

Klasifikasi Sentimen terhadap Program Barak Militer Anak Dedi Mulyadi Menggunakan Support Vector Machine

Sentiment Classification on Dedi Mulyadi's Child Military Camp Program Using Support Vector Machine

Nur Ainun Mansyur^{*1}, Farid Wajidi², Muh Rafli Rasyid³

Program Studi Teknik Informatika, Fakultas Teknik, Universitas Sulawesi Barat

E-mail : ainunsyuda01@gmail.com^{*1}, faridwajidi@unsulbar.ac.id²,

mrafli@unsulbar.ac.id³

^{*}Corresponden author

Received 21 January 2026; Revised 20 February 2026; Accepted 22 February 2026

Abstrak – Media sosial, khususnya X, menjadi wadah penting bagi publik dalam menyampaikan opini terhadap kebijakan pemerintah, termasuk kebijakan kontroversial seperti program Barak Militer Anak yang diinisiasi oleh Dedi Mulyadi. Penelitian ini bertujuan untuk menganalisis sentimen publik terhadap program tersebut serta mengevaluasi kinerja algoritma *machine learning* dalam klasifikasi teks media sosial. Data diperoleh melalui proses *crawling* sebanyak 1,826 tweet dan difilter menjadi 1,000 tweet yang relevan. Pelabelan sentimen dilakukan secara otomatis menggunakan model BERT NLP Town dan divalidasi melalui anotasi manual terhadap seluruh data. Data kemudian diproses melalui tahap *preprocessing* dan ekstraksi fitur TF-IDF sebelum diklasifikasikan menggunakan Support Vector Machine kernel linear. Evaluasi dilakukan menggunakan *hold-out* dan 10-fold *cross-validation*. Hasil *hold-out* menunjukkan akurasi sebesar 71,0%, sedangkan *cross-validation* rata-rata akurasi sebesar 69,90% ± 3,03%, *macro* F1-Score 57,89% ± 5,08%, dan *balanced accuracy* 57,36% ± 4,67%. Hasil menunjukkan model memiliki performa cukup baik, namun belum merata pada semua kelas, terutama kelas netral. Secara keseluruhan, kombinasi BERT NLP Town, TF-IDF, dan SVM memberikan gambaran awal sentimen publik terhadap kebijakan tersebut, namun masih diperlukan pengembangan lebih lanjut untuk meningkatkan stabilitas dan kemampuan generalisasi model.

Kata Kunci - Analisis Sentimen, Support Vector Machine, BERT NLP Town, TF-IDF, X

Abstract - Social media, particularly X, has become an important platform for the public to express opinions on government policies, including controversial policies such as the Children's Military Barracks program initiated by Dedi Mulyadi. This study aims to analyze public sentiment toward the program and evaluate the performance of machine learning algorithms in classifying social media text. Data was collected through a crawling process of 1,826 tweets and filtered down to 1,000 relevant tweets. Sentiment labeling was performed automatically using the BERT NLP Town model and validated through manual annotation of the entire dataset. The data was then processed through preprocessing and TF-IDF feature extraction before being classified using a linear kernel Support Vector Machine. Evaluation was conducted using hold-out and 10-fold cross-validation. The hold-out results showed an accuracy of 71.0%, while the cross-validation yielded an average accuracy of 69.90% ± 3.03%, a macro F1-Score of 57.89% ± 5.08%, and a balanced accuracy of 57.36% ± 4.67%. The results indicate that the model performs reasonably well, though its performance is not consistent across all classes, particularly the neutral class. Overall, the combination of BERT NLP Town, TF-IDF, and SVM provides an initial insight into public sentiment regarding the policy; however, further development is still needed to improve the model's stability and generalization capabilities.

Keywords – Sentiment Analysis, Support Vector Machine, BERT NLP Town, TF-IDF, X

1. PENDAHULUAN

Indonesia memiliki jumlah pengguna X aktif yang sangat tinggi, terutama di kalangan generasi muda. Kondisi ini menjadikan analisis sentimen terhadap percakapan digital sebagai cara untuk memahami opini publik secara lebih objektif dan berbasis data [1]. Namun, meninjau ribuan komentar publik secara manual tidak hanya tidak efisien, tetapi juga rentan terhadap kesalahpahaman. Ungkapan bahasa informal, bahasa gaul, singkatan, dan sarkasme yang sering muncul di media sosial mempersulit pemahaman teks. Oleh karena itu, identifikasi pola sentimen secara akurat dalam skala besar membutuhkan metode berbasis komputer yang memanfaatkan kecerdasan buatan [2].

Aplikasi X merupakan salah satu platform media sosial yang berkembang paling pesat, di mana pengguna dapat membuat, mempublikasikan, dan menampilkan pesan teks singkat yang disebut *tweet*. Melalui *tweet* ini, pengguna X dapat menyampaikan pendapat, wawasan, dan pemikiran mereka mengenai topik tertentu. X sering digunakan sebagai sumber data untuk menganalisis opini dan sentimen publik, dengan tujuan memahami persepsi masyarakat terhadap isu-isu tertentu. Analisis sentimen pada X bertujuan untuk mengkategorikan opini emosional dari *tweet* menjadi positif, negatif, atau netral [3].

Kebijakan yang diumumkan oleh Gubernur Jawa Barat mengenai program pendidikan bagi anak-anak di fasilitas militer telah memicu perdebatan publik yang luas. Program ini kontroversial karena melibatkan pendekatan yang dianggap tidak lazim dalam konteks pendidikan, perlindungan anak, dan kebijakan sosial. Fenomena ini menunjukkan bahwa media sosial telah berkembang tidak hanya sebagai ruang diskusi, tetapi juga sebagai *platform* debat digital yang sangat dinamis [4].

Salah satu metode yang efektif untuk mengklasifikasikan teks berskala besar adalah Support Vector Machine (SVM) [5]. SVM bekerja dengan membentuk *hyperplane* terbaik sebagai batas pemisah antar kelas dalam ruang fitur berdimensi tinggi. Kemampuannya dalam menangani data *non-linear* melalui fungsi *kernel* menjadikannya metode yang sesuai untuk berbagai tugas klasifikasi teks, termasuk analisis sentimen [6].

Penelitian sebelumnya, menganalisis sentimen pada maskapai penerbangan di platform twitter menggunakan algoritma Support Vector Machine yang mencapai nilai akurasi sebesar 84.37% [7]. Penggunaan algoritma Naive Bayes dalam menganalisis sentimen twitter terhadap kebijakan masuk barak militer yang mencapai nilai akurasi sebesar 86,51% [4]. Selanjutnya, dalam menganalisis sentimen review film menggunakan TF-IDF dan Support Vector Machine yang berhasil mencapai akurasi sebesar 85% [8]. Selanjutnya, membandingkan SVM dan Naive Bayes dalam analisis sentimen terhadap penggunaan mobil listrik di Indonesia dan menunjukkan perbedaan performa antar algoritma dimana algoritma SVM lebih unggul dengan mencapai akurasi sebesar 70,82% [9]. Penelitian lain juga membandingkan beberapa algoritma *machine learning* dalam analisis sentimen figur publik dan isu politik pasca Pilpres 2024, serta mengkombinasikan SVM dengan pendekatan ensemble untuk meningkatkan performa [10][11][12]. Temuan-temuan tersebut menunjukkan bahwa metode machine learning klasik masih relevan dalam studi opini publik di media sosial.

Perkembangan *Large Language Model* (LLM) seperti BERT, RoBERTa, dan GPT dalam beberapa tahun terakhir memang menunjukkan peningkatan performa signifikan dalam berbagai tugas *Natural Language Processing* [2][13]. Namun demikian, beberapa penelitian terbaru mengungkapkan bahwa pada dataset berukuran kecil hingga menengah, serta pada data teks pendek seperti *tweet*, pendekatan berbasis fitur seperti TF-IDF yang dikombinasikan dengan SVM masih memberikan performa yang kompetitif [6][14]. Selain itu, model LLM umumnya memerlukan sumber daya komputasi besar serta proses *fine-tuning* yang kompleks, sehingga pendekatan machine learning klasik tetap relevan dalam konteks penelitian.


Dengan demikian, penggunaan SVM dalam penelitian ini bukan merupakan pendekatan yang usang, melainkan strategi metodologis yang disesuaikan dengan karakteristik data dan tujuan evaluasi penelitian.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menganalisis sentimen publik terhadap program Barak Militer Anak yang diinisiasi oleh Dedi Mulyadi dengan memanfaatkan pelabelan otomatis menggunakan model BERT NLP Town dan klasifikasi menggunakan algoritma Support Vector Machine. Sentimen dikategorikan ke dalam tiga kelas, yaitu positif, negatif, dan netral. Proses analisis meliputi tahap *preprocessing*, *ekstraksi fitur* menggunakan TF-IDF, serta pemodelan klasifikasi menggunakan SVM. Kebaruan utama penelitian ini terletak pada evaluasi sentimen terhadap kebijakan spesifik yang bersifat aktual, dengan memanfaatkan pelabelan otomatis berbasis BERT untuk meningkatkan efisiensi dalam proses pelabelan data. Pendekatan ini kemudian diperkuat dengan anotasi manual terhadap seluruh data untuk menjaga kualitas label yang digunakan dalam proses klasifikasi. Berbeda dengan penelitian sebelumnya yang umumnya menggunakan dataset publik berlabel atau anotasi manual penuh, penelitian ini menggabungkan pelabelan otomatis dengan validasi manual untuk menjaga kualitas *ground truth*.

Pendekatan ini memungkinkan analisis sentimen dilakukan secara lebih sistematis dengan tetap mempertahankan kualitas label. Hasil penelitian diharapkan dapat memberikan gambaran persepsi publik sekaligus mengevaluasi efektivitas kombinasi BERT NLP Town dan SVM dalam mengklasifikasikan teks media sosial yang bersifat informal.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode text mining untuk menganalisis sentimen publik terhadap Program Barak Militer Anak Dedi Mulyadi berdasarkan data dari X. Proses penelitian ini menjelaskan 8 tahap yang digunakan untuk menganalisis komentar. Tahapannya meliputi pengumpulan data, *filtering* data, pelabelan data, *preprocessing* data, visualisasi *wordcloud*, ekstraksi fitur (TF-IDF), pelatihan model SVM, dan evaluasi model. Dan akan dijelaskan pada sub bab berikutnya [15]. Alurnya dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Data dikumpulkan menggunakan teknik *crawling* data dengan *tools Tweet Harvest* berbasis *Node.js*, dan *auth token* yang terhubung ke *platform* media sosial X. Metode ini memungkinkan pengumpulan data secara sistematis dan efisien dari berbagai sumber, sehingga memudahkan analisis, penelitian, dan pengembangan aplikasi. Data yang dikumpulkan mencakup *tweet* berbahasa Indonesia dalam rentang waktu 28 April – 2 Desember 2025, yang mengandung kata kunci “Pendidikan Barak Militer Anak” beserta kata kunci terkait, seperti “Barak Militer Anak”, “Program Pendidikan Militer Anak” [16].

Pemilihan kata kunci ini berkaitan langsung dengan topik penelitian, yaitu opini publik terhadap program pendidikan berbasis fasilitas militer bagi anak-anak yang diumumkan oleh Gubernur Jawa Barat. Kata kunci digunakan untuk memastikan bahwa *tweet* yang dikumpulkan relevan dengan isu yang menjadi fokus penelitian. Setelah proses pengumpulan, seluruh *tweet* dikompilasi ke dalam file *Microsoft Excel* untuk memudahkan proses filter dan pelabelan data. Secara keseluruhan, terdapat 1,826 data *tweet* yang berhasil dikumpulkan.

2.2. Filtering Data

Berdasarkan hasil *crawling*, diperoleh sebanyak 1,826 *tweet* yang berkaitan dengan topik penelitian. Selanjutnya, dilakukan *data cleaning* dan *filtering* untuk meningkatkan kualitas dataset sebelum tahap analisis.

Setelah data dikumpulkan, tahap awal *cleaning* meliputi penghapusan *retweet* dan data duplikat dengan menggunakan fungsi *drop_duplicates()* pada pustaka *pandas* di Google Colab [17]. Proses ini bertujuan untuk menghindari pengulangan informasi yang dapat memengaruhi distribusi sentimen serta menjaga keberagaman opini dalam dataset.

Tahap berikutnya adalah penyaringan relevansi (*filtering*) berdasarkan pencocokan kata kunci yang berkaitan langsung dengan isu “Barak Militer Anak” yaitu (kdm, kang_dedi_mulyadi, gubernur, jawa_barat, program, barak_militer, anak, pendidikan, masalah, nakal, tni, tentara, masyarakat, rakyat, disiplin, solusi, bermasalah, setuju, dan tidak) dan kebijakan yang diinisiasi oleh Dedi Mulyadi. *Tweet* yang tidak memiliki keterkaitan konteks dengan topik penelitian dieliminasi untuk mengurangi noise dan meningkatkan validitas analisis [18].

2.3. Pelabelan Data

Pelabelan data merupakan proses pengelompokan data ke dalam kategori tertentu yang menjadi langkah penting dalam penelitian berbasis *machine learning* [18].

Setelah melalui tahap *filtering*, proses pelabelan sentimen dilakukan menggunakan model *Bidirectional Encoder Representations from Transformers* (BERT) yang dikembangkan oleh NLP Town, dengan *tokenizer nlptown* yang sesuai [13]. Model BERT dipilih karena kemampuannya memahami konteks kata secara *bidirectional*, sehingga efektif dalam menangani variasi bahasa alami yang sering muncul pada media sosial. Model NLP Town digunakan untuk mengklasifikasikan teks ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. Hasil pelabelan otomatis dari model BERT kemudian digunakan sebagai label utama dalam proses pelatihan dan evaluasi model Support Vector Machine (SVM).


Untuk memastikan kualitas label otomatis tersebut, dilakukan proses validasi secara manual terhadap seluruh data yang berjumlah 1,000 *tweet*. Hasil perbandingan antara pelabelan otomatis dan anotasi manual menunjukkan adanya perbedaan distribusi sentimen yang cukup signifikan, di mana model BERT cenderung menghasilkan jumlah sentimen negatif yang lebih tinggi dibandingkan anotasi manual, serta lebih rendah dalam mengidentifikasi sentimen positif dan netral. Adapun contoh *tweet* untuk setiap label yang dapat dilihat pada Tabel 1.

Tabel 1. Contoh *Tweet* pada Setiap Label Sentimen BERT

No.	<i>Tweet</i>	Label
1.	Komponen cadangan menjalani proses pelatihan yang tidak hanya mengembangkan kemampuan fisik dan keterampilan militer, tetapi juga menanamkan nilai-nilai dasar bela negara, seperti kedisiplinan, integritas, tanggung jawab, ketangguhan, dan sikap pantang menyerah.	Positif
2.	Anak bukan tantara dan barak bukan tempat belajar. Kebijakan pendisiplinan 272 siswa dengan pendekatan militeristik yang diinisiasi oleh Gubernur Jawa Barat Dedi Mulyadi dinilai melanggar hak anak serta bertentangan dengan prinsip-prinsip dasar perlindungan anak.	Negatif
3.	Gubernur Jawa Barat Dedi Mulyadi mengirim 39 siswa bermasalah ke barak militer setelah terlibat tawuran, bolos sekolah, dan kecanduan gim. Program ini bertujuan mendisiplinkan siswa agar kembali berperilaku baik. Apakah program tersebut efektif?	Netral

2.4. Preprocessing Data

Text preprocessing adalah langkah untuk menyiapkan data tulisan mentah agar menjadi data yang lebih baik sehingga menghasilkan informasi tulisan yang berkualitas dan siap dipakai dalam tahap berikutnya. Di tahap ini digunakan berbagai pustaka seperti Sastrawi, NTLK, dan library lainnya. Tahapan *preprocessing* dapat dilihat pada Gambar 2.



Gambar 2. *Preprocessing* Data

1. *Case Folding* : Tahapan ini untuk mengubah huruf besar menjadi huruf kecil. Langkah ini dilakukan untuk mencegah kata yang sama muncul berulang kali dan untuk menjaga keseragaman dalam analisis.
2. *Cleaning* : Tahapan ini untuk menghapus data yang tidak relevan dalam penelitian. Elemen seperti emoji dan tanda baca dibuang pada langkah ini.
3. *Tokenizing* : Langkah ini untuk memecah kumpulan teks menjadi bagian-bagian kecil atau kata yang bisa mewakili teks itu. Proses ini membuat analisis isi jadi lebih mudah dan membantu menemukan pola-pola yang tidak biasa.
4. *Normalisasi* : Proses ini bertujuan untuk mengubah kata tidak baku dalam menjadi bentuk baku sesuai ejaan Bahasa Indonesia menggunakan kamus normalisasi (*dictionary-based*).
5. *Stopword* : Langkah ini untuk menghapus kata-kata yang sering muncul tetapi tidak memberikan banyak makna. Kata yang tidak penting biasanya adalah kata sambung atau kata depan.
6. *Stemming* : Langkah ini untuk mengubah menjadi bentuk aslinya. *Stemming* berguna untuk memahami bahwa sebuah kata bisa mempunyai arti dan sentimen serupa meskipun memiliki variasi yang berbeda [19].

2.5. Visualisasi WordCloud

WordCloud merupakan tampilan visual dari sekumpulan kata-kata, dimana ukuran kata itu menunjukkan seberapa sering kata-kata tersebut muncul dalam suatu teks atau kumpulan data. Dalam proses membuat *WordCloud*, kata-kata yang lebih banyak muncul akan terlihat lebih besar, sehingga menciptakan gambaran visual yang menunjukkan kata yang paling sering digunakan dalam konteks tertentu [20].

2.6. Ekstraksi Fitur (TF-IDF)

Pada tahap ini mengekstrak fitur kita akan melihat seberapa penting kata-kata yang ada atau kata kata yang muncul dalam sebuah dokumen [14]. Penilaian bobot kata memberikan skor untuk menentukan *frequency* kemunculan *term* yang kemudian dikalikan dengan *inverse* dari *frequency* dokumennya. Data yang telah diproses diubah ke dalam format numerik menggunakan TF-IDF dimana hasil kali dari frekuensi istilah dalam dokumen (TF) dan tingkat kelangkaan di seluruh dokumen (IDF) [21]. Rumus TF-IDF dijelaskan dalam persamaan (1).

$$w_{i,j} = tf_{i,j} \times \log\left(\frac{N}{df_i}\right) \quad (1)$$

Keterangan :

- $tf_{i,j}$: Jumlah kata i pada dokumen j
- N : Total dokumen
- df_i : Jumlah dokumen mengandung kata ke i

2.7. Pelatihan Model

Beberapa langkah dalam menggunakan Support Vector Machine pada penelitian ini adalah sebagai berikut. Tahap awal dilakukan *train-test split*, yaitu proses pembagian data menjadi dua bagian untuk evaluasi model. Pada penelitian ini digunakan dua skema pembagian data, yaitu 70:30 dan 80:20, di mana sebagian data digunakan sebagai data latih dan sisanya sebagai data uji. Proses pembagian data dilakukan secara *stratified* untuk menjaga proporsi distribusi kelas tetap seimbang antara data latih dan data uji. Model dilatih menggunakan data latih, kemudian diuji menggunakan data uji untuk mengevaluasi kinerja awal klasifikasi SVM. Metrik evaluasi yang digunakan meliputi akurasi, presisi, *recall*, dan *F1-score*.

Selanjutnya dilakukan *hyperparameter tuning* menggunakan metode *GridSearchCV* untuk memperoleh kombinasi parameter terbaik. Parameter yang diuji mencakup nilai C, gamma, dan degree dengan validasi silang sebanyak 5 lipatan (*5-fold cross-validation*). Model SVM diuji menggunakan tiga jenis *kernel*, yaitu *linear*, *Radial Basis Function (RBF)*, dan *polynomial*. Proses optimasi ini bertujuan untuk menemukan konfigurasi *kernel* dan parameter yang menghasilkan performa terbaik pada data pelatihan.

Dalam proses evaluasi, digunakan metrik presisi, recall, dan F1-score dengan pendekatan rata-rata weighted untuk mengakomodasi ketidakseimbangan distribusi kelas pada data. Pendekatan ini dipilih agar evaluasi kinerja model lebih representatif terhadap keseluruhan kelas.

Setelah diperoleh *kernel* terbaik, dilakukan evaluasi dengan dua skema pembagian data (70:30 dan 80:20) untuk menilai stabilitas dan konsistensi model terhadap variasi proporsi data latih dan data uji [6]. Pada tahap evaluasi *hold-out* ini, model dilatih tanpa menerapkan teknik *oversampling*, sehingga kinerja model dapat diuji pada distribusi data asli yang mencerminkan kondisi nyata.

2.8. Evaluasi Model

Tahap evaluasi model dilakukan menggunakan *confusion matrix* untuk menganalisis kinerja klasifikasi secara lebih rinci. *Confusion matrix* menyajikan jumlah prediksi yang benar dan salah pada setiap kelas, sehingga dapat memberikan gambaran performa model dalam mengklasifikasikan data ke dalam kategori yang sesuai [6].

Berdasarkan *confusion matrix*, dihitung beberapa metrik evaluasi, yaitu akurasi, presisi, recall, dan *F1-Score*. Selain itu, evaluasi juga dilengkapi dengan kurva ROC (*Receiver Operating Characteristic*) dan nilai AUC (*Area Under the Curve*) untuk mengukur kemampuan model dalam membedakan antar kelas [14].

$$akurasi = \left(\frac{TP+TN}{TP+TN+FP+FN}\right) * 100 \quad (2)$$

$$presisi = \left(\frac{TP}{TP+FP}\right) * 100 \quad (3)$$

$$recall = \left(\frac{TP}{TP+FN} \right) * 100 \tag{4}$$

$$F1 - score = 2 \left(\frac{recall*precision}{recall+precision} \right) \tag{5}$$

Persamaan (2), (3), (4), dan (5) digunakan untuk menghitung akurasi, presisi, *recall* dan *F1-Score* [18].

Untuk memperoleh evaluasi yang lebih komprehensif, penelitian ini juga menerapkan metode *Stratified K-Fold Cross Validation* dengan 10 lipatan (*10-fold cross-validation*). Untuk mengatasi ketidakseimbangan data, diterapkan teknik *Synthetic Minority Over-sampling Technique* (SMOTE) pada data latih di setiap fold, sehingga model dapat belajar dari distribusi data yang lebih seimbang tanpa menyebabkan *data leakage*. Evaluasi pada tahap ini dilakukan dengan menggunakan metrik *accuracy*, *macro-precision*, *macro-recall*, *macro F1-score*, serta *balanced accuracy*. Pendekatan *macro-average* digunakan untuk memberikan bobot yang sama pada setiap kelas, sehingga performa model terhadap kelas minoritas dapat dievaluasi secara lebih adil. Hasil dari seluruh *fold* kemudian dirata-ratakan untuk memperoleh gambaran performa model secara keseluruhan.

Sebagai tahap akhir, dilakukan analisis visual menggunakan kurva ROC untuk menilai kemampuan model dalam membedakan kelas. Kurva ROC diperoleh dengan menghitung nilai *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) pada berbagai ambang batas klasifikasi, kemudian divisualisasikan dalam grafik dua dimensi dengan FPR pada sumbu X dan TPR pada sumbu Y [6].

3. HASIL DAN PEMBAHASAN

3.1. Pengumpulan Data

Hasil *crawling* yang dikumpulkan sebanyak 1,826 data *tweet* yang berkaitan dengan topik penelitian. Data disimpan dalam format CSV untuk pemrosesan lebih lanjut. Adapun hasil *crawling* dapat dilihat pada Tabel 2.

Tabel 2. Hasil *Crawling* Data

No	Created at	Username	<i>Tweet</i>
1.	30/04/2025 05:02:04	465106464	Dedi mulyadi : siswa bermasalah akan dikirim ke barak militer selama 6 bulan setelah 6 bulan

3.2. Filtering Data

Setelah melalui tahap *cleaning* dan *filtering*, diperoleh 1,000 *tweet* yang relevan untuk dianalisis. Proses penghapusan *duplikat* telah dilakukan, namun tidak ditemukan data yang berulang. Sementara itu, tahap *filtering* mengeliminasi 826 *tweet* yang tidak sesuai dengan topik penelitian. Dataset akhir selanjutnya digunakan untuk pelabelan sentimen dan pemodelan klasifikasi. Adapun hasil *filtering* data dapat dilihat pada Tabel 3.

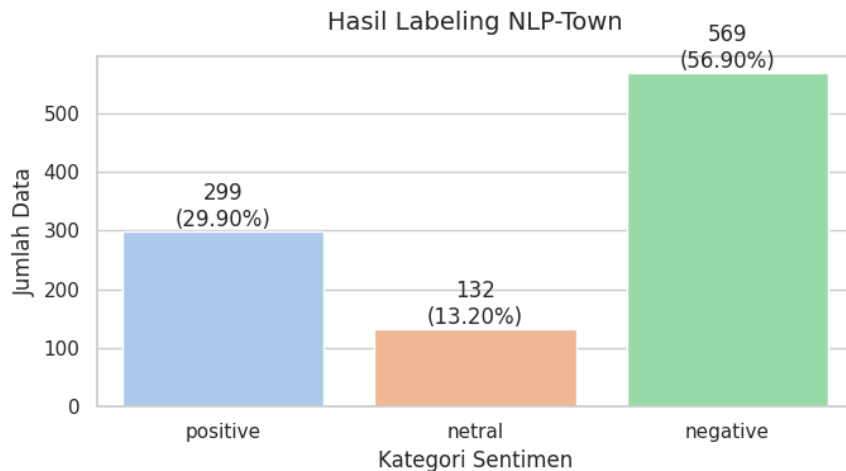
Tabel 3. Hasil *Filtering* Data

Tahap	Jumlah Data
<i>Crawling</i> Awal	1,826
Hapus <i>Duplikat</i>	0
Tidak Relevan	826
Dataset Akhir	1,000

3.3. Pelabelan Data

Sebelum tahap *preprocessing*, dilakukan pelabelan sentimen dengan menggunakan model BERT yang dikembangkan oleh NLP Town. Model ini digunakan untuk mengklasifikasikan data *tweet* secara otomatis ke dalam tiga kategori sentimen, yaitu positif,


netral, dan negatif. Hasil pelabelan otomatis tersebut kemudian digunakan sebagai dasar (*ground truth*) dalam proses pelatihan dan evaluasi model klasifikasi.



Gambar 3. Hasil Label *NLP Town*

Berdasarkan Gambar 3, diketahui bahwa labeling kelas sentimen positif sebanyak 299 data *tweet*, netral sebanyak 132 data *tweet*, dan negatif sebanyak 569 data *tweet*.


Untuk mengevaluasi kualitas label yang dihasilkan oleh model BERT, dilakukan validasi dengan membandingkan hasil pelabelan otomatis dengan anotasi manual terhadap seluruh data yang berjumlah 1000 *tweet* menggunakan metode *stratified sampling*. Hasil evaluasi menunjukkan bahwa tingkat akurasi antara label otomatis dan label manual sebesar 57,30%, dengan nilai *Cohen's Kappa* sebesar 0,35 yang termasuk dalam kategori kesepakatan cukup.



Gambar 4. *Confusion Matrix* Perbandingan Label Manual dan Bert

Berdasarkan confusion matrix pada Gambar 4, sebagian besar kesesuaian label terjadi pada kelas negatif dan positif, sedangkan ketidaksesuaian paling dominan ditemukan pada kelas netral. Hal ini menunjukkan bahwa model BERT lebih stabil dalam mengidentifikasi sentimen dengan

polaritas yang jelas, namun masih mengalami kesulitan dalam mengklasifikasikan teks netral serta cenderung bias ke arah kelas negatif. Kesulitan ini disebabkan oleh karakteristik kelas netral yang ambigu dan tidak memiliki indikator leksikal yang kuat, sehingga representasinya sering tumpang tindih dengan kelas positif maupun negatif. Selain itu, keberadaan kata atau frasa yang mengandung opini implisit atau kritik ringan dalam teks netral dapat mendorong model untuk mengklasifikasikannya sebagai sentimen negatif. Temuan ini mengindikasikan bahwa model lebih sensitif terhadap keberadaan muatan sentimen dibandingkan terhadap kondisi tanpa sentimen, sehingga kelas netral menjadi lebih sulit dipelajari karena tidak memiliki pola linguistik yang konsisten.



Gambar 5. Perbandingan Label Manual dan Bert

Selain itu pada Gambar 5, visualisasi distribusi perbandingan label otomatis dan label manual menunjukkan pola yang relatif serupa, meskipun terdapat perbedaan proporsi pada masing-masing kelas. Kelas negatif terlihat lebih dominan pada hasil pelabelan otomatis, sedangkan kelas netral dan positif lebih banyak muncul pada anotasi manual. Secara keseluruhan, hasil validasi ini menunjukkan bahwa label BERT cukup representatif untuk digunakan sebagai dasar (*ground truth*) dalam pelatihan dan evaluasi model klasifikasi pada penelitian ini.

3.4. Preprocessing Data

Setelah dataset diperoleh, tahap selanjutnya adalah *preprocessing* data yang berisi opini masyarakat terhadap kebijakan Pendidikan Barak Militer Anak yang diinisiasikan oleh Gubernur Jawa Barat Oleh Dedi Mulyadi. *Preprocessing* dilakukan terhadap 1,000 *tweet* yang telah melalui proses *filtering*, meliputi beberapa tahapan yaitu *case folding*, *cleaning*, *tokenizing*, *normalization*, *stopword removal*, dan *stemming*. Hasil *preprocessing* data dapat dilihat pada Tabel 4.

Tabel 4. Hasil *Preprocessing* Data

No.	Tahap	Data <i>Tweet</i>
1	Kalimat Awal	Program KDM (Kang Dedi Mulyadi) memang dirancang untuk remaja bermasalah melalui pelatihan disiplin di barak militer dengan tujuan membangun karakter dan kemandirian. Beberapa laporan menunjukkan hasil positif seperti peningkatan tanggung jawab tapi ada kritik soal potensi.
2	<i>Case Folding</i>	program kdm kang dedi mulyadi memang dirancang untuk remaja bermasalah melalui pelatihan disiplin di barak militer dengan tujuan membangun karakter dan kemandirian beberapa laporan

		menunjukkan hasil positif seperti peningkatan tanggung jawab tapi ada kritik soal potensi
3	<i>Cleaning</i>	program kdm kang dedi mulyadi memang dirancang untuk remaja bermasalah melalui pelatihan disiplin di barak militer dengan tujuan membangun karakter dan kemandirian beberapa laporan menunjukkan hasil positif seperti peningkatan tanggung jawab tapi ada kritik soal potensi
4	<i>Tokenizing</i>	['program', 'kdm', 'kang', 'dedi', 'mulyadi', 'memang', 'dirancang', 'untuk', 'remaja', 'bermasalah', 'melalui', 'pelatihan', 'disiplin', 'di', 'barak', 'militer', 'dengan', 'tujuan', 'membangun', 'karakter', 'dan', 'kemandirian', 'beberapa', 'laporan', 'menunjukkan', 'hasil', 'positif', 'seperti', 'peningkatan', 'tanggung', 'jawab', 'tapi', 'ada', 'kritik', 'soal', 'potensi']
5	<i>Normalization</i>	['program', 'kdm', 'kang', 'dedi', 'mulyadi', 'memang', 'dirancang', 'untuk', 'remaja', 'bermasalah', 'melalui', 'pelatihan', 'disiplin', 'di', 'barak', 'militer', 'dengan', 'tujuan', 'membangun', 'karakter', 'dan', 'kemandirian', 'beberapa', 'laporan', 'menunjukkan', 'hasil', 'positif', 'seperti', 'peningkatan', 'tanggung', 'jawab', 'tapi', 'ada', 'kritik', 'soal', 'potensi']
6	<i>Stopword Removal</i>	['program', 'kdm', 'kang', 'dedi', 'mulyadi', 'memang', 'dirancang', 'remaja', 'bermasalah', 'melalui', 'pelatihan', 'disiplin', 'barak', 'militer', 'tujuan', 'membangun', 'karakter', 'kemandirian', 'beberapa', 'laporan', 'menunjukkan', 'hasil', 'positif', 'peningkatan', 'tanggung', 'jawab', 'kritik', 'soal', 'potensi']
7	<i>Stemming</i>	program kdm kang dedi mulyadi memang rancang remaja masalah lalu latih disiplin barak militer tuju bangun karakter mandiri beberapa lapor tunjuk hasil positif tingkat tanggung jawab kritik soal potensi

Berdasarkan hasil preprocessing pada Tabel 4, setiap tahapan menunjukkan perubahan terhadap struktur teks. Proses normalization berperan dalam mengubah kata tidak baku serta bahasa campuran menjadi bentuk baku, sedangkan stopword removal menghilangkan kata yang tidak memiliki kontribusi signifikan terhadap makna sentimen. Selanjutnya, tahap stemming mengubah kata ke bentuk dasar sehingga dapat meningkatkan konsistensi fitur yang digunakan dalam proses klasifikasi. Hal ini menunjukkan bahwa setiap tahapan preprocessing memberikan kontribusi dalam menghasilkan representasi teks yang lebih baik.


3.5. Visualisasi WordCloud

Setelah tahap *preprocessing*, tahap selanjutnya yaitu visualisasi *wordcloud* untuk menunjukkan seberapa sering kata-kata positif, netral, dan negatif muncul. Adapun visualisasinya dapat dilihat pada Gambar 6, Gambar 7, dan Gambar 8.



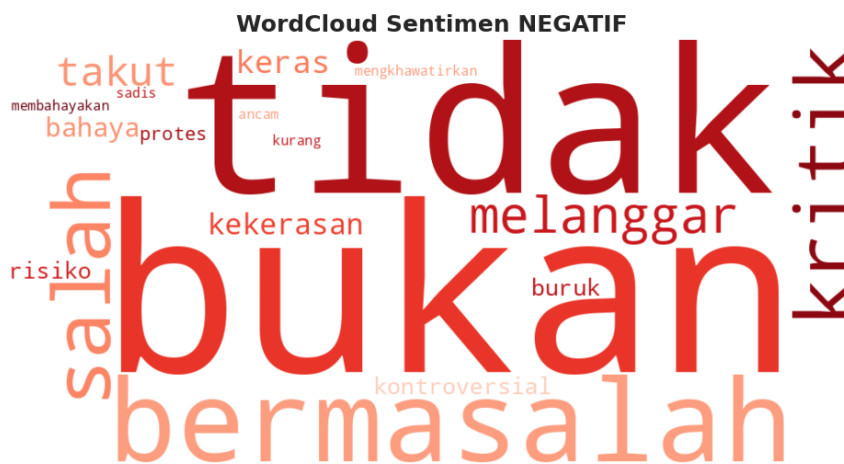
Gambar 6. *WordCloud* Sentimen Positif

Gambar 6 menunjukkan *WordCloud* sentimen positif. Kata-kata seperti “terbaik”, “dukung”, “positif”, “baik”, “tepat” dan “disiplin” muncul paling sering. Ini menunjukkan bahwa komentar positif umumnya memberikan dukungan dan apresiasi program Barak Militer Anak.



Gambar 7. *WordCloud* Sentimen Netral

Gambar 7 menunjukkan *WordCloud* sentimen netral. Kata-kata seperti “program”, “barak”, “militer”, “update”, “pemerintah”, “anak”, dan “info” yang paling dominan. Hal ini mengindikasikan bahwa komentar netral cenderung bersifat informatif dan tidak mengandung kecenderungan emosional yang kuat.



Gambar 8. *WordCloud* Sentimen Negatif

Gambar 8 menunjukkan *WordCloud* sentimen negatif. Kata-kata seperti “tidak”, “bukan”, “kritik”, “kontroversial”, dan “salah” yang mendominasi. Hal ini menunjukkan bahwa komentar negatif umumnya berisi penolakan, kritik, dan kekhawatiran terhadap program tersebut.

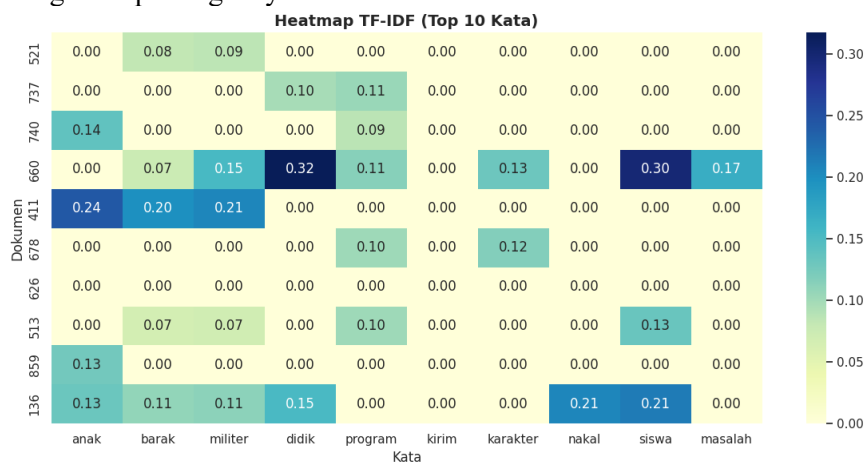
Secara keseluruhan, distribusi sentimen menunjukkan bahwa kelas negatif lebih dominan dibandingkan sentimen positif dan netral. Hal ini mengindikasikan bahwa opini publik cenderung lebih kritis terhadap kebijakan tersebut, khususnya terkait aspek perlindungan anak dan pendekatan yang digunakan. Di sisi lain, sentimen positif mencerminkan dukungan terhadap pembentukan disiplin dan karakter, sedangkan sentimen netral berperan sebagai penyampai informasi.

Temuan ini menunjukkan adanya perbedaan persepsi di kalangan masyarakat, sehingga menghasilkan dinamika opini publik di media sosial. Dengan demikian, analisis sentimen tidak

hanya digunakan untuk mengevaluasi kinerja model, tetapi juga memberikan gambaran empiris mengenai respons masyarakat terhadap kebijakan yang bersifat kontroversial.

3.6. Ekstraksi Fitur

Setelah tahap visualisasi *wordcloud*, dilakukan ekstraksi fitur menggunakan metode *Term Frequency–Inverse Document Frequency* (TF-IDF) untuk memberikan bobot pada setiap kata berdasarkan tingkat kepentingannya dalam dokumen.



Gambar 9. Visualisasi *Heatmap* TF-IDF

Gambar 9 adalah visualisasi *Heatmap* TF-IDF pada 10 dokumen pertama yang menunjukkan distribusi bobot kata. Intensitas warna menunjukkan besarnya nilai TF-IDF pada masing-masing dokumen. Kata-kata seperti “anak”, “barak”, “militer”, dan “didik” memiliki bobot yang relatif tinggi pada beberapa dokumen, yang menandakan tingkat relevansi yang tinggi terhadap topik yang dibahas.

Dalam konteks klasifikasi menggunakan Support Vector Machine (SVM), setiap kata direpresentasikan sebagai fitur dalam ruang vektor, sedangkan nilai TF-IDF menjadi bobot yang menentukan posisi dokumen dalam ruang tersebut. Kata-kata dengan bobot tinggi memiliki kontribusi lebih besar dalam pembentukan hyperplane sebagai batas pemisah antar kelas. Sebaliknya, kata-kata yang bersifat umum dan muncul di berbagai kelas cenderung memiliki daya diskriminatif yang lebih rendah dalam proses klasifikasi.

3.7. Pelatihan Model

Pada tahap pemilihan model, dilakukan pengujian tiga *kernel* menggunakan *GridSearchCV*, yaitu Linear, RBF, dan Polynomial dengan dua skenario pembagian data yaitu 70:30 dan 80:20. Berdasarkan hasil pengujian, *kernel Linear* menunjukkan performa terbaik dibandingkan *kernel* lainnya. Oleh karena itu, *kernel Linear* dipilih sebagai model terbaik karena lebih stabil dan sesuai untuk data teks berdimensi tinggi. Hasil dari pengujian ini dapat dilihat pada Tabel 5.

Tabel 5. Hasil uji 3 *kernel*

No.	<i>Kernel</i>	Best Params	Best Score	Akurasi (%)	Presisi (%)	<i>Recall</i> (%)
1	Linear	{‘C’: 1}	0,55190	71,0	66,68	71,0
2	RBF	{‘C’: 10, ‘gamma’: 0,1}	0,52837	70,0	64,58	70,0
3	Polynomial	{‘C’: 1, ‘degree’: 3}	0,24753	57,0	32,49	57,0

Selanjutnya, dilakukan analisis terhadap dua skenario pembagian data untuk melihat proporsi data terhadap kinerja model. Hasil menunjukkan bahwa rasio 80:20 memberikan

performa yang sedikit lebih baik dibandingkan 70:30. Oleh karena itu, rasio 80:20 dipilih untuk tahap evaluasi selanjutnya. Hasil perbandingan kedua rasio data dapat dilihat pada Tabel 6.

Tabel 6. Hasil Uji Rasio Data

Rasio Data	Akurasi (%)	Presisi (%)	Recall (%)
70 : 30	70,66	68,08	70,66
80 : 20	71,0	66,68	71,0

3.8. Evaluasi Model


Berdasarkan hasil pemilihan model, kernel Linear dipilih sebagai model akhir karena menunjukkan performa terbaik serta memiliki kompleksitas yang lebih sederhana untuk klasifikasi teks berbasis TF-IDF.

Setelah model terbaik ditentukan, tahap selanjutnya adalah evaluasi model yang terdiri dari tiga proses, yaitu evaluasi model terbaik (*hold-out*), *10-fold cross-validation*, dan analisis visual menggunakan *kurva ROC*.

Pada tahap evaluasi model terbaik (*hold-out*), model SVM dengan *kernel Linear* diuji menggunakan parameter $C = 1$ dengan pembagian data latih dan data uji sebesar 80:20. Hasil pengujian ini bisa dilihat pada Tabel 7.

Tabel 7. Hasil Evaluasi Model Terbaik

Data Latih	Data Uji	Akurasi (%)	Presisi (%)	Recall (%)
800	200	71,0	66,68	71,0



Gambar 10. Confusion Matrix

Berdasarkan Gambar 10, sebagian besar data berhasil diklasifikasikan dengan benar. Performa terbaik terlihat pada kelas sentimen negatif, sedangkan kesalahan klasifikasi paling banyak terjadi pada kelas netral. Hal ini menunjukkan bahwa model mampu membedakan

sentimen positif dan negatif dengan baik, namun masih mengalami kesulitan dalam mengidentifikasi sentimen netral secara konsisten.

Meskipun nilai akurasi *hold-out* cukup tinggi, evaluasi ini masih bergantung pada satu skenario pembagian data sehingga belum sepenuhnya mencerminkan kemampuan generalisasi model. Untuk memperoleh evaluasi yang lebih robust, dilakukan *10-fold cross-validation* yang dapat dilihat pada Tabel 8.

Tabel 8. *10-fold cross-validation*

<i>Fold</i>	Akurasi (%)	Presisi (%)	<i>Recall</i> (%)	<i>F1-Score</i> (%)
1	72,00	67,71	57,52	59,52
2	68,00	55,49	54,25	54,16
3	66,00	56,42	52,03	52,32
4	70,00	61,67	59,91	60,57
5	68,00	59,61	59,14	59,20
6	77,00	71,23	67,43	68,95
7	69,00	56,08	54,84	55,16
8	68,00	53,00	51,75	51,76
9	70,00	57,14	56,49	56,76
10	71,00	60,88	60,24	60,49

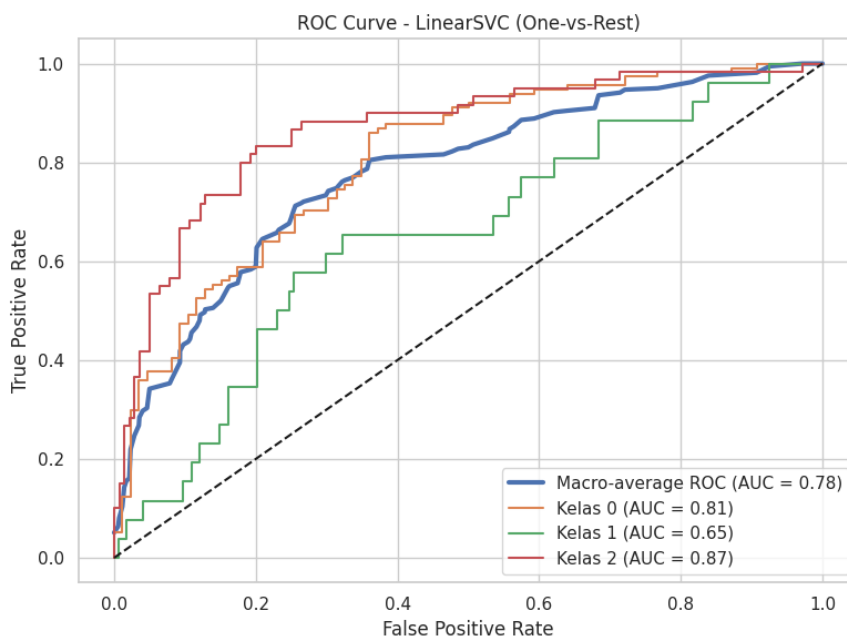
Berdasarkan pengujian tersebut, diperoleh rata-rata akurasi sebesar $69,90\% \pm 3,03\%$, presisi (*macro*) $59,92\% \pm 5,72\%$, *recall* (*macro*) $57,36\% \pm 4,67\%$, dan *F1-Score* (*macro*) $57,89\% \pm 5,08\%$. Nilai *balanced accuracy* sebesar $57,36\% \pm 4,67\%$. Jika dibandingkan dengan hasil *hold-out*, terlihat adanya sedikit penurunan performa pada tahap *10-fold cross-validation*. Hal ini menunjukkan bahwa evaluasi berbasis *hold-out* cenderung lebih optimistis, sedangkan *10-fold cross-validation* memberikan gambaran yang lebih realistis terhadap kemampuan generalisasi model. Nilai standar deviasi yang relatif kecil menunjukkan bahwa performa model cukup stabil pada setiap fold.

Tabel 9. Rata Rata Per Class Metrics (*10-fold cross-validation*)

Kelas	<i>Precision</i> (%)	<i>Recall</i> (%)	<i>F1-Score</i> (%)
Negatif	76,31	83,30	79,60
Netral	35,48	24,23	27,94
Positif	67,98	64,54	66,12

Berdasarkan Tabel 9, model menunjukkan performa terbaik pada kelas sentimen negatif dengan nilai *precision* 76,31%, *recall* 83,30%, dan *F1-score* 79,60%. Kelas sentimen positif menunjukkan performa moderat dengan *F1-score* sebesar 66,12%, sedangkan kelas netral memiliki performa terendah dengan *F1-score* sebesar 27,94%. Rendahnya performa pada kelas netral menunjukkan bahwa model masih kesulitan membedakan sentimen netral dari sentimen positif dan negatif. Meskipun teknik SMOTE telah diterapkan, pendekatan ini hanya menambah jumlah data secara sintetik tanpa meningkatkan variasi makna secara signifikan.

Secara linguistik, sentimen netral cenderung tidak memiliki kata dengan polaritas emosional yang kuat. Dalam representasi TF-IDF, kata-kata yang bersifat informatif seperti “program” atau “kegiatan” memiliki daya diskriminatif yang rendah karena muncul di berbagai kelas. Hal ini menyebabkan model SVM kesulitan membentuk hyperplane yang mampu memisahkan kelas netral secara jelas. Selain itu, dalam ruang fitur berdimensi tinggi, kelas netral cenderung berada di antara kelas positif dan negatif, sehingga sering terklasifikasi ke salah satu dari kedua kelas tersebut. Keterbatasan TF-IDF yang tidak mempertimbangkan konteks juga menjadi faktor yang menyebabkan kesalahan klasifikasi pada data netral.



Gambar 11. ROC Curve

Selanjutnya, pada tahap analisis kurva ROC yang terlihat pada Gambar 11, diperoleh nilai AUC *macro-average* sebesar 0,78, yang menunjukkan bahwa model memiliki kemampuan klasifikasi yang cukup baik. Secara per kelas, nilai AUC tertinggi terdapat pada kelas sentimen positif sebesar 0,87, diikuti kelas negatif sebesar 0,81, sedangkan kelas netral sebesar 0,65. Rendahnya nilai AUC pada kelas netral sejalan dengan hasil evaluasi sebelumnya yang menunjukkan bahwa model masih kesulitan dalam mengidentifikasi sentimen netral secara konsisten.

4. KESIMPULAN

Penelitian ini bertujuan untuk mengklasifikasikan sentimen publik terhadap program Barak Militer Anak yang diinisiasi oleh Dedi Mulyadi menggunakan algoritma Support Vector Machine (SVM) berdasarkan data X. Dari 1.000 *tweet* yang dianalisis, hasil pelabelan BERT NLP Town menunjukkan bahwa sentimen negatif mendominasi opini publik, diikuti oleh sentimen positif dan netral. Untuk memastikan kualitas label otomatis tersebut, dilakukan validasi melalui anotasi manual terhadap seluruh data. Hasil validasi menunjukkan tingkat akurasi sebesar 57,30% dengan nilai *Cohen's Kappa* sebesar 0,35 yang termasuk dalam kategori kesepakatan cukup, sehingga menunjukkan adanya perbedaan persepsi dalam penentuan label sentimen.

Berdasarkan hasil evaluasi, model SVM dengan *kernel linear* pada evaluasi model terbaik (*hold-out*) menghasilkan akurasi sebesar 71,0%. Namun, evaluasi menggunakan *10-fold cross-validation* memberikan estimasi performa yang lebih representatif dengan rata-rata akurasi sebesar 69,90% ± 3,03%, *macro F1-Score* sebesar 57,89% ± 5,08%, dan *balanced accuracy* sebesar 57,36% ± 4,67%. Hasil ini menunjukkan bahwa performa model berada pada kategori cukup baik dan belum merata pada seluruh kelas, terutama pada kelas netral yang memiliki nilai *recall* dan *F1-Score* lebih rendah dibandingkan kelas lainnya. Oleh karena itu, hasil *cross-validation* dijadikan indikator utama performa model.

Secara keseluruhan, kombinasi pelabelan BERT NLP Town, pembobotan TF-IDF, dan algoritma SVM mampu memberikan gambaran awal mengenai sentimen publik terhadap kebijakan tersebut. Meskipun demikian, model masih memerlukan pengembangan lebih lanjut untuk meningkatkan stabilitas dan kemampuan generalisasi, khususnya dalam menangani ketidakseimbangan distribusi kelas dan meningkatkan akurasi pada kelas netral.

DAFTAR PUSTAKA

- [1] N. L. Tantri, “Analisis Sentimen Pengguna Twitter Terhadap Kebijakan Gubernur Jawa Barat terkait Barak Militer menggunakan Natural Language Processing (NLP),” no. May, 2025.
- [2] J. J. Hidayat *et al.*, “Deep Learning-based Sentiment Analysis of Public Comments on Military Education Using RoBERTa Algorithm and Rule-Based Hybrid Parameters,” *J. Media Comput. Sci.*, vol. 4, no. 2, pp. 277–292, 2025, [Online]. Available: <https://jurnal.unived.ac.id/index.php/jmcs/article/view/8769>
- [3] T. Safitri, Y. Umaidah, and I. Maulana, “Analisis Sentimen Pengguna Twitter Terhadap Grup Musik BTS Menggunakan Algoritma Support Vector Machine,” *J. Appl. Informatics Comput.*, vol. 7, no. 1, pp. 28–35, 2023, doi: 10.30871/jaic.v7i1.5039.
- [4] F. D. Prastyo and S. Mulyati, “ANALISIS SENTIMEN TWITTER TERHADAP KEBIJAKAN ANAK MASUK BARAK MILITER DENGAN NAÏVE BAYES,” vol. 4, no. September, pp. 408–415, 2025.
- [5] A. Z. R. Tsani and U. Budiyanto, “ANALISIS SENTIMEN PUBLIK TERHADAP KEBIJAKAN PENGIRIMAN SISWA KE BARAK MILITER MENGGUNAKAN SUPPORT VECTOR MACHINE,” *Semin. Nas. Mhs. Fak. Teknol. Inf.*, vol. 4, no. September, pp. 261–268, 2025.
- [6] I. Sari B, F. Wajidi, and M. R. Rasyid, “Implementasi Support Vector Machine Untuk Analisis Sentimen Robot Polisi Humanoid,” *Simtek J. Sist. Inf. dan Tek. Komput.*, vol. 10, no. 2, pp. 329–335, 2025, doi: 10.51876/simtek.v10i2.1623.
- [7] H. C. Husada and A. S. Paramita, “Analisis Sentimen Pada Maskapai Penerbangan di Platform Twitter Menggunakan Algoritma Support Vector Machine (SVM),” *Teknika*, vol. 10, no. 1, pp. 18–26, 2021, doi: 10.34148/teknika.v10i1.311.
- [8] O. I. Gifari, M. Adha, F. Freddy, and F. F. S. Durrand, “Film Review Sentiment Analysis Using TF-IDF and Support Vector Machine,” *J. Inf. Technol.*, vol. 2, no. 1, pp. 36–40, 2022.
- [9] W. Ningsih, B. Alfianda, R. Rahmaddeni, and D. Wulandari, “Perbandingan Algoritma SVM dan Naïve Bayes dalam Analisis Sentimen Twitter pada Penggunaan Mobil Listrik di Indonesia,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 2, pp. 556–562, 2024, doi: 10.57152/malcom.v4i2.1253.
- [10] F. Sirait, D. Irpan, R. Fadillah, R. Rizalina, and R. S. Damanik, “Sentiment Analysis on Twitter Social Media towards Najwa Shihab Using Naïve Bayes Algorithm and Support Vector Machine (SVM),” *Int. J. Heal. Eng. Technol.*, vol. 3, no. 1, pp. 287–293, 2025, doi: 10.55227/ijhet.v3i1.280.
- [11] I. Syahrohim, S. D. Saputra, and R. W. Saputra, “PERBANDINGAN ANALISIS SENTIMEN SETELAH PILPRES 2024 DI TWITTER MENGGUNAKAN ALGORITMA MACHINE LEARNING,” vol. 12, no. 2, 2024.
- [12] M. R. Ramli, H. Sulastri, and R. Rianto, “Sentiment Analysis Of Student Opinion Related To Online Learning Using Naïve Bayes Classifier Algorithm And SVM With Adaboost On Twitter Social Media,” *J. Inform. dan Teknol. Inf.*, vol. 20, no. 2, pp. 187–201, 2023, doi: 10.31515/telematika.v20i2.8827.
- [13] A. Amelia and R. Yusuf, “ANALISIS SENTIMEN MASYARAKAT INDONESIA PADA PLATFROM X TERHADAP ISU FUFUFAFA MENGGUNAKAN BIDIRECTIONAL ENCODER REPRESENTATIONS FROM TRANSFORMERS,” *J. Inform. Teknol. dan Sains*, vol. 7, no. 1, pp. 72–80, 2025.
- [14] S. Ernawati and R. Wati, “Evaluasi Performa Kernel SVM dalam Analisis Sentimen Review Aplikasi ChatGPT Menggunakan Hyperparameter dan VADER Lexicon,” *J. Buana Inform.*, vol. 15, no. 01, pp. 40–49, 2024, doi: 10.24002/jbi.v15i1.7925.
- [15] N. A. Wahyuni, D. P. Ayu, and H. Irsyad, “Analisis Sentimen di Youtube Terhadap

- Kenaikan UKT Menggunakan Metode Support Vector Machine,” *Arcitech J. Comput. Sci. Artif. Intell.*, vol. 4, no. 1, p. 57, 2024, doi: 10.29240/arcitech.v4i1.10829.
- [16] R. D. Ramadhan and F. Arifin, “Komparasi Beberapa Algoritma Machine Learning untuk Klasifikasi Sentimen Pengguna X (Twitter) Terkait Isu Kabur Aja Dulu,” vol. 3, no. 2, pp. 81–90, 2025.
- [17] M. I. Amal, E. S. Rahmasita, E. Suryaputra, and N. A. Rakhmawati, “Analisis Klasifikasi Sentimen Terhadap Isu Kebocoran Data Kartu Identitas Ponsel di Twitter,” *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. September, pp. 645–660, 2022.
- [18] J. Emarapenta Br Sinulingga and H. Cesar Kayika Sitorus, “Analisis Sentimen Masyarakat terhadap Film Horor Indonesia Menggunakan Metode SVM dan TF-IDF,” vol. 14, no. April, pp. 42–53, 2024.
- [19] H. Firda, P. Putra, N. R. Oktadini, and P. E. Sevtiyuni, “Perbandingan Pelabelan Rating-based dan Inset Lexicon-based dalam Analisis Sentimen Menggunakan SVM (Studi Kasus: Ulasan Aplikasi GoBiz di Google Play Store),” *Sist. J. Sist. Inf.*, vol. 14, pp. 516–528, 2025, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [20] J. A. Wibowo, V. C. Mawardi, and T. Sutrisno, “Visualisasi Word Cloud Hasil Analisis Sentimen Berbasis Fitur Layanan Aplikasi Gojek Dengan Support Vector Machine,” *J. Serina Sains, Tek. dan Kedokt.*, vol. 2, no. 1, pp. 61–70, 2024, doi: 10.24912/jsstk.v2i1.32058.
- [21] H. W. Raff and F. Ratnawati, “Klasifikasi Sentimen Ulasan Pengguna terhadap Aplikasi Video Editing Play Store Menggunakan Random Forest,” *Techno.Com*, vol. 24, no. 3, pp. 646–657, 2025, doi: 10.62411/tc.v24i3.12873.