siap untuk digunakan dalam ekstraksi fitur dan pemodelan. Hasil dapat dilihat pada Tabel 2 berikut ini.

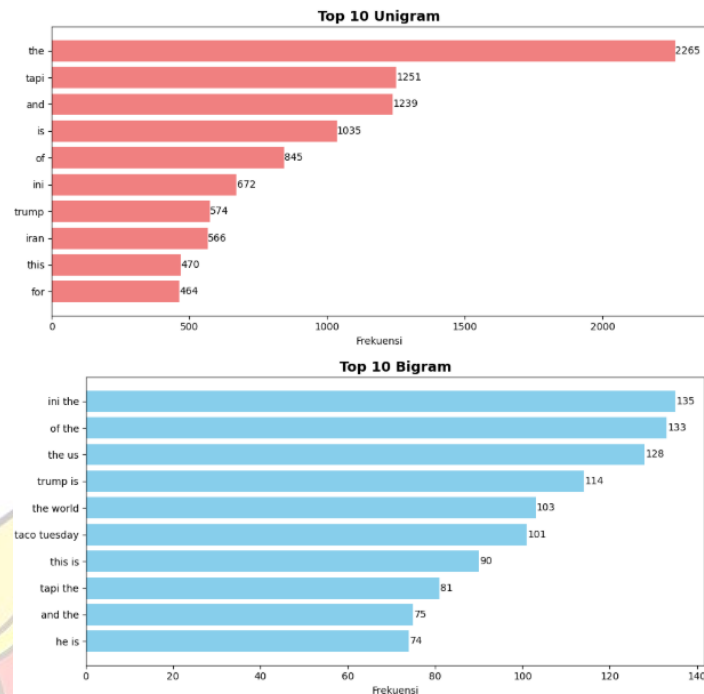
Tabel 2. Hasil Pre-Processing

No	normalisasi	tokenize	stopword_list	stopword_removal
0	trump says he will extend ceasefire with iran ...	[trump, says, he, will, extend, ceasefire, wit..	[trump, says, extend, ceasefire, iran, negotia...	trump says extend ceasefire iran negotiations ...
1	this is an urgent prayer call for several unde...	[this, is, an, urgent, prayer, call, for, seve...	[urgent, prayer, call, several, ground, church...	urgent prayer call several ground church membe...
2	itu means precision slashes consistently over ...	[itu, means, precision, slashes, consistently,...	[means, precision, slashes, consistently, prot...	means precision slashes consistently protracte...
...
1915	cnn viewers are insufferable first trump is st...	[cnn, viewers, are, insufferable, first, trump...	[cnn, viewers, insufferable, first, trump, sta...	cnn viewers insufferable first trump starting ...

N-Gram

Pada tahap N-Gram, akan dilakukan untuk mengubah data menjadi representasi matriks matematis. Penelitian ini difokuskan pada kombinasi *Unigram* yaitu metode untuk mengekstrak kata tunggal dengan frekuensi tertinggi dan *Bigram* yaitu metode untuk mengekstrak potongan dua kata berurutan untuk menangkap unsur semantic dari sebuah frasa baik itu kata majemuk ataupun unsur negasi menggunakan *CountVectorizer*. Hal ini bertujuan untuk menjaga secara utuh

mana asli dan konteks kalimat sebelum data diberikan pelabelan. Berikut ini merupakan hasil dari Unigram dan Bigram pada Gambar 2.

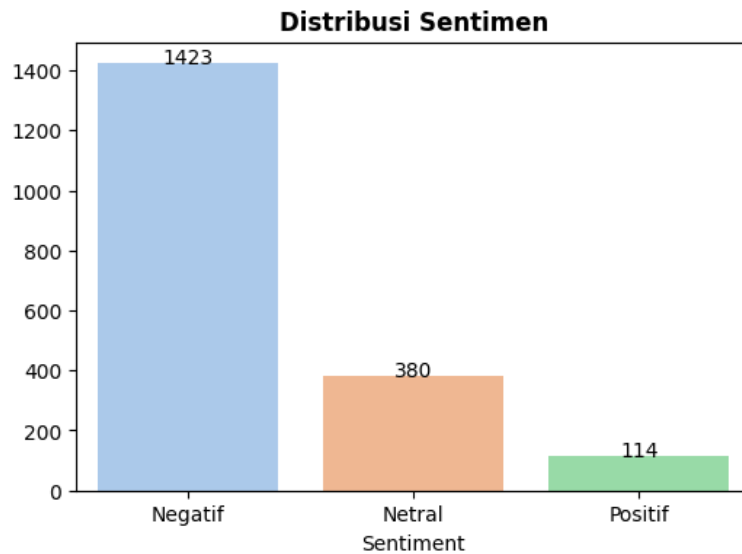


Gambar 2. Hasil Unigram dan Bigram

Disini terlihat pada Gambar 2 bahwa, top 10 dari kata *Unigram* adalah “the” dengan total 2265 kata dan top 10 kata dari *Bigram* adalah “in the” dengan total 135 kata.

Pelabelan Sentimen

Tahap pelabelan data menggunakan model RoBERTa menghasilkan tiga kategori sentimen, yaitu positif, negatif, dan netral. Berdasarkan hasil pelabelan, sebagian besar komentar lebih mengarah pada kategori negatif yang menunjukkan adanya respon krisis pada isu yang dibahas. Hal ini sejalan dengan karakteristik media sosial yang sering digunakan untuk mengekspresikan opini secara emosional. Hasil pelabelan data dapat dilihat pada Gambar 3.

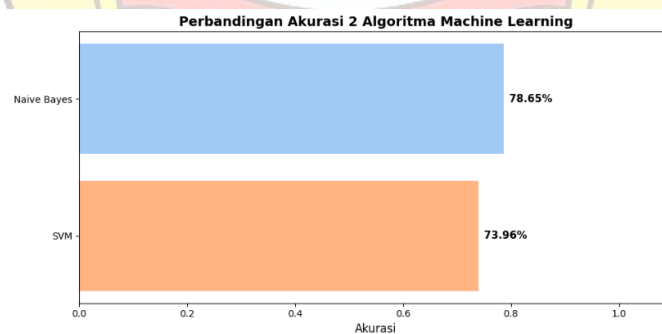


Gambar 3. Hasil Pelabelan dengan RoBERTa

Gambar 3 menunjukkan bahwa hasil dari pelabelan tiap kata menghasilkan 3 label dengan label Negatif paling tinggi dibandingkan Netral dan Positif.

Klasifikasi Model

Pada tahap klasifikasi digunakan dua algoritma yaitu SVM dan Naïve Bayes (MultinomialNB) lalu dilatih menggunakan data latih serta diuji menggunakan data uji. Hasil evaluasi menunjukkan bahwa Naïve Bayes memberikan performa yang lebih tinggi dibandingkan dengan SVM, dimana akurasi Naïve Bayes mencapai 78.65% sedangkan SVM 73.96%. Hasil perbandingan akurasi antara kedua algoritma dapat dilihat pada Gambar 4.



Gambar 4. Metrik Akurasi 2 Algoritma

Terlihat pada Gambar 3 bahwa perbandingan untuk tingkat akurasi metrics tersebut tidak terlalu jauh, dimana algoritma Naïve Bayes memiliki tingkat akurasi 4.69% lebih tinggi dibandingkan dengan algoritma SVM. Hasil untuk perbandingan *confusion matrix* antara 2 algoritma SVM dan Naïve Bayes juga ditampilkan pada Gambar 5 berikut ini.

		SVM			Naive Bayes		
		Negatif	Netral Prediksi	Positif	Negatif	Netral Prediksi	Positif
Aktual	Negatif	357	56	15	403	22	3
	Netral	51	61	2	65	47	2
	Positif	18	8	8	22	9	3

Gambar 5. Confusion Matrix untuk 2 Model Algoritma

Confusion Matrix pada Gambar 4 menunjukkan bahwa pada model algoritma SVM memiliki prediksi jumlah data pada kelas negatif sebanyak 357 data yang diklasifikasi benar, tetapi terdapat kesalahan klasifikasi sebanyak 56 data negatif diprediksi sebagai netral dan 15 sebagai positif. Untuk kelas netral sebanyak 61 data diklasifikasi benar sedangkan 51 data salah diklasifikasikan sebagai netral. Untuk kelas positif memiliki performa terendah dengan 8 data yang diklasifikasikan benar. Sedangkan untuk model algoritma Naïve Bayes lebih unggul dibandingkan dengan SVM dalam mengklasifikasikan data, terutama pada kelas negatif.

Ada juga *classification report* untuk 2 model algoritma yang dimana menampilkan data pada Tabel 3 dan Tabel 4 berikut ini.

Tabel 3. *Classification Report SVM (Linear)*

	precision	recall	f1-score	support
Negatif	0.838	0.834	0.836	428.000
Netral	0.488	0.535	0.510	114.000
Positif	0.320	0.235	0.271	34.000
accuracy	0.740	0.740	0.740	0.740
macro avg	0.549	0.535	0.539	576.000
weighted avg	0.738	0.740	0.738	576.000

Pada Tabel 3, model mencapai nilai *precision*, *recall*, dan *F1-score*, yang tinggi karena jumlah data latih untuk kelas negatif lebih banyak dibandingkan dengan kelas netral dan positif pada saat pelabelan data. Hal ini juga menyebabkan performa turun pada saat melakukan analisis pada kata kiasan dan menyebabkan kesalahan saat mengklasifikasi serta membuat nilai *precision* menurun untuk kelas positif dan netral. Akan tetapi untuk nilai *recall* yang masih tinggi pada kelas positif karena model SVM tetap berusaha untuk mencari data yang bernilai positif.

Untuk nilai *Accuracy* mencapai hasil diangka 0.740 karena model akan menebak data negatif lebih banyak. Tetapi hasil yang benar akan dilihat pada nilai *Macro Avg* yang dihitung dari rata-rata dari ketiga kelas yang meskipun data berbeda jauh, SVM memiliki stabilitas yang cukup wajar. Serta untuk nilai *Weighted Avg* yang memunculkan angka hampir menyerupai akurasi karena pembobotannya berdasarkan nilai *support* pada kelas Negatif.

Tabel 4. *Classification Report Naïve Bayes*

	precision	recall	f1-score	support
Negatif	0.822	0.942	0.878	428.000
Netral	0.603	0.412	0.490	114.000
Positif	0.375	0.088	0.143	34.000
accuracy	0.786	0.786	0.786	0.786
macro avg	0.600	0.481	0.503	576.000
weighted avg	0.753	0.786	0.758	576.000

Pada Tabel 4, karena dominasi dari jumlah data latih menciptakan bias probabilitas di awal, sehingga model memiliki kecenderungan untuk memukul rata prediksi ulasan ambigu ke arah sentimen Negatif. Hal ini membuat skor evaluasi *recall*, *precision*, dan *F1-score* naik. Sedangkan pada kelas netral dan positif

mengalami penurunan pada nilai recall, F1-score dikarenakan model memaksa untuk memprediksi kalimat negatif.

Untuk nilai *Accuracy* terlihat lebih tinggi dibandingkan SVM dikarenakan Naïve Bayes akan melakukan persama ratakan tebakan menjadi kearah mayoritas kelas negatif dengan bukti dataset memiliki kelas negatif paling tinggi. Begitu juga dengan *Macro Avg* yang mendapat nilai lebih rendah dibandingkan dengan SVM yang akan menimbulkan lebih banyak bias dan lebih rentan terhadap overfitting data.

SIMPULAN

Berdasarkan dari hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa analisis terhadap komentar YouTube pada isu gencatan senjata Iran-Trump dapat dilakukan secara efektif menggunakan pendekatan *text mining* dan juga *machine learning*. Proses pengumpulan data melalui crawling YouTube menghasilkan data komentar yang kemudian berhasil diolah melalui tahapan prapemrosesan seperti *cleaning*, *case folding*, normalisasi, tokenisasi, dan *stopword removal* sehingga data menjadi lebih bersih dan siap dianalisis. Hasil pelabelan menggunakan model RoBERTa menunjukkan bahwa komentar publik terhadap isu tersebut didominasi oleh sentimen tertentu yang mencerminkan respons emosional dan sentimen masyarakat terhadap isu geopolitik.

DAFTAR PUSTAKA

- Aftab, F., Bazai, S. U., Marjan, S., Baloch, L., Aslam, S., Amphawan, A., & Neo, T. K. (2023). A Comprehensive Survey on Sentiment Analysis Techniques. *International Journal of Technology*, 14(6), 1288–1298. <https://doi.org/10.14716/IJTECH.V14I6.6632>
- Arsi, P., Kusuma, B. A., & Nurhakim, A. (2021). Analisis Sentimen Pindah Ibu Kota Berbasis Naive Bayes Classifier. *Jurnal Informatika Upgris*, 7(1). <https://doi.org/10.26877/JIU.V7I1.7636>
- Iedwan, A. S., Mauliza, N., Pristyanto, Y., Hartanto, A. D., & Rohman, A. N. (2024). Comparative Performance of SVM and Multinomial Naïve Bayes in Sentiment Analysis of the Film "Dirty Vote." *Scientific Journal of Informatics*, 11(3), 839–848. <https://doi.org/10.15294/sji.v11i3.10290>
- Jamil, M., Hadiyanto, H., & Sanjaya, R. (2024). Sentiment Analysis: Classifying Public Comments on YouTube in Disaster Management Simulation in Indonesia Using Naïve

- Bayes and Support Vector Machine. *Ingenierie Des Systemes d'Information*, 29(2), 437–446. <https://doi.org/10.18280/ISI.290205>
- Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., Stoyanov, V., & Allen, P. G. (2019). *RoBERTa: A Robustly Optimized BERT Pretraining Approach*. <https://arxiv.org/pdf/1907.11692>
- Mahfudza, N., & Ihksan, M. (2025). Sentiment Analysis of Youtube Comments on Indonesian Presidential Candidates in 2024 using Naïve Bayes Classifier. *JURIKOM (Jurnal Riset Komputer)*, 12(2), 140–148. <https://doi.org/10.30865/jurikom.v12i2.8538>
- Mehta, T., & Deshmukh, G. (2022). YouTube Ad View Sentiment Analysis using Deep Learning and Machine Learning. *International Journal of Computer Applications*, 184(11), 10–14. <https://doi.org/10.5120/ijca2022922078>
- Moro, S., & Rita, P. (2022). Data and text mining from online reviews: An automatic literature analysis. In *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* (Vol. 12, Number 3). John Wiley and Sons Inc. <https://doi.org/10.1002/widm.1448>
- Muhammad Mutawakkil Alallah, Mokhammad Amin Hariyadi, Triyo Supriyatno, & Riana, E. (2026). Implementasi BERT dan IndoRoBERTa untuk Klasifikasi Sentimen Opini Publik tentang Kecerdasan Buatan dalam Pendidikan di YouTube. *JURIKOM (Jurnal Riset Komputer)*, 13(2), 666–678. <https://doi.org/10.30865/jurikom.v13i2.9697>
- Nur, A., Saputra, A., Saputro, R. E., & Saputra, S. (2025). Enhancing Sentiment Analysis Accuracy Using SVM and Slang Word Normalization on YouTube Comments. *Sinkron : Jurnal Dan Penelitian Teknik Informatika*, 9(2), 687–699. <https://doi.org/10.33395/SINKRON.V9I2.14613>
- Rahman, A., Rahmat, F., Fariqi, M. Y., & Adi, S. (2020). Naive Bayes Method to Analyze Sentiment Accuracy on YouTube Comments. *Jurnal EECCIS (Electrics, Electronics, Communications, Controls, Informatics, Systems)*, 14(1), 31–34. <https://doi.org/10.21776/JEECCIS.V14I1.627>
- Rajesh Kanna, P., & Santhi, P. (2021). Unified Deep Learning approach for Efficient Intrusion Detection System using Integrated Spatial–Temporal Features. *Knowledge-Based Systems*, 226, 107132. <https://doi.org/10.1016/j.knosys.2021.107132>
- Susanti, E., Maimunah, M., & Nugroho, S. (2025). Sentiment Analysis of YouTube Comments Using Machine Learning Models. *PIKSEL : Penelitian Ilmu Komputer Sistem Embedded and Logic*, 13(1), 103–114. <https://doi.org/10.33558/PIKSEL.V13I1.10743>
- Wankhade, M., Rao, A. C. S., & Kulkarni, C. (2022). A survey on sentiment analysis methods, applications, and challenges. *Artificial Intelligence Review*, 55(7), 5731–5780. <https://doi.org/10.1007/s10462-022-10144-1>
- Yadav, J. (2023). *Sentiment Analysis on Social Media*. <https://doi.org/10.32388/YF9X04>