

KLASIFIKASI SENTIMEN MASYARAKAT TERHADAP KASUS TUNTUTAN 17+8 MENGUNAKAN *NAÏVE BAYES CLASSIFIER*

Arif Kurniawan¹, Muhammad Fikry², Novi Yanti³, Surya Agustian⁴

^{1,2,3,4} Teknik Informatika, Sains dan Teknologi, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia

¹ 12050116444@students.uin-suska.ac.id, ² muhammad.fikry@uin-suska.ac.id, ³ novi_yanti@uin-suska.ac.id, ⁴ sagustian@uin-suska.ac.id

ABSTRACT – The rapid growth of social media has encouraged the emergence of diverse public opinions on various public issues, including the 17+8 Demands case, which has attracted widespread attention in Indonesia. Sentiment analysis serves as an important approach for systematically identifying public opinion trends. However, social media text data are generally unstructured and contain various forms of noise, requiring appropriate preprocessing techniques before classification can be performed. This study aims to analyze public sentiment toward the 17+8 Demands case using the Naïve Bayes Classifier method and to evaluate the impact of preprocessing stages on model performance through an ablation study approach. The research data consisted of TikTok comments processed through several preprocessing stages, including case folding, normalization, stopword removal, and stemming. Subsequently, text features were extracted using the TF-IDF weighting method and classified using the Multinomial Naïve Bayes algorithm. The results indicate that each preprocessing combination produces different classification performances. On the additional dataset consisting of 8,370 comments, the best performance was achieved using the combination of case folding and normalization, resulting in an accuracy of 89.87% and an F1-score of 91.89%. Meanwhile, on the primary dataset consisting of 1,525 comments, the best performance was obtained using the combination of normalization and stopword removal, achieving an accuracy of 81.20% and an F1-score of 80.31%. Evaluation using a confusion matrix demonstrated that the model performed well in sentiment classification, particularly for the positive sentiment class. These findings indicate that selecting appropriate preprocessing techniques plays a significant role in improving sentiment classification performance when using the Naïve Bayes Classifier method.

Keywords: Naïve Bayes Classifier; 17+8 demands; Sentiment analysis.

ABSTRAK – Perkembangan media sosial telah mendorong munculnya berbagai opini masyarakat terhadap isu-isu publik, termasuk kasus Tuntutan 17+8 yang menjadi perhatian luas di Indonesia. Analisis sentimen menjadi pendekatan yang penting untuk mengidentifikasi kecenderungan opini masyarakat secara sistematis. Namun, data teks pada media sosial umumnya bersifat tidak terstruktur dan mengandung berbagai *noise* sehingga memerlukan tahapan *preprocessing* yang tepat sebelum dilakukan klasifikasi. Penelitian ini bertujuan untuk menganalisis sentimen masyarakat terhadap kasus Tuntutan 17+8 menggunakan metode Naïve Bayes Classifier serta mengevaluasi pengaruh tahapan *preprocessing* terhadap performa model melalui pendekatan *ablation study*. Data penelitian berupa komentar TikTok yang diproses melalui tahapan *preprocessing* meliputi *case folding*, normalisasi, *stopword removal*, dan *stemming*. Selanjutnya, fitur teks diekstraksi menggunakan TF-IDF dan diklasifikasikan menggunakan algoritma Multinomial Naïve Bayes. Hasil penelitian menunjukkan bahwa setiap kombinasi *preprocessing* memberikan pengaruh yang berbeda terhadap performa model. Pada dataset tambahan sebanyak 8.370 komentar, performa terbaik diperoleh pada kombinasi *case folding* dan normalisasi dengan akurasi 89,87% dan *F1-score* 91,89%. Sementara itu, pada dataset utama sebanyak 1.525 komentar, performa terbaik diperoleh pada kombinasi normalisasi dan *stopword removal* dengan akurasi 81,20% dan *F1-score* 80,31%. Hasil evaluasi menggunakan *confusion matrix* menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik, terutama pada kelas sentimen positif. Penelitian ini membuktikan bahwa pemilihan tahapan *preprocessing* yang tepat berperan penting dalam meningkatkan performa klasifikasi sentimen menggunakan Naïve Bayes Classifier.

Kata Kunci: Analisis sentimen, Naïve Bayes Classifier, tuntutan 17+8

1. PENDAHULUAN

Dalam dinamika kehidupan demokrasi, partisipasi masyarakat menjadi elemen penting dalam mengawasi jalannya pemerintahan serta menyampaikan aspirasi

publik terhadap kebijakan negara. Salah satu wujud partisipasi masyarakat dapat diamati melalui demonstrasi yang mencerminkan penilaian publik terhadap kinerja



pemerintah. Demonstrasi besar yang terjadi pada Agustus 2025 mencerminkan meningkatnya tekanan publik terhadap pemerintah dan lembaga legislatif di Indonesia. Aksi ini melibatkan berbagai elemen masyarakat, seperti mahasiswa, buruh, dan organisasi masyarakat sipil, yang menyuarakan ketidakpuasan terhadap kinerja institusi publik serta arah kebijakan nasional[1]. Dari gelombang demonstrasi tersebut muncul tuntutan 17+8, yakni serangkaian rekomendasi kebijakan jangka pendek dan menengah yang dirumuskan sebagai respons kolektif terhadap permasalahan tata kelola pemerintahan, keadilan sosial, dan akuntabilitas institusi negara. Berbeda dengan demonstrasi sebelumnya yang cenderung terpisah dan berfokus pada isu tertentu, tuntutan 17+8 disusun secara sistematis dan lintas sektor dalam bentuk agenda kebijakan yang terorganisasi[2].

Penamaan “17+8” mencerminkan artikulasi kolektif yang terdokumentasi dengan baik, sehingga menyerupai alternatif kebijakan yang diajukan masyarakat kepada negara. Luasnya cakupan isu, mulai dari reformasi legislatif, supremasi sipil, kebijakan ekonomi dan perpajakan, hingga reformasi aparat penegak hukum, menuntut pemerintah dan DPR untuk memberikan respons yang tidak lagi parsial, melainkan terintegrasi lintas lembaga. Hal ini menjadikan tuntutan 17+8 sebagai fenomena yang unik dalam dinamika tekanan publik di Indonesia karena menggabungkan mobilisasi massa dengan perumusan agenda kebijakan yang terstruktur dan berorientasi pada perubahan[2].

Seiring dengan kompleksitas tuntutan tersebut, penting untuk memahami bagaimana respons dan persepsi masyarakat terhadap fenomena tuntutan 17+8 berkembang di ruang publik. Analisis sentimen menjadi salah satu pendekatan yang relevan untuk mengidentifikasi kecenderungan opini publik, baik yang bersifat mendukung, menolak, maupun netral. Pemahaman terhadap distribusi sentimen ini tidak hanya memberikan gambaran mengenai sikap masyarakat, tetapi juga mencerminkan tingkat kepercayaan publik terhadap pemerintah serta harapan terhadap reformasi kebijakan yang diusulkan, khususnya terkait transparansi anggaran dan penegakan hukum. Dengan demikian, analisis sentimen memiliki peran strategis dalam menyediakan data empiris yang dapat digunakan sebagai dasar pengambilan kebijakan yang lebih responsif dan akuntabel.

Perkembangan teknologi digital yang pesat telah mengubah pola komunikasi masyarakat, di mana media sosial menjadi sarana utama dalam menyampaikan opini dan pandangan terhadap berbagai isu sosial maupun politik. Salah satu platform yang memiliki tingkat interaksi tinggi adalah TikTok, yang memungkinkan pengguna untuk berpartisipasi aktif melalui komentar, tanggapan, dan diskusi terbuka. Aktivitas ini mencerminkan dinamika opini publik yang dapat diolah menjadi sumber data dalam penelitian analisis sentimen. Komentar-komentar yang muncul di TikTok dapat dianggap sebagai representasi suara masyarakat yang beragam, sehingga sangat potensial digunakan untuk mengidentifikasi pola persepsi publik terhadap isu

tuntutan 17+8 yang sedang berkembang. Oleh sebab itu, diperlukan suatu metode yang mampu mengelompokkan dan mengklasifikasikan sentimen tersebut secara sistematis dan akurat.

Metode Naïve Bayes Classifier dipilih dalam penelitian ini karena memiliki keunggulan dalam hal kesederhanaan algoritma, efisiensi perhitungan, serta kemampuan dalam mengolah data teks dalam jumlah besar[3]. Metode ini menggunakan pendekatan probabilistik dengan asumsi independensi antar fitur, sehingga sangat sesuai untuk diterapkan pada analisis sentimen berbasis teks yang kompleks[4]. Selain itu, berbagai penelitian terdahulu menyatakan bahwa metode ini memiliki tingkat akurasi yang tinggi dan performa yang stabil dalam berbagai konteks analisis sentimen[5].

Penelitian dengan judul Analisis Sentimen Ulasan Instagram di Google Play Store menggunakan Algoritma Naïve Bayes dimana penelitian tersebut menunjukkan performa yang stabil dengan akurasi 89% [6] dalam menganalisis ulasan TikTok. Selain itu, penelitian Klasifikasi Sentimen Masyarakat terhadap Kebijakan Kartu Prakerja di Indonesia yang mana penelitian tersebut memperoleh akurasi 91,06% [7] pada analisis kebijakan Kartu Prakerja. Penelitian lain yaitu Klasifikasi Sentimen Persepsi Masyarakat di Instagram terhadap Paslon Pilpres 2024 Menggunakan Naïve Bayes Classifier (NBC) penelitian tersebut menghasilkan akurasi 82% [8] dalam analisis persepsi masyarakat terhadap pasangan calon presiden. Hasil-hasil tersebut memperkuat bahwa metode Naïve Bayes Classifier merupakan pendekatan yang efektif dan reliabel dalam mengklasifikasikan opini publik, meskipun masih memiliki keterbatasan seperti ketidakseimbangan data dan keterbatasan sumber data.

Berdasarkan uraian tersebut, penelitian ini penting dilakukan untuk mengklasifikasikan sentimen masyarakat terhadap tuntutan 17+8 dengan memanfaatkan data komentar pada platform TikTok. Penelitian ini diharapkan mampu memberikan gambaran yang objektif mengenai kecenderungan opini publik serta menjadi dasar dalam memahami respons masyarakat terhadap isu kebijakan nasional yang kompleks. Selain itu, hasil penelitian ini juga diharapkan dapat memberikan kontribusi dalam pengembangan metode analisis sentimen berbasis media sosial serta mendukung pengambilan kebijakan yang lebih adaptif, partisipatif, dan berbasis data di era digital.

Kontribusi utama penelitian ini terletak pada penerapan *ablation study* untuk mengevaluasi kontribusi masing-masing tahapan *text preprocessing* terhadap performa klasifikasi sentimen pada kasus Tuntutan 17+8. Analisis ini penting karena belum diketahui secara pasti kombinasi *preprocessing* yang paling efektif untuk menangani karakteristik komentar TikTok yang bersifat tidak terstruktur. Dengan demikian, penelitian ini tidak hanya menghasilkan klasifikasi sentimen masyarakat, tetapi juga memberikan rekomendasi empiris mengenai strategi *preprocessing* yang optimal untuk meningkatkan kinerja model Multinomial Naïve Bayes.

2. DASAR TEORI

A. Klasifikasi Sentimen

Klasifikasi sentimen dapat diartikan sebagai metode analisis teks yang bertujuan untuk mendeteksi kecenderungan opini atau respons yang terdapat dalam suatu kalimat, lalu mengelompokkannya ke dalam beberapa kategori sentimen, seperti positif, negatif, ataupun netral [9]. Teknik ini menjadi bagian penting dalam bidang *Natural Language Processing* (NLP) karena mampu mengekstraksi informasi subjektif dari data teks yang tidak terstruktur, seperti komentar, ulasan, maupun unggahan di media sosial[10]. Dengan adanya klasifikasi sentimen, peneliti dapat memahami kecenderungan opini publik terhadap suatu isu secara lebih sistematis dan terukur. Selain itu, hasil klasifikasi ini juga dapat digunakan sebagai dasar dalam pengambilan keputusan, evaluasi kebijakan, serta analisis perilaku masyarakat di era digital.

B. Text Mining

Text mining adalah teknik yang digunakan untuk mengekstraksi informasi dan pengetahuan dari kumpulan data teks yang bersifat tidak terstruktur atau semi-terstruktur. Proses ini melibatkan serangkaian tahapan analisis untuk menemukan pola, hubungan, serta informasi penting yang tersembunyi dalam teks. Dalam konteks penelitian, *text mining* berperan sebagai dasar dalam pengolahan data teks sebelum dilakukan proses klasifikasi[11]. Teknik ini banyak digunakan untuk berbagai tujuan, seperti klasifikasi dokumen, pengelompokan teks, serta analisis sentimen[12]. Dengan memanfaatkan *text mining*, data teks yang awalnya sulit dipahami dapat diolah menjadi informasi yang lebih terstruktur dan bermakna, sehingga memudahkan proses analisis lebih lanjut.

C. TF-IDF (*Term Frequency–Inverse Document Frequency*)

TF-IDF adalah teknik pemberian bobot pada kata yang digunakan untuk menilai seberapa penting suatu istilah dalam sebuah dokumen dibandingkan dengan keseluruhan kumpulan dokumen lainnya [13]. Pendekatan ini dibangun dari dua unsur utama, yakni *Term Frequency* (TF) yang menunjukkan seberapa sering suatu kata muncul pada sebuah dokumen, serta *Inverse Document Frequency* (IDF) yang menggambarkan tingkat keunikan atau kelangkaan kata tersebut di antara seluruh dokumen yang dianalisis [14]. Kombinasi keduanya menghasilkan bobot yang menunjukkan seberapa relevan suatu kata dalam merepresentasikan isi dokumen. Pada proses analisis sentimen, TF-IDF dimanfaatkan sebagai teknik ekstraksi fitur yang mengonversi kumpulan kata pada teks menjadi representasi angka berdasarkan tingkat kepentingannya, sehingga data tersebut dapat diproses oleh model *machine learning* [15]. Penggunaan metode ini terbukti efektif dalam meningkatkan akurasi model

klasifikasi karena mampu menyoroti kata-kata yang memiliki kontribusi penting terhadap makna teks.

Rumus TF-IDF:

$$TF(t, d) = \frac{N(t, d)}{T} \quad 1$$

Pada rumus ini TF (t,d) menunjukkan tingkat kemunculan istilah t dalam dokumen d. Nilai N (t,d) menggambarkan frekuensi istilah t muncul di dalam dokumen tersebut, sedangkan T menunjukkan jumlah keseluruhan istilah yang terdapat pada dokumen[16]. Dengan demikian, setiap kombinasi antara dokumen dan kata memiliki nilai TF (t,d) yang berbeda-beda.

$$IDF(t) = \frac{\log N}{N(t)} \quad 2$$

Rumus tersebut menggambarkan cara menghitung IDF (t), yaitu nilai yang merepresentasikan seberapa jarang istilah t muncul dalam keseluruhan kumpulan dokumen. Pada konteks ini, N menunjukkan jumlah total dokumen, sementara N(t) mengindikasikan jumlah dokumen yang mengandung istilah t.

$$TF - IDF = TF \times IDF \quad 3$$

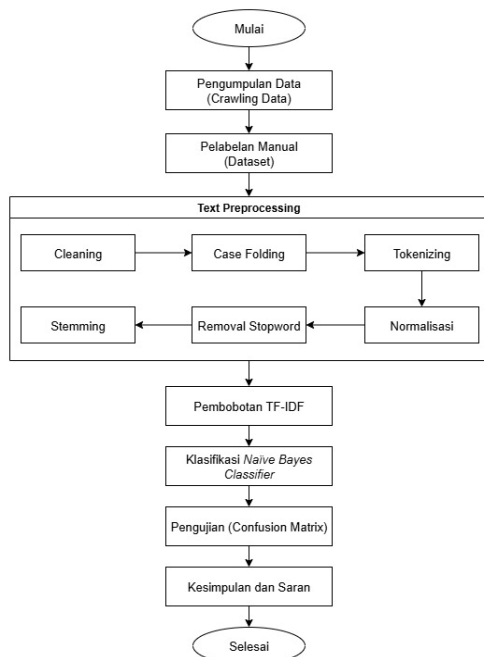
Untuk nilai TF-IDF diperoleh dengan mengalikan hasil perhitungan dari TF dan IDF setelah masing-masing nilai frekuensinya ditentukan.

D. Naïve Bayes Classifier

Naïve Bayes Classifier merupakan salah satu algoritma klasifikasi berbasis probabilitas yang menggunakan teorema Bayes sebagai dasar perhitungannya. Metode ini bekerja dengan memprediksi kemungkinan suatu data termasuk ke dalam kelas tertentu berdasarkan karakteristik fiturnya, dengan asumsi bahwa setiap fitur bersifat independen satu sama lain[11]. Meskipun asumsi tersebut tergolong sederhana, Naïve Bayes Classifier memiliki kemampuan yang baik dalam klasifikasi teks, terutama pada data berukuran besar[17]. Keunggulan utama metode ini terletak pada kemudahan implementasi, efisiensi komputasi, serta kemampuannya dalam menghasilkan akurasi yang cukup tinggi[18]. Oleh karena itu, algoritma ini banyak digunakan dalam penelitian analisis sentimen untuk mengklasifikasikan opini masyarakat secara cepat dan efektif.

3. METODOLOGI

Pada penelitian ini, proses pelaksanaan dilakukan melalui beberapa tahapan yang dirancang secara sistematis agar tujuan penelitian dapat tercapai dengan optimal. Setiap tahapan disusun berdasarkan urutan logis yang menggambarkan alur kegiatan penelitian dari awal hingga akhir. Tahapan metodologi penelitian tersebut dapat dilihat pada Gambar 1.



Gambar 1. Desain Penelitian

A. Pengumpulan Data

Data pada penelitian ini dikumpulkan dengan mengambil komentar dari platform TikTok menggunakan Apify Client. Komentar yang berhasil diperoleh selanjutnya diekspor dan disimpan dalam format .xlsx guna mendukung proses analisis pada tahap selanjutnya [19].

Sumber data dalam penelitian ini berasal dari unggahan akun media sosial @kompas.com yang telah terverifikasi, khususnya konten yang memuat pembahasan mengenai Kasus Tuntutan 17+8. Pemilihan sumber data tersebut dilakukan karena akun tersebut merupakan media yang memiliki kredibilitas tinggi dan jangkauan audiens yang luas. Dengan demikian, komentar yang diperoleh diharapkan dapat memberikan gambaran mengenai opini masyarakat terhadap isu yang diteliti.

Selain data komentar yang diperoleh dari platform TikTok, penelitian ini juga memanfaatkan beberapa jurnal penelitian terdahulu yang relevan sebagai bahan referensi dan perbandingan hasil penelitian. Data dari penelitian terdahulu tidak digunakan sebagai bagian dari dataset pelatihan maupun pengujian model, melainkan hanya digunakan untuk membandingkan metode, tahapan *preprocessing*, serta performa klasifikasi yang diperoleh pada penelitian ini dengan hasil penelitian sebelumnya.

B. Pelabelan data

Tahap berikutnya setelah pengumpulan data adalah melakukan pelabelan pada setiap komentar sesuai dengan kategori sentimen yang telah ditetapkan. Proses pelabelan diterapkan guna memberikan penanda pada setiap data sesuai kelas yang telah ditentukan, sehingga data tersebut dapat digunakan sebagai acuan dalam tahap pembelajaran

dan pengujian model. Pelabelan dilakukan secara manual dengan meninjau setiap komentar berdasarkan konteks dan makna yang terkandung di dalamnya. Untuk menjaga konsistensi dan validitas hasil pelabelan, proses ini divalidasi oleh seorang guru Bahasa Indonesia di SMAS Islam Raudhatul Jannah, Payakumbuh yang memiliki kompetensi dalam bidang kebahasaan. Setiap komentar kemudian dikategorikan ke dalam tiga kelas sentimen, yaitu positif, negatif, dan netral.

C. Text processing

Pada tahap ini dijelaskan proses awal dalam mempersiapkan teks agar dapat diolah secara optimal oleh model klasifikasi. Tahapan pra-pemrosesan dilakukan guna menyusun data teks ke dalam format yang lebih terstruktur dan mudah dianalisis [20]. Adapun tahapan pra-pemrosesan data yaitu, *cleaning*, *case folding*, *tokenizing*, *normalisasi*, *stopword removal*, dan *stemming* [21].

D. Pembobotan TF-IDF

Setelah melalui tahap *text preprocessing*, dilakukan proses ekstraksi fitur dengan menerapkan metode *Term Frequency–Inverse Document Frequency* (TF-IDF) untuk mengonversi data teks menjadi nilai numerik berdasarkan tingkat kepentingan tiap kata dalam dokumen [22].

E. Training

Tahap *training* merupakan proses pelatihan model Multinomial Naïve Bayes menggunakan data yang telah melalui tahapan *preprocessing* dan pembobotan TF-IDF [23]. Pada tahap ini, model mempelajari pola kemunculan kata pada setiap kelas sentimen sehingga dapat digunakan untuk melakukan klasifikasi terhadap data yang dianalisis. Selain menggunakan dataset utama yang berjumlah 1.525 komentar, penelitian ini juga melakukan eksperimen tambahan menggunakan dataset berjumlah 8.370 komentar untuk menganalisis pengaruh ukuran dataset terhadap performa model. Proses pelatihan dilakukan pada setiap kombinasi *preprocessing* yang diuji dalam skenario *ablation study* sehingga dapat diketahui pengaruh masing-masing tahapan *preprocessing* terhadap kinerja model klasifikasi sentimen.

F. Testing

Tahap testing dilakukan untuk mengevaluasi performa model Multinomial Naïve Bayes yang telah dilatih pada setiap skenario *preprocessing*. Evaluasi dilakukan menggunakan metrik akurasi, *F1-score*, dan *confusion matrix* untuk mengukur kemampuan model dalam mengklasifikasikan sentimen [23]. Pengujian utama dilakukan menggunakan dataset berjumlah 1.525 komentar yang terdiri atas sentimen positif, negatif, dan netral. Hasil pengujian pada dataset utama kemudian dibandingkan dengan hasil eksperimen tambahan menggunakan dataset berjumlah 8.370 komentar untuk menganalisis pengaruh ukuran dataset terhadap performa klasifikasi. Seluruh proses pelatihan dan pengujian model dilakukan menggunakan Google Colab berbasis bahasa pemrograman Python.

G. Ablation study

Ablation study merupakan metode eksperimen yang digunakan untuk mengevaluasi kontribusi setiap komponen dalam suatu sistem dengan cara mengaktifkan atau menonaktifkan komponen tersebut secara sistematis. Pada penelitian ini, *ablation study* diterapkan untuk menganalisis pengaruh tahapan *preprocessing* yang meliputi *case folding*, normalisasi, *stopword removal*, dan *stemming* terhadap performa klasifikasi sentimen menggunakan algoritma Multinomial Naïve Bayes. Setiap tahapan *preprocessing* diuji dalam berbagai kombinasi sehingga diperoleh 16 skenario pengujian yang kemudian dievaluasi menggunakan metrik akurasi dan *F1-score*. Melalui pendekatan ini, dapat diketahui kontribusi masing-masing tahapan *preprocessing* serta kombinasi yang paling optimal dalam meningkatkan kinerja model klasifikasi sentiment [24].

H. Evaluasi (*Confusion Matrix*)

Langkah berikutnya ialah melakukan pengujian performa model secara terstruktur menggunakan *confusion matrix* untuk melihat kesesuaian antara hasil prediksi dan data sebenarnya. Melalui tahap ini, kemampuan model dalam menjalankan klasifikasi dapat dianalisis dengan menghitung beberapa indikator evaluasi, seperti akurasi, presisi, *recall*, dan *F1-score*.

Penggunaan metrik presisi, *recall*, dan *F1-score* menjadi penting karena nilai akurasi saja tidak cukup menggambarkan kinerja model pada data yang tidak seimbang. Sebagai ilustrasi, dalam penelitian analisis sentimen, *precision* dan *recall* digunakan untuk memberikan penilaian yang lebih komprehensif terhadap performa model dibanding hanya mengandalkan akurasi semata.

4. HASIL DAN PEMBAHASAN

Pelabelan data

Pada tahap pelabelan data, setiap teks diberikan kategori sentimen berdasarkan isi serta maksud opini yang disampaikan. Dalam penelitian ini, sentimen dibagi menjadi tiga kelompok, yaitu positif, negatif, dan netral. Proses penentuan label dilakukan secara manual dengan memperhatikan konteks kalimat, makna komentar, dan kecenderungan pendapat yang muncul pada setiap data. Tahapan ini dilakukan agar data memiliki struktur yang jelas dan dapat digunakan sebagai dasar dalam proses pelatihan model klasifikasi sentimen menggunakan metode Naïve Bayes Classifier. Hasil dari proses pelabelan tersebut dapat dilihat pada Tabel 1.

Tabel 1. Pelabelan Data

User ID	Text	Sentimen
userjokao87iup	ayo komen ramai kn RUU perampasan aset koruptor harus di sah kan	Positif
bepripriatna	hapuskan hak pensiun anggota DPR	Negatif
agymanis2	ini serius dah yakin 😬	Netral
wantototok3	mari kita perjuangkan RUU perampasan aset	Positif
manusiadamai45	perampasan aset para koruptor gmn bos	Netral
punya.ayank09	puan2 agak lain ketua DPR ri 1 ini Alhamdulillah uangnya Bisa untuk bayar utang negara...	Negatif
prayetno.itno	jadi APBN bisa untuk meningkatkan daya beli..atau kenaikan UMR ...	Positif
srnabillah_	GA PUAS! Point intinya aja ga ada dibahas	Negatif

Dalam proses pelabelan data, setiap teks pada dataset diberi label sentimen positif, negatif, atau netral secara manual dan telah divalidasi oleh seorang guru Bahasa Indonesia di SMAS Islam Raudhatul Jannah, Payakumbuh. Dataset utama yang digunakan dalam penelitian ini berjumlah 1.525 komentar yang terdiri dari 862 komentar netral, 557 komentar negatif, dan 106 komentar positif. Selain itu, penelitian juga melakukan eksperimen tambahan menggunakan dataset berjumlah 8.370 komentar yang terdiri dari 1.171 komentar netral, 4.089 komentar negatif, dan 3.110 komentar positif untuk menganalisis pengaruh ukuran dataset terhadap performa model. Penentuan

label dilakukan dengan memperhatikan isi serta konteks dari setiap kalimat. Teks yang mengandung dukungan, harapan, atau apresiasi terhadap suatu isu dikategorikan sebagai sentimen positif, sedangkan teks yang berisi kritik, ketidakpuasan, atau sindiran diklasifikasikan sebagai sentimen negatif. Adapun teks yang tidak menunjukkan kecenderungan emosi yang jelas atau bersifat informatif dimasukkan ke dalam kategori netral. Hasil pelabelan ini menjadi landasan utama dalam proses pelatihan model klasifikasi, karena digunakan sebagai acuan bagi model untuk mempelajari pola sentimen pada masing-masing dataset.

Proses *Text Preprocessing*

Sebelum dilakukan klasifikasi sentimen, data teks terlebih dahulu melalui proses *text preprocessing* untuk menghasilkan data yang lebih bersih dan terstruktur. Tahapan ini dilakukan untuk mengurangi *noise*, menyeragamkan bentuk kata, serta meningkatkan kualitas representasi data sehingga lebih mudah diproses oleh model Naïve Bayes Classifier. Pada penelitian ini, *preprocessing* meliputi beberapa tahapan, yaitu *cleaning*, *case folding*, *tokenizing*, normalisasi, *stopword removal*, dan *stemming*. Setiap tahapan memiliki peran yang berbeda dalam memperbaiki struktur teks dan menghilangkan informasi yang tidak relevan. Hasil dari setiap proses *preprocessing* tersebut dapat dilihat pada Tabel 2.

Tabel 2. Proses *Text Processing*

Proses	Hasil
Data Asli	Kenapa yang muncul wakil ketua. Ketua dpr ri nya ke mana?? 🙋 Bagian saya bisanya mematikan mic saja 😊😊😊
<i>Cleaning</i>	Kenapa yang muncul wakil ketua. Ketua dpr ri nya ke mana?? 🙋 Bagian saya bisanya mematikan mic saja 😊😊😊
<i>Case folding</i>	kenapa yang muncul wakil ketua. ketua dpr ri nya ke mana?? 🙋 bagian saya bisanya mematikan mic saja 😊😊😊
Normalisasi	kenapa yang muncul wakil ketua ketua dpr ri nya ke mana bagian saya bisanya mematikan mic saja
<i>Tokenizing</i>	['kenapa', 'yang', 'muncul', 'wakil', 'ketua', 'ketua', 'dpr', 'ri', 'nya', 'ke', 'mana', 'bagian', 'saya', 'bisanya', 'mematikan', 'mic', 'saja']
<i>Stopword removal</i>	muncul wakil ketua ketua dpr ri nya bisanya mematikan mic
<i>Stemming</i>	muncul wakil ketua ketua dpr ri nya mati mic

Tahap *text preprocessing* dalam penelitian ini dilaksanakan melalui beberapa langkah berurutan untuk mengubah data teks mentah menjadi bentuk yang lebih terstruktur dan siap diolah pada proses klasifikasi menggunakan algoritma Multinomial Naïve Bayes. Proses dimulai dari data asli yang masih mengandung berbagai unsur tidak terstruktur seperti huruf kapital yang tidak konsisten, tanda baca, emoji, serta kata-kata tidak baku.

Selanjutnya, tahap *cleaning* merupakan proses awal pembersihan teks yang dilakukan dengan membersihkan data dari elemen yang tidak relevan, seperti emoji dan karakter khusus, namun tanpa mengubah struktur utama kalimat. Pada tahap *case folding*, setiap teks diproses dengan menyamakan seluruh huruf menjadi bentuk huruf kecil (*lowercase*), sehingga variasi penulisan akibat huruf kapital dapat

diminimalkan dan konsistensi data tetap terjaga dalam proses analisis. Setelah itu, tahap normalisasi yaitu menyederhanakan teks dengan menghilangkan tanda baca dan merapikan susunan kata sehingga menjadi lebih mudah diproses. Tahap selanjutnya adalah *tokenizing* proses menguraikan kalimat menjadi satuan-satuan kata yang lebih kecil. Selanjutnya, dilakukan *stopword removal* untuk menyaring dan menghapus kata-kata yang bersifat umum dan tidak memiliki peran penting dalam proses analisis, sehingga data yang tersisa lebih fokus pada istilah yang bermakna. Setelah itu, tahap *stemming* diterapkan untuk mengubah setiap kata ke bentuk dasarnya, sehingga berbagai variasi kata dapat diseragamkan. Dengan rangkaian proses tersebut, hasil akhir *preprocessing* menghasilkan teks yang lebih sederhana, bersih, dan siap digunakan pada tahap analisis berikutnya.

Wordcloud

Visualisasi *wordcloud* digunakan untuk menggambarkan distribusi frekuensi kata dalam dataset yang dianalisis. Melalui pendekatan ini, dapat diidentifikasi kata-kata yang paling dominan serta kecenderungan topik yang muncul dalam data. Perbandingan antara *wordcloud* sebelum dan sesudah *preprocessing* memberikan gambaran mengenai pengaruh tahapan pembersihan data terhadap kualitas representasi teks. Visualisasi distribusi frekuensi kata sebelum dan sesudah proses *preprocessing* disajikan pada Gambar 2.



Gambar 2. Wordcloud

Wordcloud pada penelitian ini merepresentasikan distribusi frekuensi kata dalam dataset yang dianalisis. Semakin besar ukuran kata, semakin sering kata tersebut muncul dalam data, sehingga dapat diinterpretasikan sebagai topik atau isu yang paling dominan dalam data. Dari hasil wordcloud, terlihat bahwa terdapat beberapa kata kunci yang memiliki frekuensi tinggi dan menjadi pusat pembahasan, seperti “rampas”, “aset”, dan “dpr”. Hal ini menunjukkan bahwa dataset banyak memuat opini atau diskusi yang berkaitan dengan isu kebijakan publik dan ekonomi.

Selain itu, dominasi kata-kata tertentu mengindikasikan adanya kecenderungan fokus pembahasan dalam dataset, sehingga dapat digunakan sebagai dasar untuk memahami konteks utama sebelum dilakukan analisis lebih lanjut. Wordcloud juga membantu mengidentifikasi kata-kata yang relevan sebagai fitur penting dalam proses klasifikasi atau analisis sentimen.

Setelah dilakukan preprocessing, kata-kata yang muncul dalam wordcloud menjadi lebih terarah dan representatif, karena kata-kata yang tidak penting telah dihilangkan dan variasi kata telah diseragamkan. Hal ini menunjukkan bahwa preprocessing berperan dalam meningkatkan kualitas data teks sehingga informasi yang dihasilkan lebih akurat dan sesuai dengan konteks yang dianalisis. Dengan demikian, wordcloud tidak hanya berfungsi sebagai visualisasi, tetapi juga sebagai alat eksplorasi awal untuk memahami pola, tema, dan kecenderungan isi data.

Ablation study

Ablation study dilakukan untuk menganalisis pengaruh masing-masing tahapan preprocessing terhadap kinerja model dalam proses klasifikasi. Melalui pendekatan ini, setiap kombinasi metode preprocessing diuji secara terpisah untuk mengetahui kontribusi dan dampaknya terhadap hasil yang diperoleh. Analisis ini bertujuan untuk mengidentifikasi kombinasi preprocessing yang paling optimal serta memahami peran setiap tahapan dalam meningkatkan kualitas data dan performa model.

Tahapan ini dilakukan dengan mengaktifkan dan menonaktifkan (1 = digunakan, 0 = tidak digunakan) sehingga memungkinkan peneliti untuk mengidentifikasi tahapan pra-pemrosesan yang paling berpengaruh pada nilai Akurasi dan F1-score. Hasil analisis tersebut digunakan untuk menentukan kombinasi pra-pemrosesan yang memberikan performa terbaik.

Data Tambahan

Untuk memperoleh pemahaman yang lebih komprehensif mengenai pengaruh jumlah dataset terhadap performa model, dilakukan eksperimen tambahan menggunakan dataset yang lebih besar sebanyak 8.370 komentar. Eksperimen ini bertujuan untuk melakukan ablation study terhadap kombinasi tahapan preprocessing yang sama seperti pada eksperimen sebelumnya, guna mengetahui apakah peningkatan jumlah data berdampak signifikan terhadap akurasi dan F1-score model Multinomial Naïve Bayes. Hasil pengujian terhadap 16 skenario kombinasi preprocessing pada dataset yang lebih besar ini ditunjukkan pada Tabel 3.

Tabel 3. Ablation study Dataset Tambahan

No	Text Processing					
	Case folding	Normalisasi	Stopword removal	Stemming	Acc	F1
1	1	0	0	0	0,8953	0,9166
2	0	1	0	0	0,8821	0,9046

3	0	0	1	0	0,8972	0,9185
4	0	0	0	1	0,8899	0,9118
5	1	1	0	0	0,8987	0,9189
6	1	0	1	0	0,8972	0,9185
7	1	0	0	1	0,8915	0,9129
8	0	1	1	0	0,8846	0,9074
9	0	1	0	1	0,8774	0,9000
10	0	0	1	1	0,8950	0,9162
11	0	1	1	1	0,8839	0,9065
12	1	0	1	1	0,8950	0,9162
13	1	1	0	1	0,8958	0,9155
14	1	1	1	0	0,8920	0,9139
15	1	1	1	1	0,8924	0,9137
16	0	0	0	0	0,8953	0,9166
Best Performance					0,8987	0,9189

Berdasarkan hasil pengujian pada dataset 8.370 komentar, diperoleh performa terbaik pada kombinasi *case folding* dan normalisasi tanpa menerapkan *stopword removal* dan *stemming* yang ditunjukkan pada skenario nomor 5 dengan akurasi sebesar 89,87% dan *F1-score* sebesar 91,89%. Kondisi ini menunjukkan bahwa kombinasi *case folding* dan normalisasi mampu menghasilkan representasi fitur yang lebih baik pada dataset tambahan sehingga memberikan performa klasifikasi yang optimal.

Data Utama

Pada pengujian *ablation study* menggunakan dataset utama yang berjumlah 1.525 komentar, hasil evaluasi setiap kombinasi *preprocessing* ditunjukkan pada Tabel 4. Setiap kombinasi *preprocessing* dievaluasi untuk mengetahui pengaruhnya terhadap performa klasifikasi sentimen. Hasil pengujian kemudian dibandingkan berdasarkan nilai akurasi dan *F1-score* untuk menentukan kombinasi *preprocessing* yang menghasilkan performa terbaik.

Tabel 4. *Ablation study* Dataset Utama

No	<i>Text Processing</i>					
	<i>Case folding</i>	Normalisasi	<i>Stopword removal</i>	<i>Stemming</i>	Acc	F1
1	1	0	0	0	0,7697	0,7538
2	0	1	0	0	0,7794	0,7656
3	0	0	1	0	0,7573	0,7480
4	0	0	0	1	0,7285	0,7076
5	1	1	0	0	0,7659	0,7518
6	1	0	1	0	0,7573	0,7480
7	1	0	0	1	0,7285	0,7076
8	0	1	1	0	0,8120	0,8031
9	0	1	0	1	0,7518	0,7343
10	0	0	1	1	0,7744	0,7619
11	0	1	1	1	0,7910	0,7846
12	1	0	1	1	0,7744	0,7619
13	1	1	0	1	0,7394	0,7259
14	1	1	1	0	0,7883	0,7786
15	1	1	1	1	0,7555	0,7480
16	0	0	0	0	0,7697	0,7538
Best Performance					0,8120	0,8031

Berdasarkan Tabel 4, terlihat bahwa setiap kombinasi *preprocessing* menghasilkan nilai akurasi dan *F1-score* yang berbeda. Hasil terbaik diperoleh pada kombinasi yang menggunakan normalisasi dan *stopword*

removal tanpa melibatkan *case folding* dan *stemming* pada pengujian nomor 8, dengan akurasi sebesar 81,20% dan *F1-score* sebesar 80,31%. Hasil terbaik diperoleh dari kombinasi normalisasi dan *stopword removal* karena

keduanya mampu menghasilkan fitur yang konsisten dan relevan tanpa menghilangkan informasi penting bagi model Multinomial Naïve Bayes.

Hasil pengujian pada dataset utama digunakan untuk mengevaluasi performa setiap kombinasi *preprocessing* dalam mengklasifikasikan sentimen masyarakat terhadap kasus Tuntutan 17+8. Nilai akurasi dan *F1-score* yang diperoleh digunakan sebagai dasar untuk menentukan kombinasi *preprocessing* yang paling optimal pada dataset penelitian.

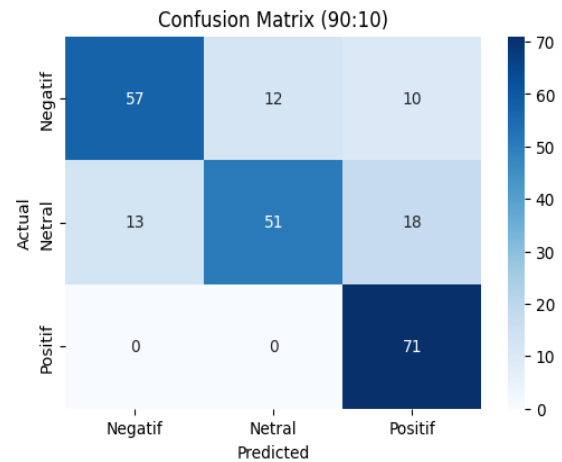
Normalisasi menyeragamkan variasi kata sehingga frekuensi lebih akurat, sementara *stopword removal* menghilangkan kata tidak penting sehingga fitur lebih fokus. Sebaliknya, proses seperti *stemming* justru dapat mengurangi konteks makna, sehingga menurunkan performa. Kombinasi ini menghasilkan representasi teks yang lebih bersih dan relevan tanpa mengurangi konteks asli kalimat.

Perbedaan kombinasi *preprocessing* terbaik antara dataset utama 1.525 komentar dan dataset tambahan 8.370 komentar menunjukkan bahwa ukuran dataset memengaruhi efektivitas tahapan *preprocessing* serta performa klasifikasi model. Pada dataset tambahan, kombinasi *case folding* dan normalisasi menghasilkan performa terbaik karena jumlah data yang lebih besar memungkinkan algoritma Multinomial Naïve Bayes mempelajari distribusi kata secara lebih stabil. Sebaliknya, pada dataset utama, kombinasi normalisasi dan *stopword removal* memberikan hasil terbaik karena mampu mengurangi *noise* dan meningkatkan relevansi fitur pada jumlah data yang lebih terbatas. Perbedaan ini menunjukkan bahwa efektivitas *preprocessing* dipengaruhi oleh karakteristik dan ukuran dataset, sehingga kombinasi yang optimal pada dataset besar belum tentu menghasilkan performa yang sama pada dataset yang lebih kecil. Kondisi tersebut mengindikasikan adanya gejala *overfitting* ringan pada beberapa skenario *preprocessing*, sehingga pemilihan tahapan *preprocessing* perlu disesuaikan dengan karakteristik data agar model memiliki kemampuan generalisasi yang lebih baik.

Confusion matrix

Confusion matrix digunakan sebagai alat evaluasi untuk mengukur kinerja model klasifikasi dengan cara mencocokkan hasil prediksi yang dihasilkan model terhadap label sebenarnya pada data aktual. Dari matriks ini, dapat diidentifikasi secara jelas jumlah prediksi yang tepat maupun yang keliru pada setiap kelas, sehingga mampu memberikan gambaran yang lebih detail dan menyeluruh mengenai kemampuan model dalam melakukan klasifikasi. Analisis ini membantu dalam mengidentifikasi tingkat akurasi serta kesalahan klasifikasi yang terjadi selama proses pengujian. Hasil evaluasi menggunakan *confusion matrix* ditunjukkan pada Gambar 3. Matriks ini digunakan untuk mengevaluasi hubungan antara hasil prediksi model dan label aktual pada setiap kelas sentimen. Berdasarkan informasi yang diperoleh, performa

model dalam melakukan klasifikasi dapat dianalisis secara lebih rinci dan sistematis.



Gambar 3. *Confusion Matrix*

Confusion matrix pada skenario pembagian data 90:10 membuktikan bahwa model memiliki kemampuan klasifikasi yang cukup baik, terutama pada kelas positif. Berdasarkan jumlah data aktual pada kelas negatif, model berhasil mengidentifikasi 57 data dengan tepat, sementara 12 data lainnya salah diprediksi sebagai netral dan 10 data sisanya diklasifikasikan sebagai positif. Pada kelas netral, model mencatat 51 prediksi yang benar, namun masih terjadi kesalahan klasifikasi, yaitu 13 data diprediksi sebagai negatif dan 18 data sebagai positif. Kondisi tersebut menunjukkan bahwa kelas netral memiliki karakteristik yang cenderung ambigu sehingga lebih sulit dibedakan dibandingkan kelas lainnya. Sementara itu, performa terbaik ditunjukkan pada kelas positif dengan 71 prediksi benar tanpa adanya kesalahan klasifikasi ke kelas negatif maupun netral.

Secara umum, hasil *confusion matrix* mengindikasikan bahwa model mampu mencapai tingkat ketepatan yang relatif tinggi, khususnya pada kelas positif, namun masih mengalami keterbatasan dalam membedakan kelas netral dan negatif secara konsisten. Kondisi ini kemungkinan disebabkan oleh kemiripan distribusi kata dan konteks sentimen pada kedua kelas tersebut. Dengan demikian, model dapat disimpulkan bekerja secara efektif dalam mengklasifikasikan sentimen, meskipun masih diperlukan peningkatan performa untuk menghasilkan klasifikasi yang lebih seimbang dan optimal.

5. KESIMPULAN

Berdasarkan hasil penelitian klasifikasi sentimen masyarakat terhadap kasus Tuntutan 17+8 menggunakan metode Naïve Bayes Classifier dengan pembobotan TF-IDF, dapat disimpulkan bahwa tahapan *preprocessing* memiliki pengaruh yang signifikan terhadap performa model klasifikasi. Hasil *ablation study* menunjukkan bahwa setiap kombinasi *preprocessing*

menghasilkan nilai akurasi dan *F1-score* yang berbeda, di mana pada dataset tambahan sebanyak 8.370 komentar performa terbaik diperoleh pada kombinasi *case folding* dan normalisasi dengan akurasi 89,87% dan *F1-score* 91,89%, sedangkan pada dataset utama sebanyak 1.525 komentar performa terbaik diperoleh pada kombinasi normalisasi dan *stopword removal* tanpa penerapan *case folding* dan *stemming* dengan akurasi 81,20% dan *F1-score* 80,31%. Temuan ini menunjukkan bahwa pemilihan tahapan *preprocessing* yang tepat lebih berpengaruh terhadap peningkatan kinerja model dibandingkan penggunaan seluruh tahapan *preprocessing* secara bersamaan. Selain itu, hasil evaluasi menggunakan *confusion matrix* menunjukkan bahwa model mampu mengklasifikasikan sentimen dengan baik, terutama pada kelas positif, meskipun masih terdapat beberapa kesalahan klasifikasi pada kelas netral dan negatif yang memiliki karakteristik lebih ambigu. Secara keseluruhan, kombinasi TF-IDF dan Naïve Bayes Classifier terbukti efektif dalam mengklasifikasikan sentimen masyarakat terhadap kasus Tuntutan 17+8 dan mampu menghasilkan performa klasifikasi yang baik dengan tingkat akurasi mencapai 81,20% pada data pengujian.

DAFTAR PUSTAKA

- [1] Y. Eykel and H. Ginting, "Kajian Yuridis Penjatuhan 17 + 8 Tuntutan Rakyat dan Implikasinya terhadap Prinsip Transparansi serta Responsivitas Pihak yang di tuntutan," *J. Ilm. Penelit. Mhs.*, vol. 3, no. 6, pp. 1156–1167, 2025, doi: 10.61722/jipm.v3i6.2081.
- [2] H. Sulistiawati and M. Afrilia, "Upaya Pemerintah Mengelola Tekanan Publik: Analisis Respon Pemerintah Atas Tuntutan 17+8 Pasca Demonstrasi Agustus 2025," *Moderat J. Ilm. Ilmu Pemerintah.*, vol. 12, no. 1, pp. 237–250, 2026, doi: 10.25157/moderat.v12i1.5769
- [3] A. I. Kamil, O. N. Pratiwi, and D. Witarsyah, "Analisis sentimen dan pemodelan topik terhadap aplikasi pembelajaran online pada platform Google Play," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 10, no. 2, pp. 836–849, Mar. 2025, doi: 10.29100/jupi.v10i2.6023.
- [4] R. Indransyah, Y. H. Chrisnanto, and P. N. Sabrina, "Klasifikasi sentimen pergelaran MotoGP di Indonesia menggunakan algoritma Correlated Naïve Bayes Classifier," *INFOTECH J.*, vol. 8, no. 2, pp. 60–66, 2022, doi: 10.31949/infotech.v8i2.3103.
- [5] A. Haris, T. Tukino, A. Hananto, and F. Nurapriani, "Penerapan Algoritma Naive Bayes Untuk Klasifikasi Sentimen Ulasan Pengguna Aplikasi Pidi Umkm Dengan Pembobotan Fitur Tf-Idf," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 5, pp. 8457–8462, 2025, doi: 10.36040/jati.v9i5.15019.
- [6] D. Surya Sayogo, B. Irawan, and A. Bahtiar, "Analisis Sentimen Ulasan Instagram Di Google Play Store Menggunakan Algoritma Naïve Bayes," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 6, pp. 3314–3319, 2024, doi: 10.36040/jati.v7i6.8178.
- [7] W. P. Anggraini and M. S. Utami, "Klasifikasi Sentimen Masyarakat Terhadap Kebijakan Kartu Pekerja Di Indonesia," *Fakt. Exacta*, vol. 13, no. 4, p. 255–261, 2021, doi: 10.30998/faktorexacta.v13i4.7964.
- [8] L. A. Akbar, E. Haerani, F. Syafria, A. Nazir, and E. Budianita, "Klasifikasi Sentimen Presepsi Masyarakat di Instagram Terhadap Paslon Pilpres 2024 Menggunakan Naïve Bayes Classifier (NBC)," *J. Komtika (Komputasi dan Inform.)*, vol. 8, no. 1, pp. 102–112, 2024, doi: 10.31603/komtika.v8i1.11293.
- [9] A. A. Firdaus, A. I. Hadiana, and A. K. Ningsih, "Klasifikasi sentimen pada aplikasi Shopee menggunakan fitur Bag of Word dan algoritma Random Forest," *Ranab Res. J. Multidiscip. Res. Dev.*, vol. 6, no. 5, pp. 1678–1683, Jul. 2024, doi: 10.38035/rrj.v6i5.994.
- [10] S. P. Warakmuly and Y. H. Putra, "Optimalisasi manajemen sentimen di media sosial universitas melalui machine learning dan AI: Studi kasus pada komentar Instagram," *J. Tata Kelola dan Kerangka Kerja Teknol. Inf.*, vol. 11, no. 1, pp. 31–38, Jun. 2025, doi: 10.34010/jtk3ti.v1i1.16204.
- [11] Sukriadi, Ismail, and A. M. Andzar, "Penerapan text mining dalam klasifikasi judul skripsi yang diusulkan mahasiswa menggunakan metode Naïve Bayes," *J. Ilm. Sist. Inf. dan Tek. Inform.*, vol. 6, no. 2, pp. 184–196, Oct. 2023, doi: 10.57093/jisti.v6i2.174.
- [12] V. Agustina and A. Herliana, "Analisis sentimen publik atas kebijakan efisiensi anggaran 2025 dengan text mining dan natural language processing," *J. Media Inform.*, vol. 6, no. 3, pp. 2182–2194, 2025, doi: 10.55338/jumin.v6i3.6301.
- [13] D. N. S. S. Utomo, H. D. Bhakti, and P. A. R. Devi, "Penerapan algoritma Naïve Bayes untuk klasifikasi penilaian kinerja pegawai di Kedai XYZ," *Kobesi J. Multidisiplin Saintek*, vol. 7, no. 1, pp. 2988–1986, 2025, doi: 10.3785/koehesi.v7i1.11029.
- [14] E. N. Hamdana, A. O. N. Wardani, and A. R. T. H. Ririd, "Sentiment analysis of visitor reviews on Google Maps at Kampung Coklat tourism," *J. Artif. Intell. Softw. Eng.*, vol. 5, no. 1, pp. 274–282, Mar. 2025, doi: 10.36040/jati.v9i5.15019.

- 10.30811/jaise.v5i1.6488.
- [15] R. Hidayat, M. Fikry, Y. Yusra, F. Yanto, and E. P. Cynthia, "Penerapan Naïve Bayes Classifier dalam Klasifikasi Sentimen Publik di Twitter terhadap Puan Maharani," *JUKI J. Komput. dan Inform.*, vol. 6, no. 1, pp. 100–108, 2024, doi: 10.53842/juki.v6i1.479.
- [16] N. A. Putri, A. Srirahayu, and N. A. Sudiby, "Analisis sentimen terhadap aplikasi KitaLulus menggunakan metode Naive Bayes dari ulasan Google Play Store," *Smart Comp Jurnalnya Orang Pint. Komput.*, vol. 14, no. 2, pp. 269–279, Apr. 2025, doi: 10.30591/smartcomp.v14i2.7230.
- [17] O. Manullang and C. Prianto, "Analisis Sentimen dalam Memprediksi Hasil Pemilu Presiden dan Wakil Presiden: Systematic Literature Review," *J. Inform. dan Teknol. Komput. (J-ICOM)*, vol. 4, no. 2, pp. 104–113, 2023, doi: 10.55377/j-icom.v4i2.7723.
- [18] R. Illahi, S. Agustian, Jasril, and F. Yanto, "Klasifikasi sentimen menggunakan Bidirectional LSTM dan IndoBERT dengan dataset terbatas," *Zo. J. Sist. Inf.*, vol. 7, no. 1, pp. 74–84, 2025, doi: 10.31849/zn.v7i1.25091.
- [19] Khairunnisa, S. K. Dewi, D. D. Rahmawati, and A. P. Sari, "Analisis sentimen komentar pada postingan Instagram 'Standwithus' menggunakan klasifikasi Naive Bayes," *J. Ilm. Inform.*, vol. 12, no. 02, pp. 191–199, Sep. 2024, doi: 10.33884/jif.v12i02.9263.
- [20] M. H. Riqo Fandany, "Analisis Sentimen Pengguna Aplikasi Cakap Belajar Online Menggunakan Algoritma Naïve Bayes Classifier," *PROSISKOJ. Pengemb. Ris. dan Obs. Sist. Komput.*, vol. 12, no. 1, pp. 34–40, 2025, doi: 10.30656/prosisko.v12i1.9117.
- [21] A. N. Puspitasari, Y. Findawati, and Y. Rahmawati, "Analisis Sentimen Tweet Pengguna E-Commerce Dengan Menggunakan Metode Klasifikasi Naive Bayes," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 9, no. 3, pp. 1123–1132, 2024, doi: 10.29100/jupi.v9i3.4939.
- [22] R. Wati, S. Ernawati, and H. Rachmi, "Pembobotan TF-IDF menggunakan Naive Bayes pada sentimen masyarakat mengenai isu kenaikan BIPIH," *J. Manaj. Inform.*, vol. 13, no. 1, pp. 84–93, Apr. 2023, doi: 10.34010/jamika.v13i1.9424.
- [23] A. H. K. S. Harahap, E. Haerani, L. Oktavia, Okfalisa, and F. Kurnia, "Klasifikasi sentimen masyarakat terhadap revisi undang-undang Tentara Nasional Indonesia menggunakan Naive Bayes Classifier," *Bull. Comput. Sci. Res.*, vol. 5, no. 4, pp. 594–603, 2025, doi: 10.47065/bulletincsr.v5i4.615.
- [24] W. S. Amin, M. Fikry, R. Abdillah, and S. Agustian, "Sentiment Classification of Public Perceptions on Rp200 Trillion HIMBARA Stimulus Using Naive Bayes," *Jurnal Riset Informatika*, vol. 8, no. 2, pp. 244–254, Mar. 2026, doi: 10.34288/jri.v8i2.500.