e-ISSN 2828-0490
JURNAL MEDIA COMPUTER SCIENCE

Deep Learning-based Sentiment Analysis of Public Comments on Military Education Using RoBERTa Algorithm and Rule-Based Hybird Parameters

Jose Julian Hidayat [1)], Cindy Setyowati [2)]; Muhammad Dikaisa Ibnu Amin [3)]; Khodir Bimasakti[4]; Aditya Pratama Werdana[5]

[1,2,3,4,5)] *Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Cikarang Selatan, Bekasi, Indonesia.*

Email: [1*)] josejulianhidayat@gmail.com ; [2)] cindyssetyo@gmail.com ; [3)] dikaaisaa@gmail.com ; khodirbimasakti@gmail.com ; [5)] adityawerdana5@gmail.com

How to Cite :

Hidayat. J. J., Setyowati. C., Amin. M. D. I., Bimasakti. K., Werdana. A.P. (2025). Deep Learning-based Sentiment Analysis of Public Comments on Military Education Using RoBERTa Algorithm and Rule-Based Hybird Parameters. Jurnal Media Computer Science,4(2) Doi: https://doi.org/10.37676/jmcs.v4i2

ARTICLE HISTORY

Received [16 Juni 2025]
Revised [07 Juli 2025]
Accepted [10 Juli 2025]

KEYWORDS

Deep Learning, Military Education, RoBERTa Algorithm, Sentiment Analysis, Social Media

This is an open access article under the CC–BY-SA license

ABSTRAK

Media sosial seperti Instagram telah menjadi ruang publik digital penting bagi masyarakat untuk menyuarakan pendapat tentang berbagai masalah kebijakan, termasuk kebijakan pendidikan militer, yang belakangan ini menjadi sangat diperdebatkan, khususnya di Jawa Barat dan bahkan di luar Pulau Jawa. Tujuan dari penelitian ini adalah untuk mengembangkan model analisis sentimen terhadap komentar publik di Instagram mengenai kebijakan pendidikan militermenggunakan pendekatan deep learning model RoBERTa dilatih dan diuji menggunakan metrik performa klasifikasi seperti akurasi, precision, recall, dan f1-score. Hasil pengujian menunjukkan bahwa model berhasil mencapai akurasi sebesar 97%, dengan nilai f1-score tertinggi pada kategori positif sebesar 0,98. Hasilnya menunjukkan bahwa RoBERTa dapat dengan efektif mengklasifikasikan sentimen berdasarkan opini masyarakat di media sosial. Metode ini tidak hanya dapat memberikan gambaran umum tentang respons publik, tetapi juga dapat digunakan sebagai alat bantu dalam proses pengambilan keputusan atau evaluasi kebijakan publik yang didasarkan pada analisis opini digital yang terjadi secara real-time.

ABSTRACT

Social media such as Instagram has become an important digital public space for people to voice opinions on various policy issues, including the military education policy, which has recently become highly debated, especially in West Java and even outside Java. The purpose of this research is to develop a sentiment analysis model for public comments on Instagram regarding military education policy using a deep learning approach. m The RoBERTa model was trained and tested using classification performance metrics such as accuracy, precision, recall, and f1-score. The test results show that the model achieved an accuracy of 97%, with the highest f1-score value in the positive category at 0.98. The results show that RoBERTa can effectively classify sentiment based on public opinion on social media. This method can not only provide an overview of public responses, but can also be used as a tool in the decision-making process or public policy evaluation based on real-time digital opinion analysis.

PENDAHULUAN

Dengan berkembangnya teknologi digital, media sosial telah menjadi tempat yang strategis untuk berbicara dengan publik tentang berbagai masalah kebijakan. Instagram, salah satu *platform* paling populer di Indonesia, telah berkembang dari *platform* berbagi foto yang sederhana menjadi *platform* yang sangat dinamis untuk berinteraksi dengan Masyarakat (Irwanda et al., 2024). Komentar yang dibuat dalam unggahan tentang masalah sosial dan politik sering kali menunjukkan sikap masyarakat yang berbeda, baik dengan dukungan, kritik, atau sarkasme. Kebijakan pendidikan militer yang diusulkan oleh tokoh politik asal Jawa Barat, Dedi Mulyadi, adalah salah satu masalah yang memicu banyak tanggapan publik. Rekomendasi bahwa siswa harus mendapatkan pendidikan militer untuk menanamkan nasionalisme dan disiplin menjadi topik pembicaraan publik. Meskipun ada beberapa orang yang mendukung metode tersebut, ada juga yang mempertanyakan kegunaannya dan efek psikologisnya dalam pendidikan kontemporer.

Komentar warganet tentang masalah ini membanjiri banyak unggahan di Instagram yang tersebar di seluruh Indonesia, bukan hanya di Jawa Barat. Dengan fenomena ini, ada kesempatan untuk menganalisis persepsi publik secara menyeluruh dengan menggunakan metode analisis sentimen. Namun demikian, melakukan pemeriksaan manual terhadap ribuan komentar publik sangat tidak efektif dan berpotensi menghasilkan interpretasi yang salah. Penggunaan bahasa informal, slang, singkatan, dan nada ironi yang sering muncul di media sosial memperumit pemahaman teks. Oleh karena itu, untuk mengidentifikasi pola sentimen secara akurat dan dalam skala besar, metode komputasional berbasis kecerdasan buatan (*AI*) diperlukan.

Analisis sentimen adalah komponen pemrosesan bahasa alami (*NLP*) yang bertujuan untuk membagi sikap atau pendapat pengguna ke dalam kategori seperti *positive*, *neutral*, atau *negative* (Nurrochmah et al., n.d.). Pendekatan *deep learning* telah menjadi pilihan utama dalam proses pengolahan bahasa dalam beberapa tahun terakhir. Hal ini disebabkan fakta bahwa, dibandingkan dengan metode konvensional seperti *Naive Bayes* atau *SVM*, metode ini memiliki kemampuan untuk memahami konteks kalimat dan relasi antar kata secara lebih mendalam. *RoBERTa (Robustly Optimized BERT Pretraining Approach*) adalah pengembangan dari model *BERT* yang menghilangkan *embedding segment*, meningkatkan ukuran *batch* dan *corpus* pelatihan, dan memperpanjang waktu pelatihan untuk meningkatkan representasi semantik teks. Model ini menunjukkan kinerja yang luar biasa dalam berbagai tugas *NLP* (Sihombing et al., 1364).

Studi sebelumnya telah menyelidiki analisis sentimen di media sosial dengan menggunakan model *transformer*. Misalnya, penelitian yang dilakukan oleh Maharani et al. (2023) menganalisis sentimen yang terkait dengan vaksinasi COVID-19 di Twitter dengan menggunakan algoritma *Long Short-Term Memory (LSTM)* berbasis *Recurrent Neural Network (RNN).* Hasilnya menunjukkan bahwa model ini memiliki kemampuan yang cukup baik untuk mengklasifikasikan perasaan publik yaitu dengan akurasi keseluruhan sekitar 80,34% (Maharani et al., 2024). Penelitian tambahan oleh Elhan et al. (2023) menggunakan algoritma *Random Forest* dan *BERT* untuk menganalisis sentimen terhadap vaksinasi COVID-19 di Indonesia. Mereka berfokus pada data Twitter sebagai sumber utama opini publik, dan berhasil menunjukan bahwa model tersebut bekerja cukup baik dengan akurasi mencapai 81% (Elhan et al., n.d.). Namun, model RoBERTa masih sangat terbatas untuk analisis komentar publik tentang kebijakan pendidikan militer. Hal ini menunjukkan adanya celah penelitian yang dapat dipenuhi, terutama dengan mempertimbangkan volume komentar Instagram, keragaman gaya bahasa, dan konteks sosial budaya.

Untuk tugas analisis sentimen, model *RoBERTa* memiliki banyak keunggulan, seperti pemahaman konteks dua arah, toleransi terhadap noise linguistik, dan kemampuan untuk memindahkan pembelajaran dari *pretraining* ke *corpus* besar (Purwati, 2023). Namun, model ini juga memiliki beberapa keterbatasan, seperti kebutuhan komputasi yang tinggi, sensitivitas terhadap domain data baru, dan kemungkinan *overfitting* pada dataset kecil jika tidak diatur dengan benar (Basbeth, 2024). Oleh karena itu, penting untuk melakukan evaluasi empiris tentang kinerja model ini dalam data sosial lokal Indonesia.

e-ISSN 2828-0490
JURNAL MEDIA COMPUTER SCIENCE

Dengan menggunakan *RoBERTa* untuk menilai komentar publik di Instagram tentang kebijakan pendidikan militer, penelitian ini bertujuan untuk mengembangkan model klasifikasi sentimen berbasis *deep learning*. Dataset mengandung 5536 komentar yang dikategorikan ke dalam tiga kategori sentimen. Untuk mengevaluasi model, metrik akurasi, ketepatan, *recall*, dan skor f1 digunakan. Hasilnya menunjukkan bahwa model memiliki akurasi sebesar 96% dan f1-score tertinggi sebesar 0,97 untuk kelas positif.

Penerapan model *RoBERTa* dan *Rule-based Hybrid* dengan adaptasi parameter statistik dalam konteks opini publik tentang kebijakan militer di *platform* Instagram berbahasa Indonesia yang sebelumnya belum banyak dipelajari adalah kebaruan (*novelty*) dari penelitian ini. Pendekatan *Rule-based Hybrid* dengan adaptasi statistik pada *preprocessing* adalah strategi algoritmik sederhana namun kuat untuk menangani normalisasi bahasa Sunda ke Indonesia (Panuntun et al., 2023). Selain itu, penelitian ini berkontribusi pada pengembangan teknik analisis opini publik kontekstual dan otomatis. Teknik-teknik ini dapat digunakan oleh pengambil kebijakan, peneliti sosial, dan lembaga pemerintah untuk menanggapi perubahan persepsi masyarakat di era digital.

LANDASAN TEORI

Analisis sentimen adalah bagian dari pemrosesan bahasa alami (*NLP*) yang berkonsentrasi pada pengenalan opini, emosi, atau sikap secara otomatis dari teks. Tujuannya adalah untuk memasukkan ekspresi subjektif ke dalam kategori seperti *negative*, *neutral*, atau positif. Menurut Liu, analisis sentimen dapat diterapkan pada berbagai jenis data teks, seperti opini politik, komentar media sosial, dan ulasan produk (Liu, 2012). Dalam kebanyakan kasus, analisis ini dilakukan pada tingkat kalimat, dokumen, atau bagian tertentu dari entitas yang dibicarakan.

Tiga kategori utama pendekatan untuk analisis sentimen diidentifikasi oleh Medhat et al. : berbasis kamus (*lexicon-based*), berbasis pembelajaran mesin (*machine learning-based*), dan hibrida (Medhat et al., 2014). Metode konvensional, seperti *SVM* dan *Naive Bayes*, sangat berhasil, tetapi mereka tidak dapat menangkap makna kontekstual. Oleh karena itu, untuk mengatasi kekurangan tersebut, penggunaan representasi berbasis vektor dan arsitektur *deep learning* telah berkembang pesat.

RoBERTa (Robustly Optimized BERT Approach) merupakan penyempurnaan dari model *BERT*. Ini menggunakan *masking* dinamis dan melakukan pelatihan pada data yang lebih besar, menghilangkan bagian prediksi frasa berikutnya. Menurut Liu et al., *RoBERTa* mengungguli *BERT* dalam banyak tugas pengolahan bahasa natural, seperti klasifikasi sentimen. Ini disebabkan oleh efisiensi dan kedalaman pemahamannya tentang konteks bahasa (Y. Liu et al., 2019).

Wilie et al., menciptakan standar dan sumber daya evaluasi untuk model pemrosesan bahasa alami dalam bahasa Indonesia, termasuk tugas klasifikasi sentimen, yang membawa perkembangan besar dalam model pemrosesan bahasa alami untuk bahasa Indonesia (Wilie et al., 2020). Model seperti *IndoBERTa* dan *IndoRoBERTa* menunjukkan bahwa arsitektur berbasis *transformer* dapat diterapkan dengan baik dalam konteks bahasa lokal dengan hasil yang kompetitif, bahkan untuk data media sosial seperti komentar Instagram.

METODE PENELITIAN

Metode penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan menerapkan model *deep learning RoBERTa* untuk klasifikasi sentimen terhadap komentar publik di Instagram. Data dikumpulkan melalui *scraping* komentar yang berkaitan dengan isu kebijakan pendidikan militer, kemudian diproses dan dilabelkan menjadi tiga kategori sentimen. Model *RoBERTa* di-*fine-tune* dan dievaluasi berdasarkan metrik akurasi, *precision*, *recall*, dan *F1-score*.

Penelitian dimulai dengan studi literatur yang bertujuan untuk memperoleh pemahaman mendalam tentang teori-teori dasar tentang analisis sentimen dan pemrosesan bahasa alami (*NLP*),

serta keunggulan model *transformer*, khususnya *RoBERTa*, dalam klasifikasi kebijakan pendidikan militer. Desain penelitian ini disusun secara sistematis untuk memodelkan analisis sentimen terhadap komentar publik di Instagram mengenai kebijakan pendidikan militer menggunakan pendekatan i dengan model *RoBERTa*. Selanjutnya, data dikumpulkan melalui komentar dari unggahan Instagram yang berkaitan dengan kebijakan pendidikan militer, terutama yang berkaitan dengan pernyataan Dedi Mulyadi. Data dikumpulkan melalui teknik *web scraping* yang dibantu oleh pustaka *Python* (Fadhillah, 2024).

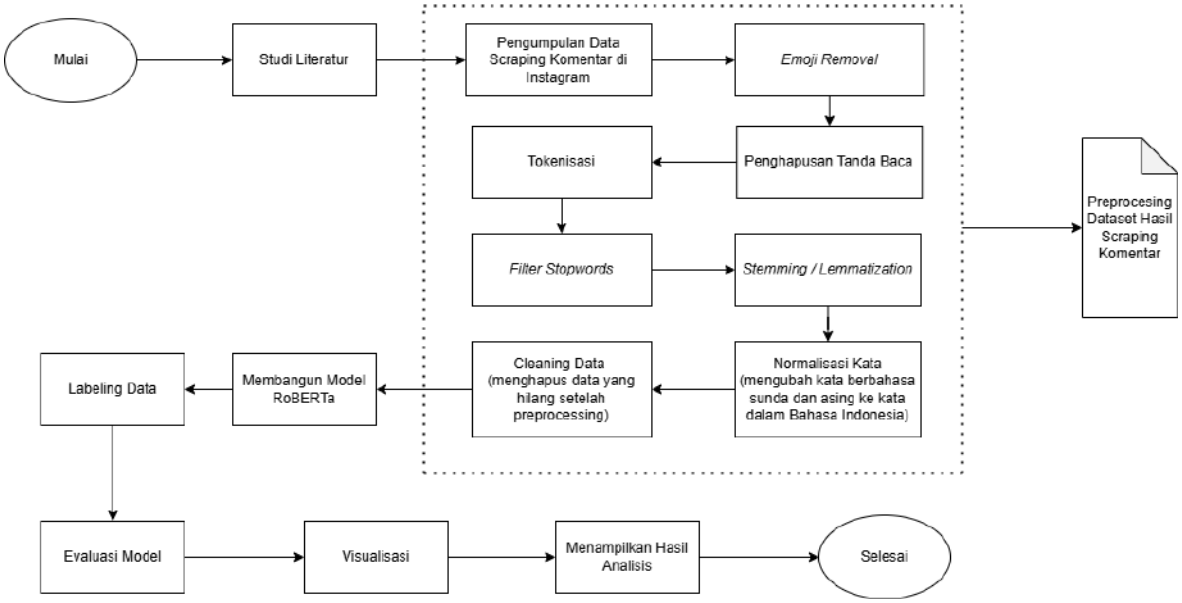

Gambar 1. Desain Penelitian Analisis Sentimen Menggunakan *RoBERTa* dan *Rule-Based Hybird Parameter*

Selanjutnya, data komentar dikumpulkan melalui pra-pemrosesan atau pembersihan data agar siap digunakan dalam pelatihan model. Proses-proses ini termasuk normalisasi kata, penghapusan emoji, tanda baca, tokenisasi kalimat, *filter stopwords*, proses *stemming* atau *lemmatization*, dan penghapusan kata-kata yang berasal dari bahasa daerah (seperti bahasa Sunda) atau asing untuk memenuhi standar Bahasa Indonesia (Fauziyah et al., 2022). Setelah data dibersihkan, mereka kemudian diperiksa lagi untuk memastikan bahwa tidak ada data yang hilang atau kosong. Proses preprocessing dataset hasil *scraping* komentar menyampaikan seluruh tahapan ini.

Data yang dikumpulkan dalam penelitian ini dikumpulkan melalui teknik *web scraping*, yang merupakan proses pengambilan data secara otomatis dari halaman web (Djufri, 2020). Data yang digunakan dalam konteks ini berasal dari *platform* media sosial Instagram, yang dipilih karena merupakan *platform online* yang aktif digunakan masyarakat untuk menyuarakan pendapat mereka dan memberikan tanggapan terhadap masalah kebijakan publik. Kebijakan pendidikan militer telah menjadi subjek diskusi dan perdebatan publik belakangan ini, terutama di wilayah Jawa Barat dan sekitarnya.

Data komentar berasal dari postingan Instagram publik yang secara eksplisit membahas kebijakan pendidikan militer. Postingan ini menerima banyak komentar dan mengungkapkan berbagai pendapat yang mencerminkan tanggapan masyarakat. Ke postingan ini dapat diakses melalui tautan ini: https://www.instagram.com/p/DJNs-1dSAN4/. Instaloader, pustaka *Python* yang digunakan untuk pengambilan data, memungkinkan pengguna mengakses dan mengunduh informasi dari postingan Instagram publik dan akun (Khairunnisa et al., n.d.). Pustaka ini mendukung autentikasi melalui akun Instagram untuk mengakses semua komentar (Darmawan et al., 2023).

Pra-pemrosesan data adalah tahap krusial yang menyiapkan data untuk analisis lebih lanjut. Meskipun data yang dikumpulkan sudah bersih dari *noise* dan tidak valid, masih perlu dilakukan beberapa langkah pra-pemrosesan. Proses ini mencakup pembagian data menjadi set pelatihan dan

e-ISSN 2828-0490
JURNAL MEDIA COMPUTER SCIENCE

pengujian. Set-set ini akan digunakan untuk melatih model dan kemudian menguji kinerjanya (Sidiq et al., 2024). Oleh karena itu, Prapemrosesan data adalah serangkaian langkah-langkah yang dilakukan pada data mentah sebelum dimasukkan ke dalam model analisis untuk meningkatkan kualitas, konsistensi, dan relevansi data.

Prapemrosesan dilakukan dalam pengolahan bahasa alami (*Natural Language Processing*) untuk menghilangkan elemen *non-struktural* dari teks, menyederhanakan bentuk kata, dan menyesuaikan format teks (Prasetya et al., 2024). Tujuan dari proses ini adalah agar teks dapat dipahami dan diproses dengan baik oleh model pembelajaran mesin atau pembelajaran mendalam.

Dalam studi ini, tahap pemodelan sentimen dilakukan dengan memanfaatkan arsitektur deep learning yang berbasis pada *transformer*, yaitu *RoBERTa (Robustly Optimized BERT Pretraining Approach)*. *RoBERTa* adalah salah satu versi yang ditingkatkan dari model *BERT*, yang telah diperbaiki dalam aspek pelatihan dan pemanfaatan data (Putri & Ramani, 2024). Pada studi ini, kami memanfaatkan model yang telah dilatih sebelumnya berbahasa Indonesia, yaitu *w11wo/indonesian-roberta-base-sentiment-classifier*. Model ini sudah tersedia di platform *Hugging Face* dan dirancang khusus untuk tugas klasifikasi sentimen dalam bahasa Indonesia.

Sebelum dimasukkan ke dalam model, data komentar publik yang telah melewati proses prapemrosesan dibagi menjadi dua bagian: data pelatihan dan data pengujian. Rasio pembagian ini adalah 80 persen untuk masing-masing. Setelah pelatihan selesai, data pelatihan digunakan untuk melatih model *RoBERTa* untuk mengidentifikasi pola-pola linguistik yang berkaitan dengan sentimen. Sementara itu, data pengujian disiapkan untuk mengevaluasi kinerja model secara objektif setelah pelatihan selesai. Secara manual, komentar yang digunakan telah dilabelkan ke dalam tiga kategori sentimen *positive*, *neutral*, dan *neugative*. Ini memungkinkan pelatihan dengan pendekatan pembelajaran yang diawasi.

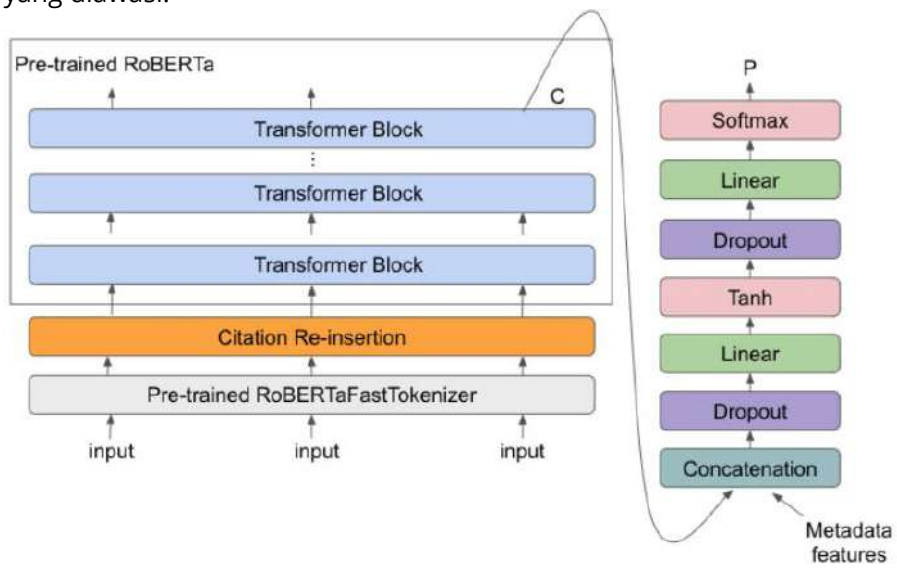

Gambar 2. Siklus *Pretrained* Model *RoBERTa*

Untuk mengevaluasi kinerja model, digunakan beberapa metrik evaluasi standar dalam tugas klasifikasi multi-kelas: akurasi, presisi, *recall*, dan skor f1. Akurasi mengukur persentase prediksi model yang sesuai dengan label aktual dari keseluruhan data uji, sedangkan presisi mengukur proporsi prediksi yang benar untuk setiap kelas dibandingkan dengan semua prediksi yang dibuat untuk kelas tersebut.

Beberapa istilah penting digunakan dalam evaluasi model klasifikasi untuk menunjukkan hasil prediksi: *True Positive (TP), True Negative (TN), False Positive (FP),* dan *False Negative (FN). True Positive (TP)* menunjukkan jumlah kasus di mana model berhasil memprediksi kelas *positive* sesuai dengan kondisi sebenarnya (Hidayat et al., 2025). *False Positive (FP)* terjadi ketika model salah memprediksi suatu data sebagai *positive*, meskipun sebenarnya termasuk dalam kelas *negative*. Sebaliknya, *True Negative (TN)* menunjukkan jumlah prediksi yang benar untuk kelas *negative*, yang berarti bahwa model dengan

tepat mengidentifikasi bahwa data tersebut tidak termasuk dalam kelas *negative*. Namun, kondisi *False Negative (FN)* adalah ketika model tidak dapat menemukan data *positive* yang sebenarnya, sehingga diprediksi *negative*. Keempat komponen ini sangat penting untuk menghitung skor F1, akurasi, presisi, dan *recall*. Untuk melakukan evaluasi ini, fungsi *classification_report* dari pustaka *scikit-learn* digunakan (Wariyanto Abdullah et al., 2025). Fungsi ini dapat memberikan hasil evaluasi untuk masing-masing kategori sentimen, serta *skor* makro dan mikro . Selain itu, model dapat dievaluasi secara visual menggunakan *confusion* matrix untuk menunjukkan distribusi kesalahan klasifikasi antar kelas (Sitanggang et al., 2024). Selain itu, distribusi nilai metrik dapat ditampilkan dengan lebih jelas menggunakan grafik seperti *bar chart* atau *heatmap*.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Setelah pelatihan dan evaluasi model selesai, langkah berikutnya dalam proses analisis adalah membuat visualisasi hasil klasifikasi sentimen model *RoBERTa*. Tujuan visualisasi ini adalah untuk membuat informasi hasil analisis lebih mudah dipahami dan memberikan gambaran umum tentang distribusi sentimen serta pola-pola yang muncul dari data komentar publik yang dianalisis (Putri & Ramani, 2024).

Dalam penelitian ini, visualisasi yang digunakan termasuk diagram batang, atau *bar chart*, yang menunjukkan pembagian jumlah komentar dalam masing-masing kategori sentimen: *positive*, *negative*, dan *neutral*. Visualisasi ini membantu memahami proporsi sentimen masyarakat yang dominan terhadap kebijakan pendidikan militer yang menjadi subjek penelitian. Selain itu, *confusion matrix* juga digunakan untuk menunjukkan performa model (Valerian et al., 2025). Ini menunjukkan berapa banyak prediksi yang salah dan benar yang dibuat oleh model untuk masing-masing kelas sentimen. Untuk mempermudah interpretasi kesalahan klasifikasi, *confusion matrix* divisualisasikan dalam bentuk tabel atau *heatmap*.

HASIL DAN PEMBAHASAN

Hasil

Gambar 3 menunjukkan matriks confusion dan Gambar 4 menunjukkan distribusi hasil prediksi berdasarkan kelas sentimen model RoBERTa yang telah dilatih untuk klasifikasi sentimen komentar publik terhadap kebijakan. Hasil ini menunjukkan bagaimana model berfungsi untuk mengidentifikasi tiga jenis sentimen: negatif, netral, dan positif.

Model menunjukkan akurasi tinggi pada seluruh kelas sentimen, terutama kelas positif, dengan 3.242 prediksi benar dari 3.336 data total (97,2%). Kelas netral juga mengidentifikasi dengan benar 1.268 data (95,1%), dan kelas negatif dengan benar 845 dari 866 data (97,6%). Namun, masih ada beberapa kesalahan klasifikasi yang kecil. Yang paling umum adalah kekeliruan antara kelas netral dan positif.

Gambar 4 menunjukkan distribusi hasil klasifikasi model; balok hijau menunjukkan jumlah prediksi benar (benar positif) dan balok merah menunjukkan jumlah prediksi salah. Dengan 3.226 prediksi benar dan hanya 95 kesalahan, kategori sentimen positif mendominasi jumlah data. Hal ini menunjukkan bahwa model cukup akurat untuk mengidentifikasi komentar dalam dataset, dan sebagian besar komentar berada dalam kategori yang positif.

e-ISSN 2828-0490
JURNAL MEDIA COMPUTER SCIENCE

Secara umum, model menunjukkan kinerja klasifikasi yang sangat baik dengan tingkat kesalahan yang relatif kecil di semua kelas. Validitas model RoBERTa dalam tugas analisis sentimen berbasis bahasa Indonesia diperkuat oleh distribusi data yang seimbang dan akurasi tinggi pada masing-masing kelas.

Pembahasan

Penelitian ini dimulai dengan pengumpulan data dari komentar publik dari satu postingan di platform media sosial Instagram yang membahas kebijakan pendidikan militer. Postingan ini dipilih karena melibatkan diskusi aktif yang relevan dengan topik penelitian. Pustaka Python bernama Instaloader digunakan untuk melakukan pengambilan data. Ini memungkinkan scraping informasi komentar dari akun Instagram publik. Setelah komentar dikumpulkan dengan baik, mereka diekspor ke dalam format .xlxs dan disimpan untuk digunakan selanjutnya. Informasi nama pengguna, dan isi komentar disertakan dalam setiap entri komentar.

Tabel 1. Dataset Komentar di Instagram Hasil Web Scrapping

created_at	text	user_id	username
1746695153	Semoga Jawa Barat semakin banyak militer militer masa depan Indonesia 👍❤️ pokoknya kebijakan hebat pak gubernur Jabar ❤️❤️❤️ karena Jawa Barat punya gubernur hebat, pasti army army militer Jawa Barat paling banyak 👍❤️❤️❤️ maju terus Ade Ade pintar pintar cerdas untuk masa depan Indonesia dan Jawa Barat	48591313395	cicih.sutarsih11
1746156365	Keluar barak nambah kuat nambah kayak jagoan berasa hebat udh di didik tentara 😂	8775330197	botok_7
1746143982	Ikut terharu PK Dedy semoga gub yg lain bisa seperti pak Dedy Mulyadi ❤️❤️🔥🔥🙏🙏	50184357689	alfikhoiriyah045
...	...	...	...
...	...	...	...
1746327420	Pak dedi orang berbahaya dlm tanda kutip, kalau terus bersinar, bisa' jadi capres dan saingan berat capres lainnya nanti.	18278645405	bang_sukur_palembang
1746185923	Pernah kerja dan ada wamil selama 3 hari, tiap tidur gak pernah buka sepatu dan baju lapangan krn pas lg tidur tiba2 pritttttt, selama 3 hari gak pernah boker krn pas baru jongkok udah pritttt, tiap makan di waktu, seret bgt dah itu nasi. Pulang2 langsung hibernasi😂	482318873	aannisanp
1746263251	Anak Indonesia wajib militer 👍	48452313565	tavisha.arsanta

Prapemrosesan data adalah tahap berikutnya, yang bertujuan untuk membersihkan dan menyiapkan komentar agar analisis dapat dilakukan dengan lebih akurat. Penghapusan emoji dan simbol, tokenisasi, penghilangan kata-kata tidak bermakna (penghapusan *stopword*), dan stemming adalah semua proses prapemrosesan.

Tabel 2. *Stopwords* dalam *Library Sastrawi* di *Python*

Baris	Kolom 1	Kolom 2	Kolom 3	Kolom 4	Kolom 5	Kolom 6
0	yang	setelah	mereka	supaya	anu	bagaimanapun
1	untuk	belum	sudah	guna	demikian	
2	pada	kami	saya	kah	tapi	
3	ke	sekitar	terhadap	pun	ingin	
4	para	bago	secara	sampai	juga	
5	namun	serta	agar	sedangkan	nggak	
...	...	...	...	...	...	
...	...	...	...	...	...	
22	saat	akan	sambil	dll	tentu	
23	harus	juga	sebelum	dahulu	amat	
24	sementara	ada	sesudah	dulunya	apalagi	

Salah satu masalah yang muncul selama proses ini adalah penemuan komentar-komentar yang menggunakan Bahasa Sunda atau campuran Bahasa Indonesia-Sunda. Untuk mengatasi masalah ini, proses normalisasi bahasa dilakukan dengan menggunakan pendekatan hybrid yang berbasis aturan dan adaptasi statistik. Dalam proses ini, kamus digunakan untuk mengkonversi kosakata Sunda ke Bahasa Indonesia dan memilih padanan kata berdasarkan frekuensi kata yang ditemukan dalam korpus Bahasa Indonesia.

Tabel 3. Normalisasi *Rule-Based Hybird Parameter*

Baris	kata_dasar	kata_normalisasi	kata_dasar	kata_normalisasi
0	aing	saya	alus	bagus
1	pisan	banget	abdi	saya
2	bageur	baik	bade	mau
3	hoyong	mau	hade	bagus
4	sae	bagus	hatur nuhun	terimakasih
...	...	...	...	...
...	...	...	...	...
48	ngadukung	dukung	goreng	jelek
49	resep	suka	sieun	takut

Metode ini telah terbukti sangat penting untuk menjamin bahwa model dapat memahami konteks komentar yang diberikan oleh penutur lokal. Dari 6276 data yang berhasil diambil dari postingan instagram melalui web scrapping, kemudian melalui tahapan preprocessing sehingga menghasilkan 5536 dataset dengan komentar bersih.

Tabel 4. Hasil *Preprocessing* Pada Dataset Komentar

text	username	komentar_bersih
💙💙bersyukurlah orang tua Krn KDM meninggikan derajat bukan menghardik derajat anak anak yg nakal ...klo ke penjara mereka hitam TPI KLO ke barak mereka putih luar biasa gubernur Jawa Barat moral etika anak nakal menjadi kebanggaan orang tua bahkan negara amiin 🔥🔥🔥💙💙	pipihsopiah305	syukur orang tua karena kdm tinggi derajat bukan hardik derajat anak anak nakal kalau penjara hitam kalau barak putih luar biasa gubernur jawa barat moral etika anak nakal jadi bangga orang tua bahkan negara amin

e-ISSN 2828-0490
JURNAL MEDIA COMPUTER SCIENCE

Keren..... 🔥🔥🔥🔥🔥	wd_djhrudin	keren
🔥🔥🔥 lanjutkan pa	faizalfairelniyaa	lanjut pa
🔥🔥💚 keren pak 🙏	miapalupi_28	keren pak
Harus diajarkan beginilah, kalo orangtuanya saja gak dianggap. Biar mereka menjadi anak hebat.	suryantinitien	harus ajar begini kalo orang tua saja gak anggap biar mereka menjadi anak hebat
...	...	...
...	...	...
Ntar kluar dari situ malah makin petantang petenteng	fathurhasan_	kemudian kluar situ malah makin tantang petenteng
Semoga bisa jadi percontohan untuk provinsi lain. Bravo KDM. Saya dukung langkah KDM 👍👍👍	asady.lpg	moga jadi contoh provinsi bravo kdm dukung langkah kdm
Saya terharu lihatnya...karna memang wajib begini anak anak yang sudah kelewatan wajib dididik ..miris karena anak anak sekarang sudah pada berani sama orang tua 👍	kharismadiantika	haru lihat karna memang wajib begini anak anak lewat wajib didik miris anak anak sekarang sudah pada berani sama orang tua
💚💚💚	meinar575	*(data komentar menjadi kosong dan dihapus dari dataset)*
🔥🔥🔥	ajeng_fitrilayla	*(data komentar menjadi kosong dan dihapus dari dataset)*

Setelah data dibersihkan dan dinormalisasi, komentar diberi label sentimen secara manual: positive, negative, dan neutral. Data kemudian dibagi menjadi dua bagian: dua puluh persen untuk data pengujian dan dua puluh persen untuk data pelatihan. Pelabelan dilakukan dengan mempertimbangkan ekspresi afektif dalam komentar dan konteks makna yang ditimbulkan. Label ini menjadi dasar dari model belajar mengklasifikasikan sentimen dalam pendekatan pembelajaran yang diawasi.

Model pra-latih *w11wo/indonesian-roberta-base-sentiment-classifier*, yang diunduh dari *platform Hugging Face*, digunakan untuk pemodelan sentimen. Model ini telah dilatih sebelumnya dengan korpus Bahasa Indonesia dan disesuaikan untuk tugas klasifikasi sentimen. Data yang telah diproses kemudian dilatih menggunakan kerangka kerja PyTorch dan pustaka transformer Hugging Face, serta tokenizer bawaan RoBERTa. Parameter pelatihan yang digunakan termasuk optimisasi dengan algoritma AdamW dan fungsi penurunan cross-entropy.

Tabel 5. Hasil Pelatihan Model dan Hasil Analisa Model

username	komentar_bersih	sentimen	true_label
suryantinitien	harus ajar begini kalo orang tua saja gak tanggap biar mereka menjadi anak hebat	*positive*	*positive*
riskhanithastarlight	betul ini tempat ajar bentuk anak remaja aktif kuat semoga dapat ajar dapat jadi pribadi lebih baik serta jadi bibit bangsa cerdas milik empati tinggi sama	*positive*	*positive*
pleply85	takut lepas situ makin tambah jago tawur pak	*negative*	*negative*
fathurhasan_	nanti kluar situ malah makin tantang petenteng	*negative*	*negative*

espryt__	moga adik adik didik tni jadi jiwa yg kuat jiwa disiplin mandiri guna bangsa negara orang tua agama	*neutral*	*neutral*
husnidha	pa dedi mau usul tambah kategori anak wajib ikut ke camp militer anak laki laki gemulai biar jadi gagah seperti laki laki	*neutral*	*neutral*
dewapradana4	sebagai warga jatim respek pak dedi menyala tempa kostrad mohon izin pak contoh buat jatim pak wakil gubernur jatim	*neutral*	*positive*
titihajar	jangan cepet jadi presiden pak jadi gubernur jabar aja	*negative*	*positive*
evisakebil	warga jateng cemburu dg jawabarat jakarta dki mas adem ayem pns nya hari rabu naik angkot angkot buat apa ngefek apa dg rakyat pemda banyak oknum nakal semua proyekin jadiin cuan sdh darah daging apa gubenur nya rubah hmmmm kaya kalau mau	*negative*	*positive*
annisa.tyas.921	pak dedi banyak aturan kebanyakan bocah ingusan	*positive*	*negative*
sahlanmujtaba	bahaya bijak militeristik didik adalah ketidaksuaian dgn butuh siswa dekat cenderung abai prinsip diferensiasi strategi perhati beda mampu minat gaya ajar individu padahal didik bukan proses instan bisa ukur hasil hitung minggu bulan dampak baru benar benar asa jangka panjang baik kognitif afektif maupun sosial mungkin perilaku siswa tampak ubah enam bulan ubah bisa sifat semu sekadar hasil tekan bukan transformasi tumbuh sadar paham paksa terus terus dekat justru risiko tumpul daya pikir kritis redam kreativitas bentuk pribadi patuh semata mampu reflektif	*positive*	*negative*
this_abi	kami di jatim cuman bisa menyimak dan iri dengki	*negative*	*negative*
ai_indodesigner	keluar barak makin gaya gaya gak pak biasa nya mental nya kaya gitu masuk penjara makin ngerasa jago aing karek sekali keluar yeuh	*negative*	*negative*

Visualisasi hasil analisis dilakukan dalam bentuk diagram batang dan confusion matrix. Seperti yang ditunjukkan oleh distribusi sentimen, sebagian besar komentar bersifat positif terhadap kebijakan pendidikan militer, dengan komentar negatif dan netral di belakangnya. Selain itu, cloud kata dibuat untuk setiap kategori sentimen untuk menemukan kata-kata yang mendominasi masing-masing kelompok. Hasil penelitian ini menunjukkan bahwa pola-pola semantik unik untuk setiap kategori sentimen, yang memperkuat pemahaman tentang hasil klasifikasi. Selain itu, untuk mendukung visualisasi tersebut, dilakukan evaluasi numerik terhadap kinerja model klasifikasi. Ini dilakukan dengan menggunakan metrik evaluasi seperti *precision*, *recall*, dan skor f1, seperti yang ditunjukkan pada Tabel 6.

e-ISSN 2828-0490
JURNAL MEDIA COMPUTER SCIENCE

Tabel 6. ***Classification Report***

	precision	recall	f1-score	support
negative	0.94	0.98	0.96	866
neutral	0.95	0.95	0.95	1334
positive	0.98	0.97	0.98	3336
accuracy			0.97	5536
macro avg	0.96	0.97	0.96	5536
weighted avg	0.97	0.97	0.97	5536

Tabel tersebut menunjukkan hasil evaluasi kinerja model berdasarkan ketiga metrik utama untuk kelas sentimen (negative, neutral, dan positive), bersama dengan jumlah dukungan data (support) untuk setiap kelas. Hasilnya menunjukkan bahwa model bekerja dengan baik dengan akurasi keseluruhan sebesar 97%. Namun, untuk memahami lebih lanjut tentang bagaimana metrik tersebut diperoleh, dilakukan perhitungan matematis yang rumit.

Precision adalah ukuran seberapa banyak prediksi yang benar dari seluruh prediksi yang dibuat pada suatu kelas tertentu. Recall menunjukkan jumlah data sebenarnya yang berhasil dikenali oleh model. Namun, skor f1 adalah rata-rata harmonis antara ketepatan dan recall, yang memberikan ukuran yang seimbang untuk kedua metrik tersebut. Ini adalah rumus yang digunakan untuk menghitung nilai masing-masing:

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

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

Perhitungan nilai *true positive (TP), false positive (FP),* dan *false negative (FN)* dilakukan secara manual berdasarkan jumlah dukungan data (*support*) untuk setiap kelas, serta nilai *precision* dan *recall* yang ditampilkan pada Tabel 5. Nilai-nilai ini kemudian digunakan dalam rumus di atas untuk memverifikasi keakuratan perhitungan metrik evaluasi model.

Untuk kelas *negative*, nilai TP adalah 845, FP sebesar 51, dan FN sebesar 21. Precision dihitung sebagai:

$$Precision_{Negative} = \frac{845}{845 + 51} = \frac{845}{896} = 0.94 \quad (1)$$

Recall untuk kelas *negative* dihitung sebagai :

$$Recall_{Negative} = \frac{845}{845 + 21} = \frac{845}{866} = 0.98 \quad (2)$$

Dengan demikian, *f1-score* untuk kelas ini adalah:

$$F1 - Score_{Negative} = 2 \times \frac{0.94 \times 0.98}{0.94 + 0.98} = 2 \times \frac{0.9212}{1.92} = 2 \times 0.47979 = 0.96 \quad (3)$$

Untuk kelas *neutral*, diperoleh TP = 1268, FP sebesar 69, dan FN sebesar 66. *Precision* dihitung sebagai:

$$Precision_{Neutral} = \frac{1268}{1268 + 69} = \frac{1268}{1337} = 0.95 \quad (1)$$

Recall untuk kelas *neutral* dihitung sebagai :

$$Recall_{Neutral} = \frac{1268}{1268 + 66} = \frac{1268}{1334} = 0.95 \quad (2)$$

Dengan demikian, *f1-score* untuk kelas ini adalah :

$$F1 - Score_{Neutral} = 2 \times \frac{0.95 \times 0.95}{0.95 + 0.95} = 2 \times \frac{0.9017}{1.8989} = 2 \times 0.4749 = 0.95 \quad (3)$$

Untuk kelas *positive*, diperoleh TP sebanyak 3242, FP sebanyak 61, dan FN sejumlah 94. *Precision* dihitung sebagai:

$$Precision_{positive} = \frac{3242}{3242 + 61} = \frac{3242}{3303} = 0.98 \quad (1)$$

Recall untuk kelas *neutral* dihitung sebagai :

$$Recall_{positive} = \frac{3242}{3242 + 94} = \frac{3242}{3336} = 0.97 \quad (2)$$

Dengan demikian, *f1-score* untuk kelas ini adalah:

$$F1 - Score_{positive} = 2 \times \frac{0.98 \times 0.97}{0.98 + 0.97} = 2 \times \frac{0.9541}{1.9535} = 2 \times 0.4882 = 0.98 \quad (3)$$

Selain mengukur kinerja model untuk masing-masing kelas berdasarkan skor precision, recall, dan f1-nya, evaluasi juga dilakukan terhadap akurasi secara keseluruhan. Ukuran ini menunjukkan proporsi jumlah prediksi yang benar dibandingkan dengan total jumlah data, memberikan gambaran umum tentang seberapa tepat model dalam mengklasifikasikan komentar secara menyeluruh. Nilai akurasi dapat dihitung dengan menggunakan rumus berikut:

$$Accuracy = \frac{Total\ Prediksi\ Benar}{Total\ Prediksi} = \frac{\sum_i TP_i}{Total\ Prediksi} \quad (1)$$

Untuk menghitung jumlah prediksi yang benar untuk setiap kategori sentimen, *confusion matrix* yang diperoleh digunakan:

$$Accuracy = \frac{\sum_i TP_i}{Total\ Prediksi} = \frac{T_{Positive} + T_{Negative} + T_{neutral}}{Total\ Prediksi} \quad (1)$$

$$Acuracy = \frac{T_{Positive} + T_{Negative} + T_{neutral}}{Total\ Prediksi} = \frac{845 + 1268 + 3242}{5536} \quad (2)$$

$$Acuracy = \frac{845 + 1268 + 3242}{5536} = \frac{5355}{5536} = 0.9673 \approx 0.97 \quad (3)$$

Proses klasifikasi model terhadap ketiga kategori sentimen ditunjukkan oleh visualisasi matrix confusion. Nilai-nilai diagonal menunjukkan jumlah prediksi yang benar untuk masing-masing kelas, dengan akurasi 97,6% untuk kelas negatif, 95,1% untuk kelas neutral, dan 97,2% untuk kelas positif.

e-ISSN 2828-0490
JURNAL MEDIA COMPUTER SCIENCE

Nilai-nilai di luar diagonal menunjukkan prediksi yang salah, tetapi jumlahnya kecil, yang menunjukkan bahwa model secara konsisten memiliki tingkat akurasi yang tinggi.

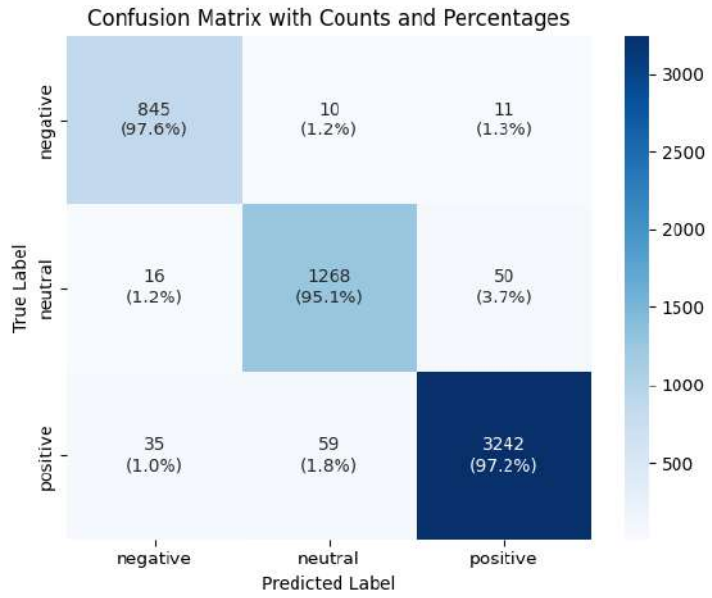

Gambar 3. Confusion Matrix Hasil Analisa Sentimen

Untuk setiap sentimen, diagram batang hasil prediksi menunjukkan perbandingan antara jumlah prediksi benar (ditunjukkan dengan warna hijau) dan prediksi salah (ditunjukkan dengan warna merah). Sebagian besar data telah diklasifikasikan dengan benar oleh model, terutama kelas positif, yang mendominasi secara kuantitatif. Keberhasilan model dalam mengenali pola sentimen secara akurat diperjelas dalam visualisasi ini.

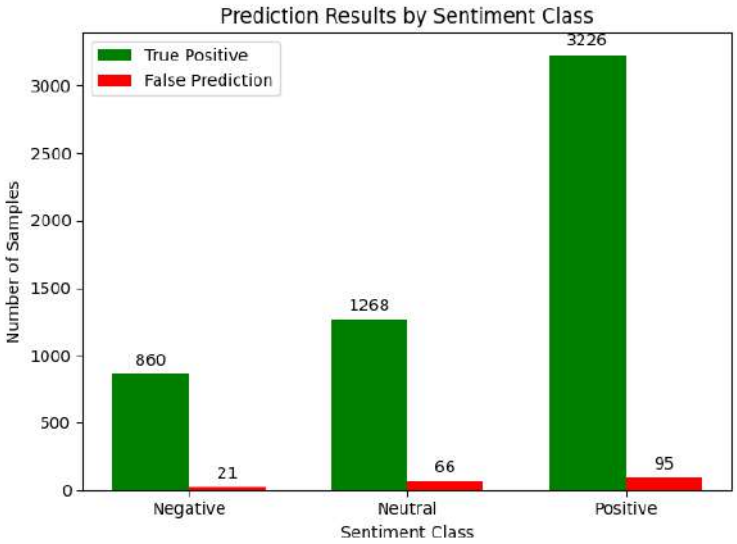

Gambar 4. Hasil Prediksi Klasifikasi Sentimen pada Komentar

Kata-kata yang paling sering muncul dalam komentar publik secara keseluruhan tentang kebijakan pendidikan militer ditampilkan dalam wordcloud yang ditunjukkan pada Gambar 5. Dengan menggunakan kata-kata seperti "pak", "anak", "baik", "gubernur", dan "program", masyarakat menunjukkan perhatian utama masyarakat terhadap sosok pemimpin, tujuan pembinaan karakter, dan arah kebijakan yang dianggap positif. Selain itu, istilah seperti "disiplin", "mental", "didik", dan "sekolah" juga sering muncul, menunjukkan bahwa pendekatan militeristik digunakan untuk

memperhatikan aspek pembentukan kepribadian generasi muda. Menurut wordcloud ini, hasil analisis menunjukkan bahwa respons publik didominasi oleh apresiasi terhadap tokoh dan program yang dianggap berkontribusi pada pembinaan moral dan perilaku remaja.

Gambar 5. Wordcloud Dari Hasil Analisis Sentimen

KESIMPULAN DAN SARAN

Kesimpulan

ini menemukan bahwa model klasifikasi sentimen berbasis pembelajaran mendalam memiliki kemampuan untuk mengelompokkan komentar publik terhadap kebijakan pendidikan militer dengan akurasi sebesar 97%. Berdasarkan evaluasi menggunakan matrix confusion, recall, dan skor f1, model ini secara konsisten menemukan ketiga kategori sentimen, dengan preferensi untuk kelas yang positif. Hasil visualisasi diagram batang juga menunjukan respon kinerja mesin learning yang cukup baik dalam menganalisa sentimen sehingga dapat menggambarkan respon publik yang mayoritas setuju dengan kebijakan pendidikan militer bagi kenakalan remaja khususnya bagi pelajar di Jawa Barat.

Hasil tersebut diperkuat oleh wordcloud, yang menggunakan kata-kata seperti "setuju", "mantap", "anak", "program", dan "disiplin", yang menunjukkan dukungan masyarakat terhadap peran tokoh publik serta program pembinaan karakter generasi muda dengan menggunakan metode pendidikan militer. Namun, komentar yang dipenuhi dengan emosi negatif sebagian besar mengkritik mereka yang menentang atau menyalahpahami kebijakan, bukan kebijakan itu sendiri. Komentar netral banyak mengandung ekspresi haru, doa, dan saran konstruktif untuk Komando Daerah Militer (KDM). Ini menunjukkan rasa ingin tahu dan harapan masyarakat atas keberhasilan program tersebut.

Secara keseluruhan, temuan penelitian ini menunjukkan bahwa kebijakan pendidikan militer mendapatkan respons publik yang cenderung mendukung dan positif, dengan kritik dan saran yang konstruktif.

Saran

Hasil penelitian ini mendorong pengembangan model klasifikasi sentimen berbasis RoBERTa dengan memasukkan pendekatan hibrida. Tujuan dari penelitian ini adalah untuk meningkatkan pemahaman tentang aspek emosi yang kompleks dalam komentar publik. Selain itu, generalisasi model dapat ditingkatkan dengan memperluas data dari berbagai masalah dan area. Hasil bahwa sebagian besar komentar mendukung kebijakan pendidikan militer menunjukkan betapa pentingnya menggunakan analisis sentimen untuk merespons kebijakan publik. Akibatnya, temuan ini dapat digunakan oleh lembaga yang terkait, seperti Komando Daerah Militer (KDM), untuk membuat

strategi komunikasi publik yang lebih terbuka dan melibatkan masyarakat. Selain itu, untuk meningkatkan penerimaan masyarakat, diperlukan peningkatan literasi digital dan edukasi publik. Ini dilakukan agar opini yang dibentuk lebih berdasarkan pemahaman yang jelas daripada disinformasi atau kesalahpahaman.

DAFTAR PUSTAKA

Irwanda, A. A., Abiyus, W., Herdiansyah, A., Turnandes, Y., & Juliani, F. (2024). Analisis engagement rate pada Instagram Universitas Lancang Kuning. ZONASi: Jurnal Sistem Informasi, 6(2), 391–399. https://journal.unilak.ac.id/index.php/zn/article/view/17904/6367

Nurrochmah, D. S., Rahaningsih, N., Dana, R. D., & Rohmat, C. L. (2025). Penerapan algoritma Naive Bayes dalam analisis sentimen ulasan aplikasi KitaLulus di Google Play Store. Jurnal Informatika Terpadu, 11(1), 1–11. https://journal.nurulfikri.ac.id/index.php/JIT/article/view/1544

Sihombing, Y. O., & Situmorang, N. V. (2024). Prediksi sentimen pada teks media sosial Corporate University menggunakan RoBERTa. Prosiding PITNAS 2024, Badan Kepegawaian Negara. https://ejournal.iwi.or.id/ojs/index.php/pitnas2024/article/view/316

Maharani, C. A., Warsito, B., & Santoso, R. (2023). Analisis sentimen vaksin COVID-19 pada Twitter menggunakan Recurrent Neural Network (RNN) dengan algoritma Long Short-Term Memory (LSTM). Jurnal Gaussian, 12(3), 403–413. https://ejournal3.undip.ac.id/index.php/gaussian/article/view/36927/30755

Elhan, A., Hardhienata, M. K. D., Herdiyeni, Y., Wijaya, S. H., & Adisantoso, J. (2023). Analisis sentimen pengguna Twitter terhadap vaksinasi COVID-19 di Indonesia menggunakan algoritme Random Forest dan BERT. Jurnal Ilmu Komputer dan Agri-Informatika (JIKA), 9(2), 199–211. https://journal.ipb.ac.id/index.php/jika/article/view/44459/24643

Purwati, K. Y. (2023, August). Analisis sentimen berita vaksin COVID-19 dengan Robustly Optimized BERT Pre-Training Approach (RoBERTa) [Skripsi, UIN Syarif Hidayatullah Jakarta]. https://repository.uinjkt.ac.id/dspace/handle/123456789/73319

Basbeth, F. (2024). Klasifikasi emosi data text Bahasa Indonesia menggunakan algoritma BERT, RoBERTa, dan DistilBERT [Skripsi, Universitas Islam Indonesia]. https://dspace.uii.ac.id/handle/123456789/51001

Fadhillah, M. R. (2024, August). Analisis sentimen berbasis aspek pada review aplikasi ChatGPT menggunakan Multinomial Naive Bayes [Skripsi, UIN Syarif Hidayatullah Jakarta]. https://repository.uinjkt.ac.id/dspace/handle/123456789/80712

Fauziyah, Y., Ilyas, R., & Kasyidi, F. (2022, July). Mesin penterjemah Bahasa Indonesia–Bahasa Sunda menggunakan Recurrent Neural Networks. Jurnal Teknoinfo, 16(2), 313–322. https://ejurnal.teknokrat.ac.id/index.php/teknoinfo/index

Panuntun, S. B., Krismaswati, D., Pramana, S., & Astuti, E. T. (2023). Analisis teks pemberitaan telemedicine di Indonesia: Pendekatan sentimen, NER, topic modeling, dan social network dalam memahami isu dan persepsi. INOHIM: Esa Unggul Management Journal, 11(1). https://inohim.esaunggul.ac.id/index.php/INO/article/view/500

Khairunnisa, K., Dewi, S. K., Rahmawati, D. D., & Sari, A. P. (2024). Analisis sentimen komentar pada postingan Instagram akun 'StandWithUs' menggunakan klasifikasi Naive Bayes. Jurnal Ilmiah Informatika (JIF), 12(2). https://doi.org/10.33884/jif.v12i02.9263

Darmawan, I. P. D. W., Pradnyana, G. A., & Pascima, I. B. N. (2023, April). Optimasi parameter Support Vector Machine dengan algoritma genetika untuk analisis sentimen pada media sosial Instagram. SINTECH Journal, 6(1). https://ejournal.instiki.ac.id/index.php/sintechjournal/article/view/1245

Djufri, M. (2020). Penerapan teknik web scraping untuk penggalian potensi pajak (Studi kasus pada online marketplace Tokopedia, Shopee dan Bukalapak). Jurnal BPPK, 13(2). https://doi.org/10.48108/jurnalbppk.v13i2.636

Sidiq, C. M., Faqih, A., & Dwilestari, G. (2024, April). Algoritma decision tree C4.5 digunakan untuk mengklasifikasikan data stroke. JATI (Jurnal Mahasiswa Teknik Informatika), 8(2). https://ejournal.itn.ac.id/index.php/jati/article/view/8388/5302

Prasetya, M. A., Wulandari, M., & Nikmah, S. A. (2024). Implementasi NLP (Natural Language Processing) dasar pada analisis sentiment review Spotify. Prosiding Seminar Nasional Teknologi dan Sains, 3. https://proceeding.unpkediri.ac.id/index.php/stains/article/view/4166/3013

Nemkul, K. (2024). Use of Bidirectional Encoder Representations from Transformers (BERT) and Robustly Optimized BERT Pretraining Approach (RoBERTa) for Nepali news classification. Tribhuvan University Journal, 39(1). https://doi.org/10.3126/tuj.v39i1.66679

Hidayat, J. J., Setyowati, C., & Werdana, A. P. (2025, May). Perancangan sistem prediksi penyakit pada tanaman padi berbasis image processing menggunakan algoritma VGG-16 transfer learning dan K-Means segmentation. Journal of Practical Computer Science, 5(1), 1–15. https://jurnal.pelitabangsa.ac.id/index.php/jpcs/article/view/5759

Abdullah, R. W., Kusumastuti, R., & Handoko. (2025, February). Analisis pengolahan ekstraksi fitur citra untuk klasifikasi jenis apel menggunakan Scikit-Learn dengan algoritma K-Nearest Neighbor. Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK), 12(1), 165–174. https://doi.org/10.25126/jtiik.2025129149

Sitanggang, A., Umaidah, Y., & Adam, R. I. (2024, August). Analisis sentimen masyarakat terhadap program makan siang gratis pada media sosial X menggunakan algoritma Naïve Bayes. Jurnal Informatika dan Teknik Elektro Terapan (JITET), 12(3), 1–8. https://doi.org/10.23960/jitet.v12i3.4902

Putri, E. F. K., & Ramani, A. (2024). Perancangan dashboard visualisasi data kesehatan ibu dan anak di Dinas Kesehatan Kabupaten Jember (Design of maternal and child health data visualization dashboard at Jember District Health Office) [Undergraduate thesis, Universitas Jember]. https://www.researchgate.net/publication/379493296

Valerian, F. R., Syarief, M., & Fatah, D. A. (2025, April). Klasifikasi tingkat obesitas menggunakan metode GBM dan confusion matrix. JATI (Jurnal Mahasiswa Teknik Informatika), 9(2), 1–8. https://doi.org/10.36040/jati.v9i2.13062

Liu, B. (2012). *Sentiment analysis and opinion mining*. Morgan & Claypool Publishers. https://www.cs.uic.edu/~liub/FBS/SentimentAnalysis-and-OpinionMining.pdf

Medhat, W., Hassan, A., & Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. Ain Shams Engineering Journal, 5(4), 1093–1113. https://doi.org/10.1016/j.asej.2014.04.011

Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., & Stoyanov, V. (2019). RoBERTa: A robustly optimized BERT pretraining approach (arXiv:1907.11692). arXiv. https://arxiv.org/abs/1907.11692

Wilie, B., Vincentio, K. A., Winata, G. I., Cahyawijaya, S., Li, X., Fung, P., & Bahar, S. (2020). *IndoNLU: Benchmark and resources for evaluating Indonesian natural language understanding* (arXiv:2009.05387). arXiv. https://arxiv.org/abs/2009.05387