

# Perbandingan Algoritma NBC, SVM, Logistic Regression untuk Analisis Sentimen Terhadap Wacana KaburAjaDulu di Media Sosial X

Adib Annur Rohman\*, Gustina Alfa Trisnapradika

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: <sup>1,\*</sup>111202113712@mhs.dinus.ac.id, <sup>2</sup>gustina.alfa@dsn.dinus.ac.id

Email Penulis Korespondensi: 111202113712@mhs.dinus.ac.id

Submitted: 03/05/2025; Accepted: 31/05/2025; Published: 01/06/2025

**Abstrak**—Penelitian ini bertujuan untuk menganalisis sentimen terhadap wacana KaburAjaDulu pada media sosial X dengan memanfaatkan algoritma Logistic Regression, Support Vector Machine (SVM), dan Naive Bayes. Data dikumpulkan melalui proses crawling dan menghasilkan 3.011 data tweet. Tahapan pra-pemrosesan meliputi pembersihan data, konversi huruf menjadi kecil, normalisasi, tokenisasi, penghapusan stopword, dan stemming. Setelah preprocessing, data dibagi menjadi dua kategori sentimen, yaitu positif dan negatif memanfaatkan pendekatan lexicon. Dataset dibagi menggunakan skema 80:20 untuk data latih dan uji, dengan representasi fitur yang memanfaatkan metode TF-IDF. Proses pemodelan dilakukan memanfaatkan ketiga algoritma tersebut untuk dievaluasi dengan memanfaatkan metrik akurasi, presisi, recall, dan f1-score. Sebagai solusi terhadap ketimpangan kelas, diterapkan teknik oversampling SMOTE (Synthetic Minority Over-sampling Technique). Berdasarkan evaluasi, memperlihatkan bahwa sebelum penerapan SMOTE, algoritma Naive Bayes memperoleh akurasi mencapai 78,18%, precision 81,80%, recall 77,06%, dan f1-score 77,35%; SVM memperoleh akurasi 85,63%, precision 86,49%, recall 85,68%, dan f1-score 85,94%; sementara Logistic Regression memperoleh akurasi 83,05%, precision 85,31%, recall 82,47%, dan f1-score 82,95%. Setelah penerapan SMOTE, Naive Bayes meningkat menjadi akurasi 81,90%, precision 82,27%, recall 81,67%, dan f1-score 81,87%; SVM memperoleh akurasi 85,63%, precision 87,59%, recall 86,89%, dan f1-score 87,13%; serta Logistic Regression memperoleh akurasi 83,33%, precision 84,46%, recall 83,62%, dan f1-score 83,88%. Temuan ini membuktikan bahwa SVM memiliki performa klasifikasi sentimen yang paling konsisten dan unggul pada dataset ini, memberikan kontribusi penting bagi pengembangan metode analisis pandangan masyarakat pada platform media sosial.

**Kata Kunci:** Analisis Sentimen; Naive Bayes; SVM; Logistic Regression; SMOTE

**Abstract**—This research aims to analyze sentiment towards KaburAjaDulu discourse on X social media by utilizing Logistic Regression, Support Vector Machine (SVM), and Naive Bayes algorithms. Data was collected through a crawling process and resulted in 3,011 tweet data. Pre-processing stages include data cleaning, conversion of letters to lowercase, normalization, tokenization, stopword removal, and stemming. After preprocessing, the data was divided into two sentiment categories, namely positive and negative using a lexicon approach. The dataset is divided using an 80:20 scheme for training and test data, with feature representation utilizing the TF-IDF method. The modeling process is performed utilizing the three algorithms to be evaluated using accuracy, precision, recall, and f1-score metrics. As a solution to class inequality, the oversampling technique SMOTE (Synthetic Minority Over-sampling Technique) is applied. Based on the evaluation, it shows that before the application of SMOTE, Naive Bayes algorithm obtained 78.18% accuracy, 81.80% precision, 77.06% recall, and 77.35% f1-score; SVM obtained 85.63% accuracy, 86.49% precision, 85.68% recall, and 85.94% f1-score; while Logistic Regression obtained 83.05% accuracy, 85.31% precision, 82.47% recall, and 82.95% f1-score. After applying SMOTE, Naive Bayes improved to 81.90% accuracy, 82.27% precision, 81.67% recall, and 81.87% f1-score; SVM obtained 85.63% accuracy, 87.59% precision, 86.89% recall, and 87.13% f1-score; and Logistic Regression obtained 83.33% accuracy, 84.46% precision, 83.62% recall, and 83.88% f1-score. These findings prove that SVM has the most consistent and superior sentiment classification performance on this dataset, making an important contribution to the development of methods for analyzing people's views on social media platforms.

**Keywords:** Sentiment Analysis; Naive Bayes; SVM; Logistic regression; SMOTE

## 1. PENDAHULUAN

Media sosial pada masa kini telah berevolusi menjadi sebuah platform utama bagi masyarakat untuk menyuarakan opini publik terkait berbagai peristiwa sosial, politik, ekonomi, maupun budaya. Salah satu platform yang populer adalah X, yang memungkinkan penyebaran informasi secara cepat dan masif melalui penggunaan tagar atau hashtag. Tagar berfungsi sebagai alat penting dalam mengelompokkan percakapan daring serta memudahkan pengguna untuk mengikuti isu tertentu secara real-time [1]. Salah satu tagar yang dalam kurun waktu terakhir gencar dibicarakan di platform media sosial Indonesia adalah #KaburAjaDulu [2], [3], [4]. Tagar ini mencerminkan respons masyarakat terhadap ketidakpuasan atau kekecewaan terhadap kondisi sosial, politik, atau kebijakan pemerintah yang sedang terjadi. Analisis terhadap sentimen pengguna terkait tagar ini penting dilakukan guna memahami dinamika opini publik di era digital, sekaligus menjadi masukan yang berharga bagi pemangku kepentingan dalam merespons isu yang berkembang [5].

Dalam ranah analisis sentimen, teknologi machine learning telah berkembang pesat sebagai pendekatan utama untuk mengklasifikasikan opini publik secara otomatis [6]. Sasaran hasil dari analisis sentimen adalah untuk mengenali serta mengategorikan perspektif atau sentimen yang terdapat pada suatu tulisan, misalnya opini positif, negatif, atau netral. Tugas ini biasanya memanfaatkan berbagai algoritma dalam *machine learning*, di antaranya adalah Naive Bayes, Support Vector Machine (SVM), dan Logistic Regression.. Naive Bayes dikenal sebagai algoritma sederhana namun efektif, terutama pada data berukuran besar dengan fitur yang saling independen [7]. Sementara itu, SVM unggul dalam memisahkan data non-linear dengan margin maksimum dan sering kali memberikan hasil akurasi

yang tinggi pada tugas klasifikasi teks [8]. Logistic Regression, meskipun awalnya dikembangkan untuk masalah prediksi biner, juga terbukti mampu menangani klasifikasi teks dengan cukup baik, bahkan sering bersaing ketat dengan SVM dalam hal akurasi [9]. Setiap algoritma menawarkan serangkaian keuntungan dan batasan yang berbeda, yang relevansinya ditentukan oleh ciri-ciri data yang menjadi objek analisis seperti panjang teks, keberadaan kata slang, kesalahan penulisan (*typo*), atau sarkasme yang umum ditemukan dalam percakapan di media sosial. Oleh karena itu, pemilihan algoritma yang sesuai sangat penting agar hasil analisis dapat menggambarkan sentimen publik secara akurat.

Berbagai penelitian sebelumnya telah mengeksplorasi efektivitas masing-masing algoritma. Muliana dkk melakukan analisis sentimen terhadap pendapat umum tentang hasil pemilu dengan memanfaatkan Naïve Bayes serta mencatat akurasi 66,90% pada data uji [10]. Ryo dkk (2023) membandingkan algoritma Multinomial Naive Bayes, SVM dan Logistic Regression pada analisis sentimen migrasi televisi digital pada twitter, dengan hasil SVM menunjukkan akurasi sebesar 94,00%, Logistic Regression dengan akurasi 90,00%, dan Naive Bayes dengan akurasi 88,00% [11]. Studi oleh Audi dkk (2024) menggunakan Logistic Regression untuk menganalisis ulasan aplikasi Sirekap dan mencapai akurasi sebesar 91% [12]. Sementara itu, penelitian yang dilakukan Vania dkk (2025) membandingkan Naïve Bayes, SVM, dan Logistic Regression untuk analisis sentimen penipuan dan bot dalam pembelian tiket konser, menunjukkan bahwa SVM lebih unggul akurasi nya di banding algoritma yang lain dengan akurasi 91,27%, kemudian diikuti algoritma Logistic Regression dengan akurasi 90,03%, dan yang terakhir algoritma Naive Bayes dengan akurasi 77,70% [13]. Nur Hadi dkk (2024) membandingkan metode Support Vector Machine (SVM), Logistic Regression dan Naive Bayes dalam analisis sentimen pembangunan Ibu Kota Nusantara (IKN) pada media sosial X dengan akurasi 80% untuk SVM dan 79% untuk Logistic Regression dan Naive Bayes [14].

Namun, terdapat gap penelitian, yaitu belum banyak studi yang secara spesifik membandingkan performa ketiga algoritma tersebut terhadap analisis sentimen pada tagar viral tertentu di Indonesia, khususnya pada Platform X yang memiliki karakteristik data singkat dan padat. Selain itu, karakteristik bahasa informal, penggunaan slang, dan sarkasme yang umum ditemukan di media sosial Indonesia menjadi tantangan tersendiri dalam klasifikasi sentimen.

Selain itu, isu-isu sosial yang viral di media sosial sering kali mencerminkan kondisi psikologis, persepsi sosial, dan tingkat kepercayaan publik terhadap pemerintah maupun institusi lainnya [15], [16]. Oleh sebab itu, pemahaman terhadap pola sentimen masyarakat tidak hanya bermanfaat bagi peneliti di bidang teknologi informasi, tetapi juga penting bagi pemerintah, lembaga survei, media, maupun pihak swasta yang ingin memahami persepsi publik. Analisis sentimen pada kasus #KaburAjaDulu diharapkan dapat menjadi salah satu bentuk kontribusi akademik yang tidak hanya bersifat teoretis, tetapi juga memiliki nilai praktis dan aplikatif.

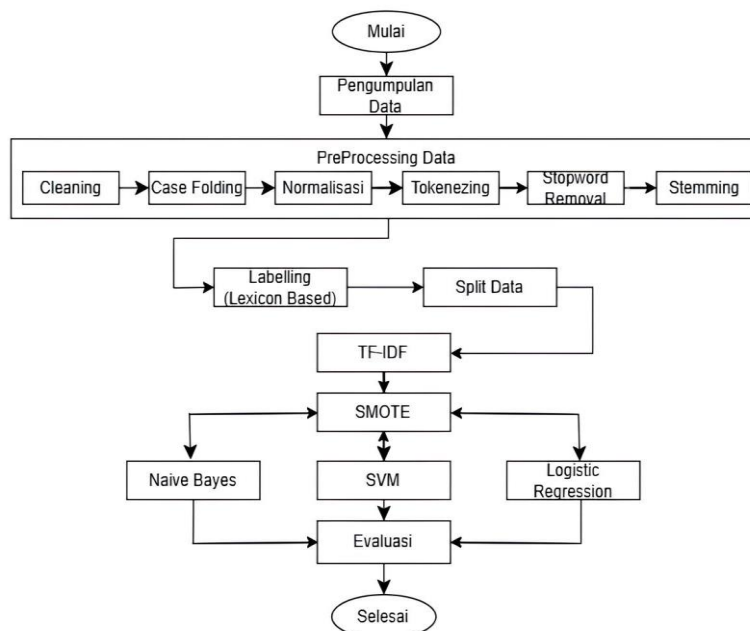
Penelitian ini juga akan menjalankan tahapan *preprocessing* seperti pembersihan data, konversi huruf, normalisasi, tokenisasi, penghapusan *stopword*, dan *stemming* untuk memastikan model dapat dilatih secara maksimal. Lebih lanjut, untuk memberikan bobot yang berbeda pada setiap butir kata pada data, digunakan metode TF-IDF. Sementara itu, untuk mengatasi potensi masalah ketidakseimbangan jumlah data antar kelas sentimen, diterapkan teknik SMOTE. Melalui implementasi pendekatan ini, diharapkan capaian penelitian ini mampu menyajikan pemahaman yang mendalam mengenai kekuatan dan kelemahan setiap algoritma, serta memberikan panduan dalam memilih metode yang paling tepat guna menganalisis sentimen pada kasus-kasus dengan karakteristik yang sama di kemudian hari.

Berdasarkan latar belakang yang telah dipaparkan, studi ini memiliki tujuan untuk menguji dan mengkomparasikan kemampuan algoritma Naïve Bayes, Support Vector Machine, dan Logistic Regression untuk melakukan analisis sentimen terhadap wacana KaburAjaDulu di platform X (sebelumnya Twitter). Kinerja setiap model akan diukur dengan parameter evaluasi yang mencakup akurasi (*accuracy*), presisi (*precision*), *recall*, dan *f1-score*. Diharapkan, temuan dari penelitian ini berpotensi menghasilkan sumbangsih terkait dengan pengembangan teknik analisis sentimen untuk media sosial berbahasa Indonesia dan juga menyajikan pemahaman praktis kepada praktisi maupun peneliti data science dalam menentukan algoritma yang paling tepat untuk analisis opini publik yang berbasis tagar.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini mengadopsi pendekatan kuantitatif dengan metode eksperimental komparatif. Penelitian ini dilaksanakan melalui sejumlah tahapan pokok yang tersusun secara terstruktur dan sistematis. Tahapan tersebut meliputi proses mengumpulkan data dari platform X, tahap awal pemrosesan data dilakukan guna membersihkan serta mempersiapkan data teks, pelabelan data untuk menentukan polaritas proses pemisahan data menjadi kelompok data untuk keperluan pelatihan model dan kelompok data yang diperuntukkan bagi pengujian model, serta pengembangan dan evaluasi model klasifikasi dengan memanfaatkan pendekatan Naïve Bayes dan Support Vector Machine (SVM), dan Logistic Regression. Gambaran visual mengenai tahapan-tahapan penelitian ini dapat dilihat pada Gambar 1 berikut:



Gambar 1. Tahapan Penelitian

## 2.2 Pengumpulan Data

Data *tweet* yang menjadi fokus dalam penelitian ini didapatkan dari platform media sosial X dengan melakukan proses pengambilan data otomatis menggunakan *library Tweet Harvest* [17]. Metode pengumpulan data ini memanfaatkan token akses milik akun yang telah terhubung pada media sosial X untuk mengakses data publik. Pencarian data dilakukan dengan kata kunci utama berupa tagar "#KaburAjaDulu" dalam rentang waktu mulai dari tanggal 1 Januari 2025 hingga 26 April 2025. Proses pengumpulan data ini berhasil mengumpulkan total 3.011 data *tweet* yang relevan dengan isu KaburAjaDulu dan akan menjadi objek utama dalam analisis sentimen penelitian ini.

## 2.3 Preprocessing Data

Sebelum dilakukan analisis sentimen, data *tweet* mentah melalui serangkaian tahapan pra-pemrosesan untuk membersihkan dan mentransformasikan data menjadi format yang sesuai untuk pemodelan *machine learning*. Tahapan pra-pemrosesan yang diterapkan meliputi:

- Cleaning menghapus karakter-karakter yang tidak diperlukan seperti mention (@username), tagar (#KaburAjaDulu dan hashtag lainnya), tautan URL, simbol-simbol khusus, dan retweet (RT).
- Perubahan Huruf Menjadi Huruf Kecil (Case Folding): Seluruh teks pada *tweet* diubah dalam format huruf kecil dengan tujuan menyeragamkan representasi kosakata dan mengeliminasi perbedaan interpretasi kata yang sama karena perbedaan kapitalisasi.
- Normalisasi mengganti kata-kata informal atau singkatan yang umum digunakan di media sosial (misalnya, "yg", "bgt", "dll") dengan bentuk formalnya. langkah memiliki tujuan supaya variasi kata yang tidak diperlukan bisa berkurang dan meningkatkan konsistensi data.
- Tokenizing memecah setiap *tweet* menjadi unit-unit kata atau token. Proses ini penting untuk analisis lebih lanjut, di mana setiap token akan diperlakukan sebagai fitur.
- Stopword Removal menghilangkan kata-kata yang kerap ditemukan didalam teks namun tidak memiliki kontribusi signifikan terhadap sentimen, seperti kata hubung ("dan", "atau"), kata ganti ("saya", "kamu"), dan artikel ("sebuah", "itu"). Daftar stopwords yang digunakan disesuaikan dengan konteks bahasa Indonesia [15].
- Stemming menerapkan proses stemming untuk mentransformasi kata-kata ke bentuk dasarnya atau stem. Algoritma stemming yang umum digunakan untuk bahasa Indonesia adalah algoritma Nazief & Adriani. Tujuan stemming ialah untuk menyederhanakan variasi kata yang memiliki variasi bentuk namun berasal dari kata dasar yang sama, sehingga membantu meningkatkan kemampuan generalisasi model.

## 2.4 Labelling Data

Setelah tahapan pra-pemrosesan, setiap data *tweet* diberi label sentimen positif atau negatif menggunakan pendekatan berbasis leksikon (*lexicon-based approach*). Dalam pendekatan ini, sentimen suatu teks ditentukan berdasarkan orientasi sentimen dari kata-kata yang terkandung di dalamnya, yang merujuk pada kamus atau daftar kata-kata yang telah diberi skor sentimen [18]. Proses pelabelan ini menghasilkan total 948 *tweet* dengan label sentimen negatif (31,52%) dan 789 *tweet* dengan label sentimen positif (26,23%), sementara sisanya termasuk kategori netral atau tidak terdefinisi yang kemudian tidak dimasukkan dalam dataset akhir. Informasi distribusi ini menunjukkan adanya ketidakseimbangan kelas, sehingga perlu diterapkan metode penanganan seperti SMOTE pada tahap pelatihan model.

## 2.5 Split Data

Dataset yang sudah dilabeli sentimen kemudian dipisahkan menjadi dua kelompok utama menggunakan skema *split* data 80:20. Sebanyak 80% data digunakan sebagai data pelatihan (*training data*) dalam proses pembelajaran model *machine learning*, sementara 20% sisanya digunakan sebagai data pengujian (*testing data*) guna menilai kinerja model yang sudah dilatih. Pembagian ini memastikan bahwa model dievaluasi pada data yang belum pernah dilihat sebelumnya.

## 2.6 TF-IDF

Untuk memungkinkan pemrosesan oleh algoritma *machine learning*, data tekstual *tweet* ditransformasikan menjadi representasi numerik melalui metode TF-IDF atau *Term Frequency-Inverse Document Frequency*. Teknik ini menetapkan nilai bobot untuk setiap kata berdasarkan seberapa sering kata itu muncul pada suatu *tweet* dan invers frekuensinya dalam keseluruhan korpus [19]. *Term* yang kerap ditemukan dalam *tweet* tertentu tetapi jarang ditemukan dalam korpus secara keseluruhan dianggap lebih signifikan dalam membedakan sentimen *tweet* tersebut, sehingga mendapatkan bobot TF-IDF yang lebih tinggi. Representasi ini menghasilkan matriks numerik yang merefleksikan signifikansi setiap term dalam setiap *tweet* untuk analisis sentimen.

## 2.7 SMOTE

Dalam penelitian ini, deteksi awal terhadap distribusi label sentimen pada data latih menunjukkan adanya potensi ketidakseimbangan kelas, di mana jumlah *tweet* dengan sentimen positif dan negatif mungkin tidak terdistribusi secara merata. Untuk mengatasi potensi ketidakseimbangan kelas sentimen yang terdeteksi dalam data latih, penelitian ini mengimplementasikan metode oversampling SMOTE (*Synthetic Minority Over-sampling Technique*). SMOTE berfungsi menciptakan data-data buatan yang baru untuk kategori minoritas melalui interpolasi fitur antara sampel dan tetangga terdekatnya [20]. Implementasi SMOTE menggunakan pustaka *imblearn* pada data latih bertujuan untuk menyeimbangkan distribusi kelas sebelum pelatihan model, sehingga meningkatkan kemampuan model dalam mengklasifikasikan semua sentimen secara efektif dan menghindari bias terhadap kelas mayoritas. Pemilihan jumlah tetangga terdekat ( $k$ ) dipertimbangkan, dan evaluasi dampak SMOTE dilakukan dengan membandingkan kinerja model sebelum dan sesudahnya.

## 2.8 Modeling

Tahapan ini mencakup proses implementasi dan pelatihan dari tiga algoritma *machine learning* yang telah dipilih untuk mengklasifikasikan sentimen, yaitu Naive Bayes, Support Vector Machine (SVM), dan Logistic Regression. Selanjutnya, setiap algoritma akan dilatih menggunakan data latih yang telah melalui pra-pemrosesan dan direpresentasikan sebagai fitur TF-IDF, beserta label sentimen yang sesuai.

### 2.8.1 Naive Bayes

Algoritma Naive Bayes, terutama jenis Multinomial Naive Bayes yang biasanya dipakai untuk keperluan klasifikasi teks dengan fitur frekuensi kata, akan diimplementasikan menggunakan pustaka *scikit-learn* (`sklearn.naive_bayes.MultinomialNB`) [21]. Model akan dilatih memakai data latih yang sudah diproses. Kemungkinan akan dilakukan penyesuaian parameter *smoothing* ( $\alpha$ ) melalui teknik *cross-validation* untuk mengoptimalkan kinerja model. Model *Naive Bayes* dipilih karena efisiensinya dan seringkali memberikan hasil yang kompetitif dalam tugas klasifikasi teks meskipun asumsi independensi fiturnya yang sederhana.

### 2.8.2 SVM

Algoritma *Support Vector Machine* (SVM) akan diimplementasikan menggunakan pustaka *scikit-learn* (`sklearn.svm.SVC`). Pemilihan jenis *kernel* yang sesuai untuk data teks, seperti *kernel linear*, akan dipertimbangkan. Proses pelatihan model SVM akan dilakukan dengan data latih menggunakan parameter default dari implementasi pustaka [22]. SVM dipilih karena kapasitasnya untuk menangani data berdimensi besar dan menemukan *hyperplane* optimal untuk pemisahan kelas.

### 2.8.3 Logistic Regression

Algoritma *Logistic Regression* akan diimplementasikan menggunakan pustaka *scikit-learn* (`sklearn.linear_model.LogisticRegression`). Model ini akan dilatih menggunakan data latih dengan parameter default dari implementasi pustaka. *Logistic Regression* dipilih karena interpretasinya yang relatif mudah dan kemampuannya untuk memberikan probabilitas kelas, serta seringkali menunjukkan kinerja yang baik dalam klasifikasi teks setelah fitur direpresentasikan dengan tepat [22].

## 2.9 Evaluasi

Setelah proses pelatihan selesai, kinerja dari ketiga model klasifikasi sentimen (*Naive Bayes*, SVM, dan *Logistic Regression*) akan dievaluasi memakai data uji yang sebelumnya tidak dipakai dalam masa pelatihan. Evaluasi ini dilakukan dengan tujuan untuk menilai seberapa baik setiap algoritma bekerja dalam mengklasifikasikan sentimen terkait isu KaburAjaDulu. Untuk mengukur kinerja tersebut, beberapa metrik evaluasi berikut akan digunakan:



- a. Akurasi adalah metrik yang digunakan untuk mengetahui seberapa banyak prediksi model yang tepat dibandingkan dengan keseluruhan data yang diuji.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{1}$$

- b. Presisi (*Precision*) bertujuan untuk menilai proporsi *tweet* yang diprediksi menjadi sentimen positif (atau negatif) yang sebenarnya memiliki sentimen positif (atau negatif). Presisi akan dihitung untuk kedua kelas sentimen.

$$Precision = \frac{TP}{TP + FP} \tag{2}$$

- c. Recall, atau yang juga disebut sensitivitas, mengukur kemampuan model untuk menemukan semua *tweet* yang sebenarnya memiliki sentimen positif (atau negatif) dan berhasil mengklasifikasikannya dengan benar. Metrik ini dihitung untuk setiap kelas sentimen.

$$Recall = \frac{TP}{TP + FN} \tag{3}$$

- d. 1-Score merupakan hasil perhitungan rata-rata harmonik dari presisi dan recall. Metrik ini menyajikan evaluasi kinerja model yang lebih komprehensif, terutama jika jumlah data untuk setiap kategori sentimen tidak seimbang. F1-Score juga dihitung untuk setiap kelas sentimen.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{4}$$

Untuk memberikan visualisasi kinerja klasifikasi dengan menampilkan perhitungan banyaknya prediksi yang tepat (*True Positive* dan *True Negative*) serta jumlah prediksi yang keliru (*False Positive* dan *False Negative*) yang dihasilkan oleh model klasifikasi sentimen [23]. Perbandingan kinerja antara ketiga algoritma akan didasarkan pada nilai metrik-metrik evaluasi ini. Analisis akan dilakukan untuk mengidentifikasi algoritma mana yang menunjukkan kinerja terbaik secara keseluruhan dalam mengklasifikasikan sentimen pada dataset isu KaburAjaDulu. Selain itu, perbandingan kinerja sebelum dan sesudah penerapan SMOTE (jika diterapkan) juga akan dilakukan untuk mengevaluasi efektivitas teknik penanganan ketidakseimbangan kelas terhadap kinerja model. Pada akhirnya, analisis ini dimaksudkan untuk mengenali algoritma mana yang menunjukkan kinerja terbaik dalam memahami dan mengategorikan sentimen yang berkaitan dengan isu spesifik yang sedang dibahas.

### 3. HASIL DAN PEMBAHASAN

Bab ini akan memaparkan temuan dari implementasi dan pengujian model untuk mengklasifikasikan sentimen terkait isu KaburAjaDulu yang beredar di platform media sosial X. Studi ini memanfaatkan tiga algoritma machine learning yang berbeda guna melaksanakan analisis, yaitu Support Vector Machine (SVM), Logistic Regression, Naive Bayes. Kinerja dari setiap model dievaluasi menggunakan beberapa ukuran, termasuk *accuracy*, *precision*, *recall*, dan *f1-score*, baik sebelum maupun sesudah penerapan teknik oversampling SMOTE. Setiap tahapan analisis disertai dengan visualisasi data dan pembahasan mendalam.

#### 3.1 Pengumpulan Data

Studi ini bertujuan untuk mengumpulkan berbagai pendapat masyarakat mengenai isu "KaburAjaDulu" yang tersebar di platform media sosial X (sebelumnya Twitter). Pengambilan data dilakukan secara otomatis melalui proses *crawling* yang dibantu oleh *library* Tweet Harvest, berdasarkan kata kunci spesifik yang relevan dengan isu utama "#KaburAjaDulu" dalam rentang waktu yang relevan dengan popularitas isu, yaitu 1 Januari 2025 hingga 26 April 2025. Hasil dari proses ini adalah terkumpulnya total 3.011 *tweet*. Setiap data *tweet* yang berhasil dihimpun mengandung informasi mengenai *username* penulis dan teks lengkap *tweet* (*full\_text*), yang menjadi materi utama untuk analisis sentimen. Informasi lebih detail mengenai hal ini dapat ditemukan pada Tabel 1.

**Tabel 1.** Data Tweet Hasil Crawling

Username	Tweet
JHTY_mochitrack	Mau kabur aja dulu ke negara tetangga kayak malaysia atau singapura atau nggak ke brunei mau kerjaa di sana kalau ada kesempatan
2022Wibpr	@VindhTR harusnya pemikiran kolot aneh macam taliban begitu sekalian aja mereka kabur aja dulu ke afghanistan..di sana hasrat patriarki terpenuhi.. perempuan suruh tertutup dari atas ke bawah.. kerjanya cuma boleh ngemis di sekitar tukang roti...
sam_faris18	@Mdy_Asmara1701 susah nyari pemerintahan yg ideal makanya ga ush percaya sama mereka bisa kabur aja dulu silahkan gess lebih baik

### 3.2 Preprocessing Data

Sebagai persiapan untuk analisis sentimen, data tweet yang masih belum diolah dan telah terkumpul melalui tahapan *crawling* menjalani serangkaian proses *preprocessing* yang esensial untuk meningkatkan kualitas data dan mempersiapkannya agar sesuai untuk pemodelan *machine learning*. Tahapan ini bertujuan untuk menghilangkan *noise*, menstandarisasi format teks, dan mereduksi variasi kata yang tidak perlu tanpa menghilangkan informasi sentimen yang relevan. Proses *preprocessing* yang diterapkan dalam penelitian ini meliputi beberapa langkah sistematis, yang hasilnya diilustrasikan pada Tabel 2 menggunakan contoh salah satu *tweet* dari dataset.

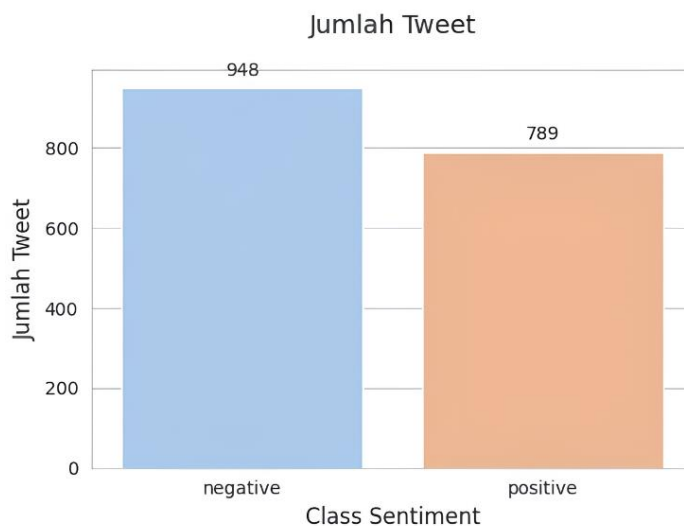
Tabel 2. Data Hasil Preprocessing

Preprocessing	Tweet
Tweet	Mau kabur aja dulu ke negara tetangga kayak malaysia atau singapura atau nggak ke brunei mau kerjaa di sana kalau ada kesempatan
Cleaning	mau kabur aja dulu ke negara tetangga kayak malaysia atau singapura atau nggak ke brunei mau kerjaa di sana kalau ada kesempatan
Case Folding	mau kabur aja dulu ke negara tetangga kayak malaysia atau singapura atau nggak ke brunei mau kerjaa di sana kalau ada kesempatan
Normalisasi	mau kabur aja dulu ke negara tetangga kayak malaysia atau singapura atau nggak ke brunei mau kerjaa di sana kalau ada kesempatan
Tokenizing	mau,kabur,aja,dulu,ke,negara,tetangga,kayak,malaysia,atau,singapura,atau,nggak,ke,brunei, mau,kerjaa,di,sana,kalau,ada,kesempatan
Stopword Removal	kabur,aja,negara,tetangga,kayak,malaysia,singapura,nggak,brunei,kerjaa,kesempatan
Stemming	kabur aja negara tetangga kayak malaysia singapura nggak brunei kerjaa sempat

Tabel 2 memberikan gambaran konkret mengenai transformasi sebuah *tweet* melalui setiap langkah *preprocessing*. Dimulai dari teks asli yang mengandung elemen-elemen seperti *hashtag*, proses *cleaning* menghilangkan karakter-karakter non-alfanumerik dan elemen yang dianggap kurang relevan untuk analisis sentimen. Tahap berikutnya yaitu *case folding*, sebuah proses mengubah keseluruhan karakter dalam teks dikonversi ke format huruf kecil. Proses normalisasi dilakukan untuk mengganti kosakata yang tidak sesuai kaidah bahasa atau disingkat ke dalam format yang lebih formal. Kemudian, tokenisasi menguraikan teks diuraikan menjadi elemen-elemen yang lebih kecil berupa kata atau token. Tujuan dilakukannya *stopword removal* adalah untuk membersihkan teks dari kata-kata yang lazim dan dianggap kurang penting dalam menentukan sentimen. Langkah terakhir adalah *stemming*, yang mengubah setiap kata menjadi bentuk dasarnya. Hasil akhir dari tahapan ini adalah representasi kata-kata yang lebih ringkas dan terstandarisasi, yang akan digunakan dalam proses representasi fitur TF-IDF.

### 3.3 Labeling Data

Setelah melalui tahapan pra-pemrosesan, setiap data *tweet* diberikan label sentimen untuk keperluan klasifikasi. Dalam penelitian ini, pendekatan berbasis leksikon digunakan dalam menentukan polaritas sentimen di setiap *tweet*. Proses pelabelan ini menghasilkan dua kategori utama sentimen, yaitu positif dan negatif. Gambar 2 menyajikan visualisasi distribusi jumlah *tweet* untuk masing-masing label sentimen yang berhasil diterapkan pada keseluruhan dataset.



Gambar 2. Diagram Hasil Pelabelan

Gambar 2 memperlihatkan distribusi jumlah *tweet* berdasarkan label sentimen yang telah ditetapkan. Berdasarkan hasil pelabelan menggunakan pendekatan berbasis leksikon, dataset terdiri dari 948 *tweet* yang diklasifikasikan sebagai sentimen negatif, yang mencakup 31,52% dari total keseluruhan data. Sementara itu, terdapat

789 *tweet* yang dilabeli sebagai sentimen positif, merepresentasikan 26,23% dari total dataset. Visualisasi ini memberikan gambaran mengenai proporsi data untuk setiap kelas sentimen sebelum penerapan teknik penanganan ketidakseimbangan kelas (SMOTE). Perbedaan jumlah antara sentimen negatif dan positif mengindikasikan adanya ketidakseimbangan kelas dalam dataset awal.

### 3.4 Pengujian dan Evaluasi

Setelah proses pelatihan model Support Vector Machine (SVM), Logistic Regression, dan Naive Bayes Classifier (NBC) menggunakan data latih selesai, langkah berikutnya adalah menguji performa setiap model. Pengujian ini dilakukan dengan menggunakan sekumpulan data pengujian yang terpisah dan belum pernah terpapar pada model selama proses pembelajaran. Hal ini bertujuan untuk mengukur kemampuan setiap model dalam memprediksi sentimen pada data yang benar-benar baru dan membandingkan keunggulan masing-masing algoritma dalam mengklasifikasikan sentimen terkait isu KaburAjaDulu. Hasil evaluasi yang terdiri atas metrik *accuracy*, *precision*, *recall*, dan *F1-Score* untuk sentimen negatif dan positif tersaji dalam Tabel 3.

**Tabel 3.** Hasil *Classification Report* sebelum SMOTE

Model	Class	Accuracy	Precision	Recall	F1-Score
NBC	Negatif	78%	74%	93%	83%
	Positif		88%	59%	71%
SVM	Negatif	86%	85%	91%	88%
	Positif		87%	79%	83%
Logistic Regression	Negatif	83%	79%	94%	86%
	Positif		91%	69%	78%

Tabel 3 menyajikan laporan klasifikasi kinerja ketiga model sebelum penerapan SMOTE. Pada kondisi awal, algoritma SVM menunjukkan Model dengan tingkat akurasi paling tinggi adalah SVM, mencapai 86%. Di urutan berikutnya adalah Logistic Regression dengan akurasi sebesar 83%, dan kemudian Naive Bayes Classifier (NBC) dengan akurasi 78%. Detail metrik untuk setiap kelas sentimen (negatif dan positif) juga ditampilkan. Misalnya, untuk SVM, presisi dalam mengidentifikasi sentimen negatif adalah 85% dengan *recall* 91%, menghasilkan F1-Score 88% untuk kelas negatif. Sementara itu, untuk sentimen positif, presisinya 87% dengan *recall* 79% dan F1-Score 83%. Perbandingan metrik antar model pada kondisi sebelum SMOTE memberikan gambaran awal mengenai kemampuan klasifikasi masing-masing algoritma pada distribusi data awal.

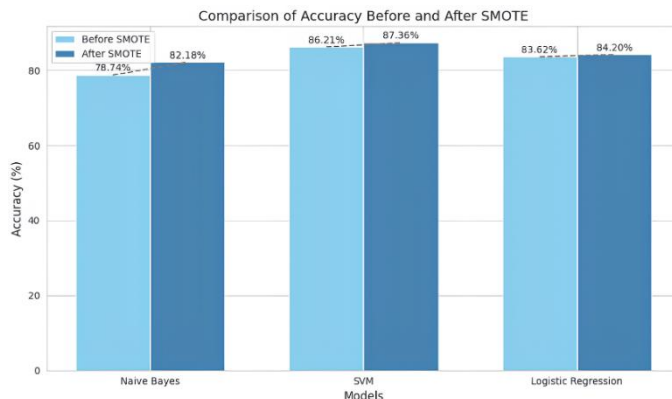
Untuk menganalisis pengaruh teknik oversampling (SMOTE) terhadap kinerja klasifikasi sentimen, Tabel 4 menyajikan laporan klasifikasi yang komprehensif dari ketiga model (Naive Bayes Classifier, Support Vector Machine, dan Logistic Regression) setelah pelatihan dilakukan dengan memanfaatkan data latih yang sudah di-oversampling untuk mengatasi potensi ketidakseimbangan kelas.

**Tabel 4.** Hasil *Classification Report* setelah SMOTE

Model	Class	Accuracy	Precision	Recall	F1-Score
NBC	Negatif	82%	85%	84%	83%
	Positif		77%	79%	71%
SVM	Negatif	86%	85%	90%	87%
	Positif		87%	80%	83%
Logistic Regression	Negatif	83%	82%	90%	86%
	Positif		85%	75%	80%

Tabel 4 menyajikan laporan klasifikasi kinerja ketiga model setelah data latih di-oversampling menggunakan SMOTE. Terlihat adanya perubahan kinerja pada beberapa model. Akurasi NBC meningkat menjadi 82%, yang menunjukkan adanya perbedaan yang cukup besar dalam nilai presisi dan recall untuk kategori sentimen negatif dan positif. Presisi untuk sentimen negatif meningkat menjadi 85% namun *recall* sedikit menurun menjadi 84%, sementara untuk sentimen positif, presisi menurun menjadi 77% namun *recall* meningkat menjadi 79%. Pada model SVM, akurasi tetap stabil di angka 86%, dengan sedikit perubahan pada nilai presisi dan *recall* pada kedua jenis sentimen, yaitu positif dan negatif. Logistic Regression juga menunjukkan akurasi yang sama yaitu 83%, namun terdapat perubahan mengenai nilai presisi dan *recall* pada kedua kategori sentimen positif dan negatif. Secara keseluruhan, perbandingan antara Tabel 3 dan Tabel 4 memberikan insight mengenai dampak penerapan SMOTE terhadap kinerja klasifikasi masing-masing algoritma.

Untuk mengevaluasi dampak teknik penanganan ketidakseimbangan kelas, Gambar 3 berikut memvisualisasikan diagram perbandingan akurasi model Naive Bayes, SVM, dan Logistic Regression sebelum dan setelah implementasi SMOTE.



Gambar 3. Diagram Perbandingan 3 Model

Berdasarkan grafik batang pada Gambar 3 yang membandingkan akurasi Naive Bayes, SVM, dan Logistic Regression sebelum dan sesudah SMOTE. Penerapan SMOTE secara signifikan meningkatkan akurasi Naive Bayes 78,16% menjadi 81,90%, sedikit meningkatkan akurasi Logistic Regression 83,05% menjadi 83,33%, namun tidak berpengaruh pada akurasi SVM tetap 85,63%. Secara keseluruhan, SMOTE memberikan manfaat berbeda pada setiap algoritma, dengan Naive Bayes menunjukkan peningkatan terbesar, SVM stabil, dan Logistic Regression meningkat moderat, menekankan pentingnya mempertimbangkan karakteristik algoritma dan dataset saat menangani ketidakseimbangan kelas.

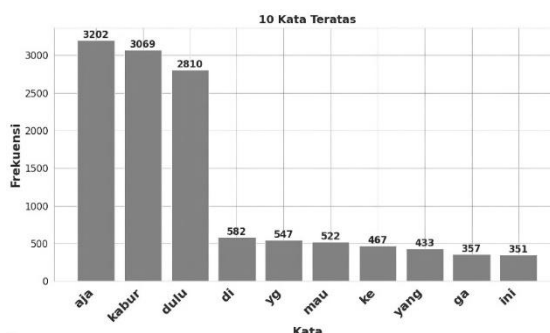
Untuk memberikan wawasan lebih lanjut mengenai karakteristik sentimen dalam dataset, visualisasi *word cloud* dihasilkan untuk mempresentasikan kosakata yang paling berulang kali muncul di dalam *tweet* berlabel positif dan negatif secara terpisah.



Gambar 4. Wordcloud Positif dan Negatif

Gambar 4 menyajikan representasi visual berupa *word cloud* untuk sentimen positif dan negatif mengilustrasikan secara visual kata-kata yang paling dominan dalam masing-masing kategori *tweet*. Pada *word cloud* sentimen positif, kata-kata dengan ukuran lebih besar seperti "kabur aja", "udah", "negara", dan kata-kata lain yang menonjol mengindikasikan frekuensi tinggi dalam *tweet* yang mengekspresikan pandangan positif terhadap isu KaburAjaDulu, memberikan wawasan kualitatif mengenai aspek-aspek yang diasosiasikan dengan sentimen positif. Sementara itu, pada *word cloud* sentimen negatif, kata-kata yang dominan seperti "kabur aja", "negara", "gak", "gue", dan lainnya dengan ukuran yang lebih besar mencerminkan frekuensi tinggi dalam *tweet* yang mengekspresikan sentimen negatif. Analisis perbandingan kedua *word cloud* ini membantu mengidentifikasi perbedaan leksikal yang signifikan antara *tweet* dengan sentimen positif dan negatif terhadap isu KaburAjaDulu.

Untuk memberikan gambaran yang lebih komprehensif mengenai karakteristik linguistik dalam dataset, Gambar berikut menyajikan visualisasi grafik batang yang menampilkan 10 kata dengan frekuensi kemunculan tertinggi setelah seluruh data *tweet*. Analisis frekuensi kata ini membantu mengidentifikasi istilah-istilah yang paling dominan dalam percakapan terkait isu KaburAjaDulu.



Gambar 5. Sebaran 10 Kata Sering Muncul

Gambar 5 menyajikan grafik batang yang menampilkan 10 kata dengan frekuensi kemunculan tertinggi dalam keseluruhan dataset *tweet* setelah melalui tahapan pra-pemrosesan. Sumbu horizontal merepresentasikan 10 kata teratas, yaitu "aja", "kabur", "dulu", "di", "yg", "mau", "ke", "yang", "ga", dan "ini". Sumbu vertikal menunjukkan frekuensi kemunculan masing-masing kata. Berdasarkan visualisasi, kata "aja" memiliki frekuensi tertinggi, diikuti oleh "kabur" dan "dulu". Kata-kata lain seperti "di", "yg", "mau", "ke", "yang", "ga", dan "ini" juga termasuk dalam 10 kata teratas namun dengan frekuensi yang lebih rendah dibandingkan tiga kata pertama. Informasi ini menyajikan ilustrasi umum terkait kata-kata yang paling menonjol pada percakapan terkait isu KaburAjaDulu, meskipun frekuensi kemunculan suatu kata tidak secara langsung mengindikasikan polaritas sentimennya dan memerlukan analisis lebih lanjut dalam konteks kalimat.

### 3.5 Pembahasan

Hasil evaluasi menunjukkan bahwa algoritma SVM secara konsisten memiliki kinerja terbaik dengan akurasi 85,63%, baik sebelum maupun sesudah diterapkan teknik oversampling SMOTE. Sementara itu, Naive Bayes mengalami peningkatan akurasi yang signifikan dari 78,16% menjadi 81,90% setelah diterapkan SMOTE, sedangkan Logistic Regression hanya mengalami peningkatan tipis dari 83,05% menjadi 83,33%. Temuan ini menunjukkan bahwa keberhasilan penggunaan SMOTE bergantung pada karakteristik algoritma: Naive Bayes, yang sensitif terhadap distribusi kelas, mendapatkan manfaat lebih besar dibandingkan SVM yang sejak awal sudah mampu menangani ketidakseimbangan dengan baik. Tidak hanya akurasi, parameter lain seperti precision, recall, dan f1-score juga mendukung kesimpulan bahwa SVM unggul dalam mengenali pola sentimen positif maupun negatif. Hal ini selaras dengan penelitian sebelumnya oleh Dahlian dan Sitanggang (2023) yang menunjukkan bahwa SVM sering kali mengungguli algoritma lain dalam klasifikasi teks karena kemampuannya memaksimalkan margin antar kelas. Di sisi lain, Logistic Regression, meskipun memiliki interpretabilitas yang baik, cenderung kalah akurat karena sensitivitasnya terhadap representasi fitur, sementara Naive Bayes unggul pada data besar tetapi lemah jika asumsi independensi antar fitur tidak terpenuhi. Analisis wordcloud dan distribusi kata juga menunjukkan bahwa kata-kata seperti "kabur aja", "negara", dan "gak" mendominasi kedua sentimen, baik positif maupun negatif. Namun, frekuensi kemunculan kata tidak selalu mengindikasikan polaritas sentimen; konteks penggunaannya lebih menentukan makna sentimen dalam kalimat. Oleh karena itu, pemodelan machine learning yang mampu menangkap pola kompleks menjadi sangat penting. Jika dibandingkan dengan penelitian terdahulu seperti oleh Vania dkk (2025), hasil penelitian ini juga menegaskan bahwa SVM sering menjadi pilihan unggul untuk analisis sentimen di media sosial, khususnya pada kasus-kasus dengan bahasa informal, penggunaan slang, serta adanya sarkasme yang umum di platform X. Namun, perlu dicatat bahwa keberhasilan ini tetap bergantung pada kualitas preprocessing, pemilihan fitur, serta parameter tuning yang digunakan. Dengan demikian, temuan penelitian ini tidak hanya memperkuat bukti empiris terkait keunggulan SVM, tetapi juga memberikan gambaran praktis bagi praktisi data science tentang pentingnya memilih algoritma sesuai dengan karakteristik data yang dianalisis. Studi ini juga menyoroti bahwa penanganan imbalance menggunakan teknik seperti SMOTE harus disesuaikan dengan model yang digunakan, karena tidak semua algoritma merespons teknik oversampling dengan cara yang sama.

## 4. KESIMPULAN

Penelitian ini secara khusus meneliti dan membandingkan kemampuan algoritma Naive Bayes, SVM, dan Logistic Regression dalam mengidentifikasi kecenderungan sentimen dalam percakapan mengenai isu KaburAjaDulu di platform X. Hasilnya mengungkapkan bahwa algoritma SVM secara konsisten menghasilkan akurasi tertinggi sebesar 85,63%, baik sebelum maupun sesudah diterapkan metode SMOTE yang bertujuan untuk mengatasi masalah ketidakseimbangan kelas data sentimen. Penerapan SMOTE terbukti signifikan dalam meningkatkan akurasi Naive Bayes dari 78,16% menjadi 81,90%, serta memberikan sedikit peningkatan pada Logistic Regression dari 83,05% menjadi 83,33%. Analisis metrik lain seperti precision, recall, dan f1-score semakin menguatkan bahwa SVM unggul dalam memahami pola sentimen pada data media sosial yang bersifat informal. Meskipun demikian, penelitian ini memiliki beberapa keterbatasan, di antaranya hanya memfokuskan analisis pada dua kategori sentimen (positif dan negatif) tanpa mempertimbangkan kelas netral, penggunaan dataset dari satu periode waktu yang terbatas, serta belum melakukan eksplorasi terhadap algoritma lain yang mungkin lebih canggih seperti Random Forest atau deep learning. Oleh karena itu, penelitian selanjutnya disarankan untuk mengeksplorasi lebih banyak kelas sentimen, memperluas cakupan data, dan membandingkan hasil dengan metode pemodelan lanjutan agar diperoleh pemahaman yang lebih komprehensif.

## REFERENCES

- [1] P. I. Purnama and R. R. Suryono, "Analisis Sentimen Acara Clash of Champions dengan Algoritma Naive Bayes dan Support Vector Machine," *BITS*, vol. 6, no. 4, pp. 2277–2287, 2025, doi: 10.47065/bits.v6i4.6575.
- [2] N. Abelia, K. J. Farah, D. Wibisono, and I. Mahmud, "Dampak Framing Tagar # Kaburajadulu Terhadap Opini Publik dan Kebijakan Sosial di Indonesia," *Filosofi*, vol. 2, no. 2, pp. 71–77, 2025, doi: <https://doi.org/10.62383/filosofi.v2i2.577>.
- [3] M. Siahaan, Elisa; Sinulingga, Sania; Damanik, Bea; Ritonga, "Analisis Wacana Kritis Norman Fairclough Terhadap Tagar#Kaburajadulu Dalam Berita Media Daring Kompas.Com Dandetik.Com," *Inov. Pendidik. Nusant.*, vol. 6, no. 2, pp.



- 517–531, 2025.
- [4] P. Sari, M. Julianty, D. Mirza, N. Nafilah, and S. Zulfachrinal, “Menghadapi Ancaman Nasionalisme Disintegrasi Bangsa di Tengah Trend Kabur Aja Dulu,” *JUBPI*, vol. 3, no. 2, pp. 193–199, 2025, doi: <https://doi.org/10.55606/jubpi.v3i2.3821>.
- [5] A. M. Rani and N. Hendrastuty, “Perbandingan Algoritma NBC Dan SVM Untuk Melakukan Analisis Sentimen Terhadap PP NO . 82 Tahun 2021,” *BITS*, vol. 6, no. 4, pp. 2139–2151, 2025, doi: 10.47065/bits.v6i4.6496.
- [6] J. S. Hutagalung and Rasiban, “Analisis Sentimen Keuangan (Data Fiqa and Financial Phrasebank) Menggunakan Algoritma Logistic Regression Dan Support Vector Machine,” *J. Indones. Manaj. Inform. dan Komun.*, vol. 4, no. 3, pp. 1654–1669, 2023, doi: 10.35870/jimik.v4i3.404.
- [7] R. I. Saputri, S. Khomsah, and N. A. Prasetyo, “Perbandingan Metode Naïve Bayes Classifier Dan Support Vector Machine Untuk Klasifikasi Cyber Harassment Pada Twitter,” *Algorit. J. Ilmu Komput. dan Inform.*, vol. 8, no. 1, pp. 10–21, 2024, doi: 10.30829/algoritma.v8i1.16601.
- [8] G. Natalianus, V. Kurniawan, and N. R. Feta, “Perbandingan Akurasi Algoritma Naïve Bayes Dan Support Vector Machine Dalam Analisis Sentimen Pengguna Twitter Terhadap Aplikasi Sirekap Abstrak,” *Fountain Informatics J.*, vol. 9, no. 2, pp. 11–17, 2024, doi: <http://dx.doi.org/10.21111/fij.v9i2>.
- [9] B. Ramadhani and R. R. Suryono, “Komparasi Algoritma Naïve Bayes dan Logistic Regression Untuk Analisis Sentimen Metaverse,” *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 714–725, 2024, doi: 10.30865/mib.v8i2.7458.
- [10] A. S. Muliana *et al.*, “Analisis Sentimen Publik terhadap Hasil Pemilu dengan Naïve Bayes pada Media Sosial X Analysis of Public Sentiment on Election Results using Naïve Bayes in Social Media X,” *J. Sist. Sist. Inf.*, vol. 13, no. 6, pp. 2467–2478, 2024, doi: <https://doi.org/10.32520/stmsi.v13i6.4592>.
- [11] R. B. Dahlian and D. Sitanggang, “Sentiment Analysis of Digital Television Migration on Twitter Using Naïve Bayes Multinomial Comparison, Support Vector Machines, and Logistic Regression Algorithms,” *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 12, no. 2, pp. 280–288, 2023, doi: 10.32736/sisfokom.v12i2.1668.
- [12] A. Hagi and D. B. Rarasati, “Sentiment Analysis of Sirekap Application Review Using Logistic Regression Algorithm,” *J. Inform.*, vol. 11, no. 2, pp. 55–64, 2024, doi: 10.31294/inf.v11i2.22066.
- [13] V. Agresia, R. R. Suryono, U. T. Indonesia, L. Ratu, and K. B. Lampung, “Comparison Of Svm , Naïve Bayes , And Logistic Regression Algorithms For Sentiment Analysis Of Fraud And Bots In Purchasing Concert Ticket Komparasi Algoritma Svm , Naïve Bayes , Dan Logistic Regression Untuk Analisis Sentimen,” *J. INOVTEK Polbeng*, vol. 10, no. 2, pp. 591–602, 2025, doi: <https://doi.org/10.35314/npfydh47>.
- [14] N. Hadi and D. Sugiarto, “Analisis Sentimen Pembangunan IKN pada Media Sosial X Menggunakan Algoritma SVM , Logistic Regression dan Naïve Bayes,” *JPIT*, vol. 10, no. 1, pp. 37–49, 2025, doi: 10.30591/jpit.v10i1.7106.
- [15] Tommy Suhendra, B. Intan, and A. T. Martadinata, “Analisis Sentimen Pengguna Aplikasi Netflix Pada Ulasan Google Playstore Menggunakan Metode Naïve Bayes,” *ESCAF 3rd*, vol. 2, no. 2, pp. 1011–1022, 2024, doi: 10.47065/bits.v6i2.5528.
- [16] E. Triningsih, M. Afdal, I. Permana, and N. E. Rozanda, “Analisis Sentimen Terhadap Program Makan Bergizi Gratis Menggunakan Algoritma Machine Learning Pada Sosial Media X,” *BITS*, vol. 6, no. 4, pp. 2240–2250, 2025, doi: 10.47065/bits.v6i4.6534.
- [17] L. Kencono and D. Darwis, “Perbandingan Algoritma NBC , SVM dan Random Forest untuk Analisis Sentimen Implementasi Starlink pada Media Sosial X,” *BITS*, vol. 6, no. 4, pp. 2288–2300, 2025, doi: 10.47065/bits.v6i4.6813.
- [18] A. R. Ismail and Raden Bagus Fajriya Hakim, “Implementasi Lexicon Based Untuk Analisis Sentimen Dalam Menentukan Rekomendasi Pantai Di DI Yogyakarta Berdasarkan Data Twitter,” *Emerg. Stat. Data Sci. J.*, vol. 1, no. 1, pp. 37–46, 2023, doi: 10.20885/esds.vol1.iss.1.art5.
- [19] F. Nurwanda and J. R. Rizkiani, “Perbandingan Metode Naive Bayes Classifier dan Support Vector Machine pada Analisis Sentimen Twitter Topik Lifestyle,” *J. Ilm. Wahana Pendidik.*, vol. 9, no. 21, pp. 314–323, 2023, [Online]. Available: <https://doi.org/10.5281/zenodo.10077023>
- [20] T. A. Dewi and E. Mailoa, “Perbandingan Implementasi Metode Smote Pada Algoritma Support Vector Machine (Svm) Dalam Analisis Sentimen Opini Masyarakat Tentang Mixue,” *J. Indones. Manaj. Inform. dan Komun.*, vol. 4, no. 3, pp. 849–855, 2023, doi: 10.35870/jimik.v4i3.289.
- [21] N. Wijaya and E. S. Panjaitan, “Analisis Sentimen Ulasan Aplikasi Instagram di Google Play Store : Pendekatan Multinomial Naive Bayes dan Berbasis Leksikon,” *BITS*, vol. 6, no. 2, pp. 921–929, 2024, doi: 10.47065/bits.v6i2.5615.
- [22] S. Agustian and A. Nazir, “Klasifikasi Sentimen Terhadap Pengangkatan Kaesang Sebagai Ketua Umum Partai PSI Menggunakan Metode Support Vector Machine,” *Technol. Sci.*, vol. 6, no. 1, pp. 216–225, 2024, doi: 10.47065/bits.v6i1.5340.
- [23] S. D. Simamora, F. Irwiensyah, and F. N. Hasan, “Analisis Sentimen Terkait Konflik Palestina-Israel Pada Media Sosial X Menggunakan Algoritma Naïve Bayes Classifier,” *Build. Informatics, Technol. Sci. Vol. 6*, vol. 6, no. 1, pp. 146–157, 2024, doi: 10.47065/bits.v6i1.5344.