J-CEKI : Jurnal Cendekia Ilmiah
Vol.5, No.1, Desember 2025

Analisis Sentimen Komentar YouTube terhadap Pengangkatan Menkeu Purbaya Menggunakan Algoritma SVM dan Naïve Bayes

Anggi Dian Oktavianingsih[1], Ahmad Fadlil Fauzi [2], Juan Immanuel [3], Ongki D.Simatupang[4], Fachri Amsury[5], Riza Fahlapi [6]
[1,2,3,4,5,6] Universitas Bina Sarana Informatika, Indonesia
E-mail: anggidian.oktavianingsih@gmail.com[1], ahmadcraft9@gmail.com[2], juanimmanuel37@gmail.com[3], ongkisimatupang27@gmail.com[4], fachri.fcy@bsi.ac.id[5], riza.rzf@bsi.ac.id[6]

Article History:
Received: 01 Desember 2025
Revised: 15 Desember 2025
Accepted: 17 Desember 2025

Keywords: *Analisis Sentimen; Komentar YouTube; Support Vector Machine; Naïve Bayes; Komentar Publik.*

Abstract: *Penelitian ini bertujuan untuk menganalisis sentimen warganet terhadap komentar YouTube yang membahas pengangkatan Purbaya Yudhi Sadewa sebagai Menteri Keuangan, sekaligus membandingkan performa algoritma Support Vector Machine (SVM) dan Naïve Bayes dalam proses klasifikasi. Sebanyak 1.202 komentar dikumpulkan dan melalui tahapan preprocessing sebelum dilakukan pelabelan manual. Hasil analisis menunjukkan bahwa sentimen positif mendominasi dengan proporsi 58%, diikuti sentimen netral 29%, dan negatif 13%. Hal ini mengindikasikan bahwa sebagian besar komentar awal dari pengguna YouTube bersifat mendukung atau memberikan penilaian yang cenderung baik terhadap topik yang dibahas. Pada evaluasi model, algoritma SVM menunjukkan performa lebih unggul dengan akurasi 66,39% dan f1-score 55,53%, sedangkan Naïve Bayes menghasilkan akurasi 62,66% dan f1-score 40,94%. Hasil uji 10-fold cross validation turut mengonfirmasi bahwa SVM memiliki tingkat konsistensi yang lebih baik dibandingkan Naïve Bayes. Berdasarkan hasil tersebut, SVM dinilai lebih sesuai digunakan dalam analisis sentimen komentar publik yang memiliki variasi bahasa cukup luas dan konteks yang tidak selalu eksplisit, seperti pada isu pemerintahan dan politik.*

PENDAHULUAN

Perkembangan pesat teknologi informasi telah mengubah perilaku masyarakat, baik dalam pola pikir, sikap, maupun tindakan sosial. Komunikasi digital melalui media sosial kini memainkan peran penting dalam pembentukan opini publik. Penyebaran informasi yang cepat, kemampuan pengguna untuk memberikan komentar, serta tingginya pengaruh tokoh publik di dunia digital menjadikan media sosial sebagai ruang yang strategis dalam dinamika persepsi masyarakat (Pratiwi & Suhendra, 2024). Media sosial juga berperan dalam menggiring opini serta memengaruhi persepsi masyarakat terhadap isu publik dan kinerja pemerintah. Dalam konteks demokrasi seperti Indonesia, opini publik memiliki posisi strategis karena mampu

mencerminkan tingkat kepercayaan dan respons masyarakat terhadap kebijakan maupun tokoh publik (Juleha et al., 2024).

Salah satu tokoh publik yang menarik perhatian warganet adalah Purbaya Yudhi Sadewa, terutama sejak ia dilantik sebagai Menteri Keuangan Republik Indonesia pada 8 September 2025 menggantikan Sri Mulyani Indrawati dalam perombakan kabinet Presiden Prabowo Subianto (Gayati, 2025). Sebelum menduduki jabatan tersebut, Purbaya dikenal sebagai ekonom senior yang pernah memimpin Lembaga Penjamin Simpanan (LPS) sebagai Ketua Dewan Komisioner serta menjabat sebagai Deputi Bidang Ekonomi di Kementerian Koordinator Bidang Perekonomian (Binekasri, 2024). Publik menunjukkan beragam respons terhadap pengangkatannya mulai dari dukungan, sikap menunggu, hingga kritik khususnya pada video yang menampilkan rapat perdana Purbaya bersama Komisi XI DPR RI. Reaksi warganet yang cenderung bersifat observasional dan netral menjadikan YouTube sebagai sumber data potensial untuk menganalisis persepsi publik menggunakan pendekatan analisis sentimen (Lestari & Berliani, 2024).

Analisis sentimen merupakan bagian dari *text mining* dan *natural language processing* (NLP) yang bertujuan untuk mengidentifikasi opini publik berdasarkan teks menjadi kategori positif, negatif, atau netral (Purnamasari et al., 2023).Teknik ini telah banyak diterapkan dalam bidang sosial, politik, ekonomi, hingga pemasaran karena kemampuannya dalam menangkap emosi dan sikap masyarakat terhadap suatu isu (Maulani et al., 2024). Di Indonesia, berbagai penelitian menggunakan analisis sentimen telah digunakan untuk mengukur persepsi publik terhadap kebijakan pemerintah, tokoh politik, dan isu sosial (Krisdiyanto et al., 2021; Mola et al., 2024; Siagian & Painem, 2024).

Sejumlah penelitian menunjukkan bahwa algoritma *Support Vector Machine* (SVM) dan Naïve Bayes merupakan algoritma yang sering digunakan dan cukup efektif untuk tugas klasifikasi teks, terutama pada data media sosial yang bersifat pendek dan tidak terstruktur. Penelitian (Saputra et al., 2025) menunjukkan bahwa SVM memiliki akurasi tinggi setelah melalui tahapan praproses dan ekstraksi fitur. Studi lainnya, termasuk penelitian pada komentar YouTube juga menemukan bahwa SVM sedikit lebih unggul daripada Naïve Bayes dalam akurasi (Saputra et al., 2025). Secara teknis, SVM bekerja dengan mencari *hyperplane* terbaik untuk memisahkan kelas, sementara Naïve Bayes mengandalkan pendekatan probabilistik dengan asumsi independensi antar fitur. Dalam konteks bahasa natural, terutama komentar publik yang sering ambigu dan bersifat netral, SVM umumnya memberikan hasil yang lebih stabil.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menganalisis sentimen masyarakat terhadap pengangkatan Purbaya Yudhi Sadewa sebagai Menteri Keuangan melalui komentar YouTube, serta membandingkan performa algoritma SVM dan Naïve Bayes. Penelitian ini diharapkan dapat memberikan gambaran objektif terkait persepsi awal publik pada masa transisi kepemimpinan di bidang keuangan, sekaligus memberikan kontribusi ilmiah dalam pengembangan metode *machine learning* untuk analisis opini publik di era digital.

METODE PENELITIAN

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja algoritma *Support Vector Machine* (SVM) dan Naïve Bayes dalam proses klasifikasi sentimen pada komentar YouTube yang membahas pengangkatan serta rapat perdana Menteri Keuangan Purbaya Yudhi Sadewa, dengan fokus pada video Rapat Perdana Bersama Komisi XI DPR RI yang dipublikasikan melalui kanal YouTube KOMPASTV. Data dikumpulkan melalui proses *web scraping* menggunakan bahasa pemrograman Python. Sebanyak 6.122 komentar berhasil

diperoleh sebelum melalui tahap *preprocessing*.

Alur penelitian terdiri dari beberapa tahapan utama, yaitu pengumpulan data, *preprocessing* teks, pelabelan sentimen, pembagian dataset menjadi data latih dan data uji, pelatihan model menggunakan algoritma SVM dan Naïve Bayes, serta evaluasi performa model. Setiap tahapan dirancang untuk memastikan bahwa data bersih, terstandardisasi, dan siap untuk proses klasifikasi sehingga model yang dibangun mampu memberikan hasil analisis sentimen yang akurat dan reliabel.

A. Pengumpulan Data

Tahap pengumpulan data dilakukan melalui metode *web scraping* menggunakan YouTube Data API v3 dengan bantuan *library* Python seperti *googleapiclient* untuk mengekstraksi komentar *top-level* maupun balasan secara otomatis. Pendekatan ini sejalan dengan penelitian terbaru yang memanfaatkan teknik *scraping* untuk mengumpulkan komentar YouTube dalam skala besar (Irlon, 2025). Seluruh komentar yang berhasil dikumpulkan berjumlah 6.122 komentar dan masih berupa data mentah yang mengandung berbagai noise seperti emoji, URL, tanda baca, kata tidak baku, serta karakter khusus. Pada tahap ini data masih berupa komentar umum, belum difilter khusus mengenai Purbaya. Oleh karena itu, diperlukan proses *preprocessing* agar data siap digunakan pada tahap pelabelan dan pemodelan sentimen berikutnya.

B. *Preprocessing Data*

Tahap *preprocessing* dilakukan untuk menyiapkan data teks sebelum dianalisis lebih lanjut pada proses klasifikasi sentimen. Komentar YouTube yang terkumpul masih berupa data mentah yang mengandung berbagai bentuk *noise* seperti emotikon, URL, tanda baca, singkatan, dan kata tidak baku, sehingga diperlukan sejumlah tahap pembersihan dan transformasi. Tahap pertama adalah *cleaning data*, yaitu menghapus elemen-elemen yang tidak relevan seperti angka, tautan, karakter khusus, dan emotikon agar teks lebih terfokus pada konten utama. Langkah ini umum digunakan pada pengolahan data media sosial (Setiawan, 2024). Selanjutnya dilakukan *case folding*, yaitu mengubah seluruh teks menjadi huruf kecil untuk menyamakan bentuk kata dan menghindari perbedaan kapitalisasi.

Tahap berikutnya adalah *tokenizing*, di mana teks dipecah menjadi token kata sehingga dapat dianalisis sebagai satuan fitur (Kannan, 2014). Proses normalisasi kemudian diterapkan untuk mengubah kata tidak baku atau slang menjadi bentuk standar menggunakan kamus kosakata informal. Langkah ini sangat penting karena komentar pada media sosial, termasuk YouTube, cenderung menggunakan bahasa gaul dan singkatan. Penelitian (Ardinata et al., 2024) menunjukkan bahwa normalisasi slang berbasis kamus dan model *fastText* dapat secara signifikan meningkatkan kualitas pemrosesan teks, terutama untuk tugas analisis sentimen pada data berbahasa Indonesia.

Setelah itu, dilakukan *stopword removal* untuk menghapus kata-kata umum yang tidak memiliki kontribusi besar terhadap penentuan sentimen, seperti “yang”, “dan”, atau “jadi”, sehingga hasil analisis menjadi lebih fokus (Pradana & Hayaty, 2019). Tahap terakhir adalah *stemming*, yaitu mengubah kata berimbuhan ke bentuk dasarnya menggunakan stemmer Bahasa Indonesia, sehingga representasi teks menjadi lebih konsisten dan akurat untuk proses pembobotan fitur dan klasifikasi. Setelah proses *preprocessing* selesai, barulah dilakukan *filtering* berdasarkan kata kunci yang relevan dengan topik penelitian, seperti “Purbaya”, “Pak Purbaya”, “Menkeu Purbaya”, atau penyebutan terkait lainnya. Hanya komentar yang relevan setelah proses *filtering* inilah yang digunakan sebagai dataset untuk pelabelan dan pemodelan berikutnya.

C. Pelabelan Data

Tahap pelabelan data dilakukan untuk memberikan kategori sentimen pada setiap komentar, yaitu positif, negatif, atau netral, sehingga data siap digunakan sebagai dataset terstruktur untuk proses pelatihan model klasifikasi. Pada penelitian ini, proses pelabelan dilakukan secara manual oleh peneliti, mengingat bahasa komentar YouTube sering kali mengandung konteks implisit, sarkasme, atau penggunaan bahasa informal yang sulit ditangani secara otomatis. Pelabelan manual juga memberikan kontrol yang lebih baik terhadap konteks dan makna kalimat, terutama pada komentar politik dan kinerja pejabat publik yang rentan multitafsir. Pendekatan ini sejalan dengan praktik umum dalam penelitian analisis sentimen berbahasa Indonesia, di mana akurasi label sangat dipengaruhi oleh pemahaman manusia terhadap konteks sosial dan linguistik (Purnamasari et al., 2023). Untuk menjaga konsistensi, peneliti melakukan pengecekan ulang (*double-checking*) pada label yang diberikan sehingga mengurangi subjektivitas dan memastikan dataset siap untuk proses pembagian data dan pelatihan model.

D. Pembagian Dataset

Dataset yang telah diberi label kemudian dibagi menjadi dua bagian, yaitu data latih dan data uji dengan rasio 80:20 sebagaimana digunakan pada penelitian sebelumnya (Santoso et al., 2025). Pembagian dilakukan secara acak agar distribusi tiap kelas sentimen tetap seimbang. Tujuan dari proses ini adalah memastikan bahwa model dapat dilatih secara optimal dan dievaluasi secara objektif menggunakan data yang tidak pernah dilihat sebelumnya.

E. Pelatihan Model

Pada tahap pelatihan, data teks yang sudah dipreproses diubah menjadi representasi numerik menggunakan metode TF-IDF. Selanjutnya dua algoritma digunakan, yaitu *Support Vector Machine* (SVM) dan Naïve Bayes. Model dilatih menggunakan data latih untuk mempelajari pola sentimen dalam komentar, kemudian siap dievaluasi pada data uji untuk mengetahui performanya.

F. Evaluasi Model

Tahap evaluasi dilakukan untuk menilai performa algoritma *Support Vector Machine* (SVM) dan Naïve Bayes dalam mengklasifikasikan sentimen komentar. Proses evaluasi menggunakan data uji yang telah dipisahkan sebelumnya. Beberapa metrik utama digunakan, yaitu *accuracy*, *precision*, *recall*, dan *f1-score*, yang merupakan standar umum dalam penilaian performa model klasifikasi karena mampu menggambarkan ketepatan dan kelengkapan prediksi model (Manning et al., 2009). Selain itu, *confusion matrix* digunakan untuk melihat distribusi prediksi pada masing-masing kelas sentimen, sehingga memudahkan identifikasi pola kesalahan model.

HASIL DAN PEMBAHASAN

A. Deskripsi Dataset

Dataset awal yang digunakan dalam penelitian ini terdiri atas 6.122 komentar YouTube yang diperoleh dari video Rapat Perdana Bersama Komisi XI DPR RI di kanal KOMPASTV. Seluruh komentar dikumpulkan melalui proses *web scraping* menggunakan YouTube Data API v3.

Namun, tidak semua komentar dapat langsung digunakan. Melalui tahapan *preprocessing* dan *filtering*, komentar yang mengandung spam, duplikasi, hanya emotikon, atau tidak relevan dengan konteks penelitian dihapus. Setelah proses penyaringan tersebut, jumlah komentar yang layak digunakan sebagai dataset analisis sentimen menjadi 1.202 komentar. Dataset inilah yang selanjutnya digunakan dalam proses pelabelan, pembagian data, dan pelatihan model.

B. *Preprocessing Data*

Tahap preprocessing dilakukan untuk mengubah komentar mentah menjadi data yang siap

dianalisis. Proses ini mencakup beberapa langkah, yaitu *cleaning*, *case folding*, tokenisasi, normalisasi, penghapusan *stopword*, dan *stemming*. Melalui tahapan ini, teks komentar yang awalnya mengandung tanda baca, emotikon, singkatan, serta kata tidak baku dikonversi menjadi bentuk yang lebih sederhana dan konsisten.

Tabel 1. *Preprocessing Data*

Data Komentar	clean_comment	tokens	normalized_tokens	clean_tokens	stemmed_tokens
â ¤		[]	[]	[]	[]
sekarang airel dilan	sekarang airel dilan	['sekarang', 'airel', 'dilan']	['sekarang', 'airel', 'dilan']	['airel', 'dilan']	['airel', 'dil']
Pinter pa Purbayaaa , jln terus mayrakat dukung	pinter pa purbayaaa jln terus mayrakat dukung	['pinter', 'pa', 'purbayaaa', 'jln', 'terus', 'mayrakat', 'dukung']	['pinter', 'pa', 'purbayaaa', 'jln', 'terus', 'mayrakat', 'dukung']	['pinter', 'pak', 'purbayaaa', 'jalan', 'masyarakat', 'dukung']	['pinter', 'pak', 'purbayaaa', 'jalan', 'masyarakat', 'dukung']
Sangat setuju	sangat setuju	['sangat', 'setuju']	['sangat', 'setuju']	['setuju']	['tuju']
Jangan mau diajak korupsi	jangan mau diajak korupsi	['jangan', 'mau', 'diajak', 'korupsi']	['jangan', 'mau', 'diajak', 'korupsi']	['diajak', 'korupsi']	['ajak', 'korupsi']
Dpr disekolahi pk purbaya	dpr disekolahi pk purbaya	['dpr', 'disekolahi', 'pk', 'purbaya']	['dpr', 'disekolahi', 'pak', 'purbaya']	['dpr', 'disekolahi', 'pak', 'purbaya']	['dpr', 'sekolah', 'pak', 'purbaya']
Bongkar klu Benar Rakyat Mendukung pastiâ ¤â ¤	bongkar klu benar rakyat mendukung pasti	['bongkar', 'klu', 'benar', 'rakyat', 'mendukung', 'pasti']	['bongkar', 'kalau', 'benar', 'rakyat', 'mendukung', 'pasti']	['bongkar', 'rakyat', 'mendukung']	['bongkar', 'rakyat', 'dukung']

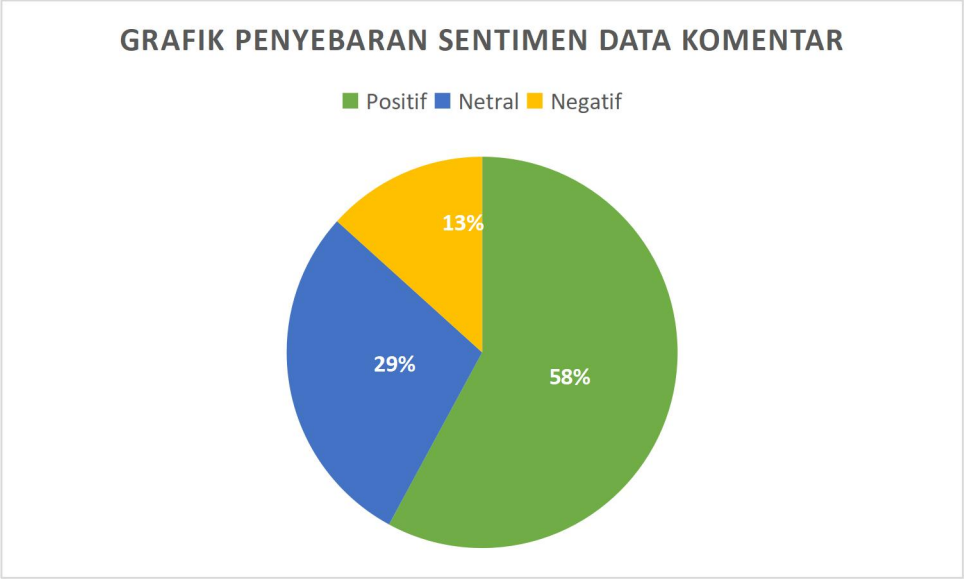
Tabel tersebut menampilkan contoh perubahan teks dari bentuk awal hingga menjadi token akhir. Dari hasil yang ditunjukkan, terlihat bagaimana setiap komentar mengalami transformasi bertahap sehingga menghasilkan representasi kata dasar yang lebih informatif dan siap digunakan oleh algoritma klasifikasi.

Setelah seluruh proses *preprocessing* diterapkan, jumlah data mengalami penyusutan dari 6.122 komentar menjadi 1.202 komentar yang relevan. Data inilah yang kemudian digunakan pada tahap analisis dan pelatihan model selanjutnya.

C. Pelabelan Sentimen

Tahap pelabelan sentimen dilakukan secara manual untuk memastikan bahwa setiap komentar diklasifikasikan sesuai dengan konteks dan makna sebenarnya. Proses ini membagi komentar ke dalam tiga kategori, yaitu positif, netral, dan negatif. Pelabelan manual dipilih karena mampu memberikan hasil yang lebih akurat dibandingkan pelabelan otomatis, terutama

pada komentar YouTube yang banyak mengandung bahasa informal, sarkasme, dan variasi gaya penulisan.



Gambar 1. Grafik Penyebaran Sentimen

Hasil pelabelan ditunjukkan pada grafik penyebaran sentimen. Dari total 1.202 komentar yang telah melalui tahap *preprocessing*, diperoleh distribusi sebagai berikut: 696 komentar (58%) termasuk kategori positif, 346 komentar (29%) termasuk kategori netral, dan 160 komentar (13%) termasuk kategori negatif. Dominasi komentar positif menunjukkan bahwa sebagian besar pengguna memberikan tanggapan yang mendukung atau bernada optimistis terhadap isi video terkait.

Grafik ini memberikan gambaran awal mengenai kecenderungan opini publik sebelum dilakukan proses pelatihan model, sekaligus memastikan bahwa dataset memiliki variasi kelas yang cukup untuk kebutuhan analisis sentimen selanjutnya.

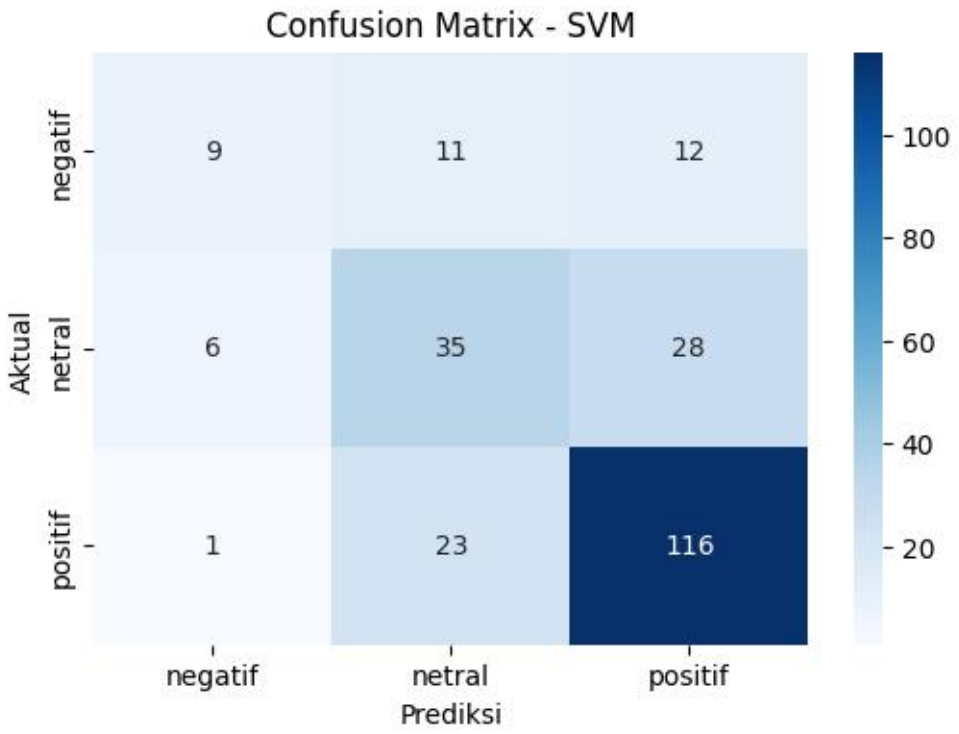
D. Pembagian *Data Training* dan *Testing*

Dataset kemudian dibagi menjadi 80% data latih dan 20% data uji. Dari total 1.202 data, sebanyak 961 data digunakan sebagai *data training*, sementara 241 data digunakan sebagai *data testing*. Pembagian dengan proporsi 80/20 ini dipilih karena dapat memberikan jumlah data latih yang cukup besar untuk membangun model yang stabil, sekaligus menyediakan data uji yang memadai untuk mengevaluasi performa model secara objektif dan representatif.

E. Hasil Eksperimen Model Algoritma *Support Vector Machine*

Confusion matrix

Setelah dilakukan pelatihan dan pengujian menggunakan algoritma *Support Vector Machine*, Berikut merupakan visualisasi *confusion matrix* hasil prediksi model:



Gambar 2. *Confusion Matrix* SVM

Berdasarkan Gambar 2, model masih kurang optimal dalam mengenali komentar negatif. Dari total 32 data pada kelas ini, hanya 9 komentar yang dapat diklasifikasikan dengan benar, sedangkan 11 komentar terprediksi sebagai netral dan 12 komentar lainnya salah dikenali sebagai positif. Pada kelas netral, model berhasil mengidentifikasi 35 komentar dengan benar, namun terjadi kesalahan berupa 6 komentar netral yang diklasifikasikan sebagai negatif dan 28 komentar yang terdeteksi sebagai positif. Sementara itu, performa terbaik ditunjukkan pada kelas positif, dengan 116 komentar berhasil diprediksi secara tepat. Meski demikian, masih terdapat kesalahan klasifikasi berupa 23 komentar positif yang terdeteksi sebagai netral dan 1 komentar yang salah diprediksi sebagai negatif.

Classification Report

Evaluasi performa model secara kuantitatif ditunjukkan melalui classification report berikut:

Tabel 1. *Classification Report* Algoritma SVM

	precision	***recall***	***f1-score***	***support***
negatif	0.56	0.28	0.38	32
netral	0.51	0.51	0.51	69
positif	0.74	0.83	0.78	140
accuracy			0.66	241
macro avg	0.60	0.54	0.56	241
weighted avg	0.65	0.66	0.65	241

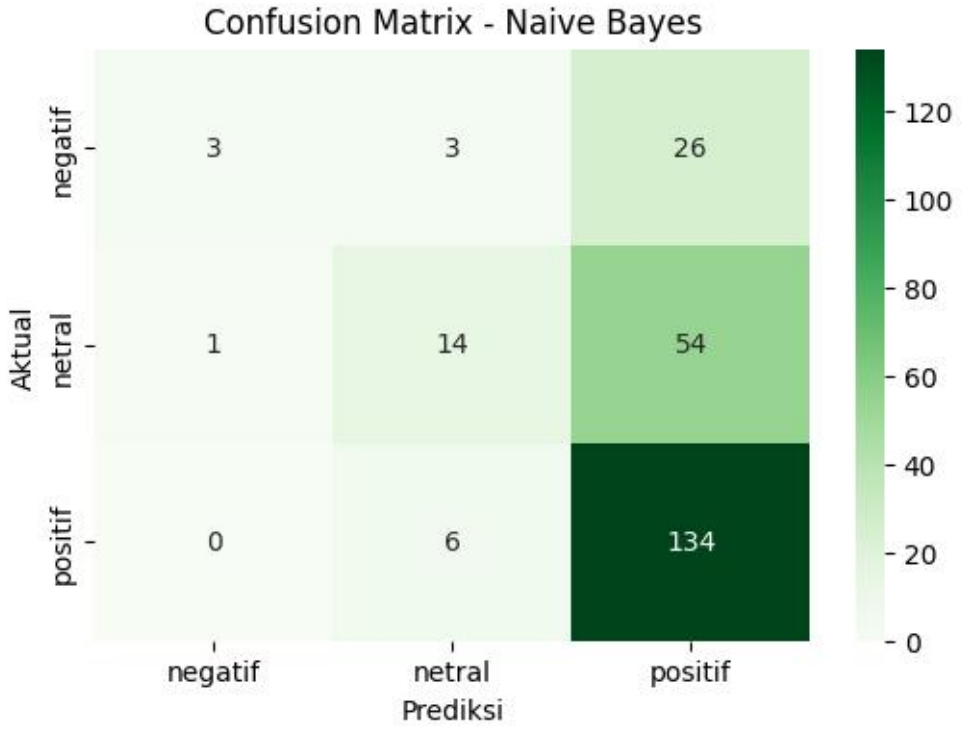
Berdasarkan nilai tersebut, terlihat bahwa kelas positif memiliki performa tertinggi, terutama pada nilai *recall* sebesar 0.83, yang menunjukkan bahwa sebagian besar komentar positif berhasil dikenali oleh model. Sebaliknya, performa terendah terjadi pada kelas negatif dengan nilai *recall* 0.28, yang menandakan banyaknya komentar negatif yang gagal dikenali

dengan benar. Nilai *f1-score* untuk kelas ini juga relatif rendah, yaitu 0.38, sehingga mengindikasikan bahwa model belum mampu menangkap karakteristik unik dari komentar negatif secara konsisten.

Secara keseluruhan, model memperoleh akurasi sebesar 66%, dengan nilai *macro average f1-score* 0.56 dan *weighted average f1-score* 0.65. Nilai *macro average* yang lebih rendah menunjukkan bahwa performa antar kelas masih belum seimbang, terutama dipengaruhi oleh rendahnya hasil pada kelas negatif. Hal ini dapat disebabkan oleh kemiripan kata antara komentar bernuansa negatif dan netral, sehingga model mengalami kesulitan membedakan konteks kedua kategori tersebut.

F. Hasil Eksperimen Model Algoritma Naïve Bayes

Confusion Matrix



Gambar 3. *Confusion Matrix* Algoritma Naïve Bayes

Berdasarkan *confusion matrix* pada Gambar 3, dapat diamati bahwa performa model Naïve Bayes menunjukkan kecenderungan yang kurang optimal dalam mengenali komentar negatif dan netral, namun memberikan performa yang sangat baik pada kelas positif. Pada kelas negatif, hanya 3 komentar yang berhasil diklasifikasikan dengan benar, sementara 3 komentar negatif diklasifikasikan sebagai netral dan 26 komentar lainnya salah diprediksi sebagai positif. Pada kelas netral, model berhasil mengenali 14 komentar secara tepat, namun masih terdapat kesalahan prediksi berupa 1 komentar netral yang terdeteksi sebagai negatif dan 54 komentar lainnya salah diklasifikasikan sebagai positif. Pencapaian terbaik ditunjukkan pada kelas positif, dimana model mampu memprediksi 134 komentar positif dengan benar. Akan tetapi, terdapat kesalahan berupa 6 komentar positif yang terdeteksi sebagai netral, meskipun tidak ada satupun komentar positif yang salah diklasifikasikan sebagai negatif.

Classification Report

Tabel 2. *Classification Report* Algoritma Naïve Bayes

	precision	*recall*	*f1-score*	*support*
negatif	0.75	0.09	0.17	32
netral	0.61	0.20	0.30	69
positif	0.63	0.96	0.76	140
accuracy			0.63	241
macro avg	0.66	0.42	0.41	241
weighted avg	0.64	0.63	0.55	241

Berdasarkan hasil classification report, model Naïve Bayes menunjukkan performa terbaik pada kelas positif, dengan nilai *recall* 0.96 dan *f1-score* 0.76, yang menandakan bahwa sebagian besar komentar positif berhasil dikenali dengan benar. Namun, performa pada kelas netral masih rendah dengan *f1-score* 0.30, menunjukkan bahwa model sering keliru membedakan komentar netral dari kelas lain. Kelas negatif menjadi kategori dengan performa terlemah, ditunjukkan oleh nilai *recall* yang sangat rendah sebesar 0.09 dan *f1-score* 0.17, sehingga mengindikasikan bahwa model belum mampu menangkap pola khas dalam komentar negatif.

Secara keseluruhan, Naïve Bayes memperoleh akurasi 63%, dengan *macro average f1-score* sebesar 0.41 dan *weighted average f1-score* 0.55. Nilai *macro average* yang rendah menunjukkan bahwa performa model tidak merata antar kelas, terutama dipengaruhi oleh buruknya hasil pada kelas negatif dan netral. Hal ini menunjukkan bahwa model cenderung lebih efektif dalam memproses komentar positif, namun belum mampu mengklasifikasikan komentar bernuansa negatif dan netral secara konsisten.

G. Diskusi dan Perbandingan Antara Algoritma *Support Vector Machine* dan Naïve Bayes

Berdasarkan hasil evaluasi, algoritma Naïve Bayes menunjukkan performa yang kurang optimal dengan akurasi 62,66%, *precision* 66,16%, *recall* 41,79%, dan *f1-score* 40,94%. Nilai *recall* dan *f1-score* yang rendah terutama pada kelas negatif dan netral menunjukkan bahwa model ini kesulitan mengenali komentar dengan nada ambigu atau bersifat umum. Pada konteks video yang berisi rapat perdana pengangkatan Purbaya Yudhi Sadewa sebagai Menteri Keuangan, sebagian besar komentar bersifat positif atau hanya memberikan observasi awal, bukan evaluasi yang mendalam. Distribusi kata pada komentar seperti ini cenderung mirip antar kelas, sehingga asumsi independensi fitur yang digunakan Naïve Bayes tidak terpenuhi. Akibatnya, model sering salah mengklasifikasikan komentar yang bernada halus, tidak eksplisit, atau berada di antara dua sentimen.

Sebaliknya, algoritma *Support Vector Machine* (SVM) menunjukkan performa yang lebih stabil dengan akurasi 66,39%, *precision* 60,44%, *recall* 53,90%, dan *f1-score* 55,53%. Walaupun selisih akurasi dengan Naïve Bayes tidak terlalu besar, SVM lebih mampu menjaga keseimbangan prediksi antar kelas. SVM bekerja dengan mencari hyperplane terbaik sehingga lebih efektif menangani variasi pola bahasa yang muncul dalam komentar public terutama pada situasi awal seperti pengangkatan pejabat baru, di mana opini masyarakat masih beragam, cenderung positif, dan belum sepenuhnya menggambarkan penilaian kinerja. Dengan kemampuan tersebut, SVM lebih mampu membedakan perbedaan konteks yang halus serta menangkap struktur kalimat yang tidak selalu eksplisit. Hal ini menjadikan SVM algoritma yang lebih sesuai untuk menganalisis sentimen pada komentar warganet dalam konteks isu politik dan pemerintahan yang bernada diplomatis atau kehati-hatian.

Tabel 3. Perbandingan Performa Naïve Bayes dan SVM

Metric	Naïve Bayes	SVM
Accuracy	62.66%	66.39%
Precision	66.16%	60.44%
Recall	41.79%	53.90%
F1-score	40.94%	55.53%

Tabel 4. Hasil *10-fold cross validation*

Fold	Naïve Bayes (%)	SVM (%)
Fold 1	62.81	67.77
Fold 2	56.20	61.98
Fold 3	56.67	61.67
Fold 4	54.17	65.00
Fold 5	67.50	68.33
Fold 6	68.33	73.33
Fold 7	62.50	60.83
Fold 8	61.67	64.17
Fold 9	56.67	55.83
Fold 10	62.50	63.33

Hasil uji *10-fold cross validation* juga mengonfirmasi konsistensi performa kedua algoritma. Nilai akurasi Naïve Bayes menunjukkan fluktuasi cukup besar, yaitu antara 54,17% hingga 68,33%, menandakan sensitivitas terhadap perubahan distribusi data pada tiap *fold*. Sementara itu, SVM memiliki rentang performa yang lebih stabil, yaitu 55,83% hingga 73,33%, dan sebagian besar *fold* menunjukkan akurasi lebih tinggi dibandingkan *Naïve Bayes*. Konsistensi ini memperkuat temuan bahwa SVM lebih adaptif terhadap karakteristik bahasa komentar YouTube yang beragam dan dinamis. Oleh karena itu, SVM dapat dianggap sebagai algoritma yang lebih sesuai untuk menganalisis sentimen publik terhadap isu pengangkatan Menteri Keuangan baru, sedangkan Naïve Bayes kurang efektif karena batasan asumsi model yang tidak sesuai dengan pola bahasa dalam komentar warganet.

KESIMPULAN

Berdasarkan hasil analisis sentimen terhadap 1.202 komentar YouTube mengenai pengangkatan Purbaya Yudhi Sadewa sebagai Menteri Keuangan, diperoleh distribusi sentimen yang didominasi oleh komentar positif (58%), disusul komentar netral (29%) dan negatif (13%). Temuan ini menunjukkan bahwa mayoritas warganet memberikan tanggapan yang mendukung, optimistis, atau setidaknya menilai secara baik langkah awal dan sosok Purbaya pada rapat perdana tersebut. Dari sisi performa model, algoritma *Support Vector Machine* (SVM) menunjukkan hasil yang lebih unggul dengan akurasi 66,39% dan *f1-score* 55,53%, dibandingkan Naïve Bayes yang memperoleh akurasi 62,66% dan *f1-score* 40,94%. Hasil *10-fold cross validation* juga mengonfirmasi bahwa SVM lebih stabil dan konsisten dibandingkan *Naïve Bayes*.

Dengan demikian, SVM dapat dinyatakan sebagai algoritma yang lebih sesuai untuk mengolah pola bahasa pada komentar publik dalam konteks isu politik dan pemerintahan.

Penelitian ini memiliki beberapa keterbatasan. Pertama, dominasi komentar positif menyebabkan distribusi label tidak seimbang, terutama pada kelas negatif yang jumlahnya relatif sedikit. Ketidakseimbangan ini memengaruhi performa model, khususnya *Naïve Bayes*, yang menunjukkan kesulitan dalam mengenali kelas minoritas. Kedua, penelitian ini hanya menggunakan pendekatan ekstraksi fitur TF-IDF, tanpa membandingkan dengan teknik representasi teks lain seperti Word2Vec atau BERT yang berpotensi menangkap konteks kalimat secara lebih mendalam. Selain itu, data dikumpulkan dari satu video dalam satu periode waktu, sehingga persepsi publik yang lebih luas dan dinamis belum sepenuhnya terwakili.

Sebagai rekomendasi, penelitian selanjutnya dapat memperluas pengambilan data dari berbagai video dan periode waktu untuk mendapatkan gambaran opini publik yang lebih komprehensif terhadap kinerja Purbaya Yudhi Sadewa setelah menjabat. Teknik penyeimbangan data seperti SMOTE atau *class weighting* juga dapat diterapkan untuk meningkatkan kualitas model, khususnya dalam mendeteksi sentimen negatif yang jumlahnya sedikit. Selain itu, disarankan untuk mengeksplorasi model berbasis *deep learning* atau *embedding modern* seperti FastText, Word2Vec, atau BERT untuk meningkatkan tingkat akurasi dan pemahaman konteks pada analisis sentimen.

DAFTAR REFERENSI

Ardinata, P. M. S., Permana, A. A. J., & Wijaya, I. N. S. W. (2024). *IDENTIFIKASI DAN NORMALISASI TEKS SLANG DENGAN FASTTEXT PADA TWITTER DALAM BAHASA INDONESIA*. *21*(1).

Binekasri, R. (2024). Dana Nasabah Aman, 99,94% Rekening di Bank Dijamin LPS. *CNBC Indonesia*. https://www.cnbcindonesia.com/market/20240802115442-17-559874/dana-nasabah-aman-9994-rekening-di-bank-dijamin-lps

Gayati, M. D. (2025, September). Gantikan Sri Mulyani, Prabowo lantik Purbaya Yudhi Sadewa jadi Menkeu. *ANTARA*. https://www.antaranews.com/berita/5093749/gantikan-sri-mulyani-prabowo-lantik-purbaya-yudhi-sadewa-jadi-menkeu?utm_source=chatgpt.com

Irlon. (2025). *ANALISIS PERBANDINGAN ALGORITMA NAÏVE BAYES SVM DAN RANDOM FOREST PADA KLASIFIKASI SENTIMEN KOMENTAR YOUTUBE " CLASH OF CHAMPIONS " RUANGGURU*. *19*(2).

Juleha, J., Yuniar, J., & Marsuki, N. R. (2024). Peran Media Sosial Dalam Dinamika Opini Publik dan Partisipasi Politik Era Digital Universitas Muhammadiyah Makassar , Indonesia. *Concept: Journal of Social Humanities and Education*, *3*(1), 38–45.

Kannan, S. (2014). *Preprocessing Techniques for Text Mining*.

Krisdiyanto, T., Maricha, E., & Nurharyanto, O. (2021). *Analisis Sentimen Opini Masyarakat Indonesia Terhadap Kebijakan PPKM pada Media Sosial Twitter Menggunakan Naïve Bayes Clasifiers*. *7*(1), 32–37.

Lestari, S., & Berliani, S. (2024). Analisis Sentimen Masyarakat Terhadap Isu Pecat Sri Mulyani Pada Twitter Menggunakan Metode Naive Bayes Dan Support Vector Machine. *Jurnal Sains Dan Teknologi*, *5*(3), 2024. https://doi.org/10.55338/saintek.v5i1.2789

Manning, C. D., Raghavan, P., & Schutze, H. (2009). *An Introduction To Information Retrieval* (Issue c). Cambrige University Press.

Maulani, G., Hariyono, R. C. S., Tania, K. D., & Purbaya, M. E. (2024). *Penerapan Data Mining Di Berbagai Bidang* (A. Wisandra (ed.); 1st ed.). CV Hei Publishing Indonesia.

https://repository.bsi.ac.id/repo/files/443997/download/Buku-_-Penerapan-Data-Mining-di-Berbagai-Bidang.pdf

Mola, S. A. S., Lete, P. R., Triyanto, Junio, B. J. A., & Tiwuk. (2024). *Analisis sentimen menggunakan metode naive bayes dan metode support vector machine pada kasus pelantikan artis sebagai anggota anggota dpr ri tahun 2024*. *15*(c), 22–32.

Pradana, A. W., & Hayaty, M. (2019). *The effect of stemming and removal of stopwords on the accuracy of sentiment analysis on indonesian-language texts*. *4*(3).

Pratiwi, F. S., & Suhendra. (2024). Peran Komunikasi Digital dalam Pembentukan Opini Publik : Studi Kasus Media Sosial. *Iapa Proceedings Conference*, 293–315.

Purnamasari, D., Aji, A. B., Wulandari, D., & Reza, F. A. (2023). *Pengantar Metode Analisis Sentimen* (I. M. Wiryana (ed.); 1st ed.). Penerbit Gunadarma. https://penerbit.gunadarma.ac.id/wp-content/uploads/2023/09/Pengantar-Metode-Analisis-Sentimen_Detty-cs_Watermark.pdf

Santoso, B. A., Nugroho, B. I., & Asyfiya, D. U. (2025). *Perbandingan Algoritma Naïve Bayes, Support Vector Machine, dan Random Forest Untuk Analisis Sentimen Komentar Politik Youtube Bayu*. *6*(4), 391–400. https://doi.org/10.47065/tin.v6i4.8326

Saputra, J., Maryani, L., Wulandari, D., Eka, W., Informatika, P. T., & Komputer, P. T. (2025). *Analisis Performa Naive Bayes dan SVM terhadap Sentimen Teks Media Sosial dengan Word2Vec dan SMOTE*. *10*(1), 143–155.

Setiawan, B. (2024). *A Review of Sentiment Analysis Applications in Indonesia Between 2023-2024*. *08*, 71–83.

Siagian, J. K., & Painem. (2024). *ANALISIS SENTIMEN MASYARAKAT INDONESIA TERHADAP RENCANA KENAIKAN PPN MENJADI 12 % DI MEDIA SOSIAL X ANALYSIS OF INDONESIAN PUBLIC SENTIMENT TOWARDS THE PLAN TO INCREASE VAT TO 12 % ON X SOCIAL MEDIA USING THE NAÏVE BAYES METHOD*. *3*(September), 779–786.